

Optimasi Prediksi Sisa Umur Penggunaan Baterai dengan Model PSO-LSTM

Optimizing Battery's Remaining Useful Life Prediction using PSO-LSTM Model

Wilson Wiranata¹, Yohanes Calvinus²

^{1,2} Jurusan Teknik Elektro Fakultas Teknik Universitas Tarumanagara; email: wilson.525210017@stu.untar.ac.id, yohanesft@untar.ac.id

[Dikirimkan: 2 November 2024, Direvisi: 28 Mei 2025, Diterima: 31 Mei 2025]
Corresponding Author: Wilson Wiranata

INTISARI — Baterai kini menjadi solusi utama seiring dengan bergesernya sumber energi menjadi energi terbarukan. Pada tahun 2011 hingga 2022 *National Aeronautics and Space Administration* (NASA) telah merekap adanya peningkatan kurang lebih sebanyak 40% nilai PPM dan jumlah karbon dioksida (CO₂). *Electric Vehicle* (EV) telah berkontribusi dalam pengurangan CO₂ dan PPM secara berkelanjutan. Walaupun demikian, teknologi baterai memiliki kekurangan yang bersangkutan dengan masa akhir penggunaan atau yang sering disebut dengan *Remaining Useful Life* (RUL) yang dapat menyebabkan kebakaran atau emisi racun pada baterai tersebut. Penelitian ini akan menggunakan pendekatan data yang memanfaatkan kecerdasan buatan untuk memprediksi RUL baterai, di mana dapat dicegah terjadinya kerusakan baterai dengan model tersebut. Model stokastik *Particle Swarm Optimization - Long Short Term Memory* (PSO-LSTM) telah digunakan untuk mengoptimasi *hyperparameter window size* dan *hidden layer* secara stokastik. Hal tersebut dilakukan untuk mendapat model yang memiliki kesalahan minim. PSO-LSTM memprediksi data yang bersumber dari NASA *Prognosis Centre of Excellence* (PCoE) yang meliputi data “Siklus” dan “Kapasitas”. Didapati bahwa hasil PSO-LSTM teroptimasi dengan baik dengan RMSE 0.074 dan MAE 0.021 (80% data pelatihan), lalu 0.070 untuk RMSE dan 0.021 untuk nilai MAE (20% data pengujian). Model stokastik PSO-LSTM tersebut dapat dikembangkan pada *Battery Management System* (BMS) cerdas untuk keperluan industri otomotif di kemudian harinya.

KATA KUNCI — Energi Terbarukan, Prediksi, PSO-LSTM, RUL

ABSTRACT — Batteries now serve as the main solution amid the shift to renewable energy. Between 2011 and 2022, the National Aeronautics and Space Administration (NASA) recorded an approximate notable 40% increase in global CO₂ concentration in parts per million (PPM). Electric Vehicles (EVs) have contributed to sustainable reductions in CO₂ and PPM. Nevertheless, battery technology has drawbacks related to its end-of-life phase, commonly referred to as Remaining Useful Life (RUL), which can potentially lead to fires or dangerous toxic emissions from the cells. This study will employ a data-driven approach utilizing artificial intelligence to predict battery RUL, thereby effectively preventing potential battery failures with the developed model. The stochastic Particle Swarm Optimization - Long Short Term Memory (PSO-LSTM) model has been used to optimize window size and hidden layer hyperparameters. This was done to achieve a model with minimal error. PSO-LSTM forecasts data sourced from NASA's Prognosis Centre of Excellence (PCoE), encompassing both “Cycle” and distinct “Capacity” measurements. PSO-LSTM model optimization produced RMSE of 0.074 and MAE values of 0.021 on 80% training data, and RMSE of 0.070 with MAE of 0.021 on 20% testing data. This stochastic PSO-LSTM model can be integrated into intelligent Battery Management Systems (BMS) for specific future automotive industry applications


KEYWORD — Prediction, PSO-LSTM, Renewable Energy, RUL

I. PENDAHULUAN

Dengan adanya transisi menuju energi bersih, teknologi baterai merupakan salah satu solusi utama menurunkan tingkat karbon dioksida (CO₂). Badan *National Aeronautics and Space Administration* (NASA) telah merekam temuan data terkait peningkatan jejak CO₂ dari tahun 2011 hingga tahun 2022. Terdapat peningkatan kurang lebih sebanyak 40% nilai PPM dari jumlah karbon CO₂ yang beredar di muka Bumi dalam kurun waktu 10 tahun tersebut [1]. Transportasi memberikan kontribusi terbesar dalam peningkatan ini. Dari tahun 2018 di area Tegal, Jawa Tengah, telah dilakukan survei terhadap kontribusi emisi kendaraan bermotor yang dihasilkan oleh ruas jalan adalah sebesar 80,096,024 g/ jam di Jalan Ki Hajar Dewantoro [2]. Salah satu solusi dari masalah ini adalah dengan menggantikan mobil berbahan bensin (BBM) dengan mobil berkendaraan baterai, atau yang lebih umum disebut dengan *Electric Vehicle* (EV). Sebagai energi terbarukan, baterai telah mendorong industri transportasi menuju energi bersih. Di Negara Republik Tiongkok ditemukan adanya relevansi terhadap peningkatan penjualan EV dan penurunan emisi CO₂. Dengan adanya peningkatan 1% pada penjualan EV, maka terdapat pengurangan emisi karbon sebesar 0.096% di sebuah kota di Republik

Tiongkok [3]. Data-data tersebut menunjukkan signifikansi dari EV dalam perlawanan terhadap polusi CO₂. Teknologi baterai EV yang umum dijumpai di masyarakat merupakan teknologi baterai Lithium Ion (Li-Ion). Baterai Li-Ion memiliki densitas yang lebih tinggi apabila dibandingkan dengan jenis-jenis baterai lainnya seperti Nikel Kadmium (Ni-Cd) dan timbal-asam (Pb-O₂). Densitas baterai Li-Ion berada di kisaran 90-260 Wh/kg tergantung dari material yang digunakan [4]. Walaupun terbaru, baterai tetap mengalami degradasi pada pemakaian sisa umur penggunaan atau yang lebih sering disebut sebagai *Remaining Useful Life* (RUL). RUL dapat diartikan sebagai penurunan performa menuju kegagalan sebuah baterai seiring berjalannya waktu [5].

Apabila sudah mencapai masa akhir dari RUL tersebut, maka terdapat beberapa masalah yang dapat timbul. Pembengkakan baterai dapat menyebabkan kebakaran dan emisi racun dari baterai tersebut. Penyebab utama dari penurunan RUL adalah pengisian dan pengosongan, serta suhu baterai itu sendiri. telah dilakukan survei terhadap pengaruh pengisian dan pengosongan baterai terhadap RUL. Dilakukan percobaan pengosongan baterai 18650 keluaran sony dengan tingkat pengosongan sebesar 1C, 2C, dan 3C. Pada 50 siklus pertama, didapati bahwa baterai tersebut masih stabil. Degradasi yang signifikan terjadi pada siklus ke-52 dan seterusnya. Pada 1C dihasilkan penurunan sebesar 9,5%, 13,2% untuk 2C, dan sebesar 16,9% untuk tingkat pengosongan 3C [6]. Penyebab utama dari fenomena ini adalah dikarenakan adanya *loss* pada karbon di tingkat pengosongan yang lebih tinggi. Selain dari pengosongan dan pengisian, temperatur juga berperan penting terhadap degradasi baterai. Pada suhu 25°C hingga 45°C terdapat peningkatan pada kapasitas baterai. Namun, kapasitas tersebut mengurangi masa RUL baterai [7].



Gambar 1. Peningkatan Nilai PPM

Pada penelitian ini telah dikembangkan model PSO-LSTM untuk memprediksi RUL pada tahap pelatihan dan pengujian dengan menerapkan optimasi hiperparameter *window size* dan *hidden layer* secara stokastik. Optimasi tersebut dilakukan guna mencari solusi terbaik secara cepat dan memaksimalkan hiperparameter yang digunakan untuk hasil yang lebih akurat. Diharapkan bahwa model tersebut dapat dijadikan sebuah model prediksi yang dapat dimanfaatkan di industri baterai untuk kedepannya.

II. KAJIAN PUSTAKA

A. PREDIKSI RUL


Terdapat tiga macam pendekatan yang bisa diterapkan pada prediksi RUL baterai berdasarkan pemahaman terhadap data dan sistem yang dimiliki. Tiga macam tersebut meliputi pendekatan berbasis data, pendekatan fisik, dan pendekatan hibrida. Pendekatan berbasis data memanfaatkan metode matematis dan model kecerdasan buatan untuk memprediksi, sementara pendekatan fisik merupakan pendekatan yang memanfaatkan model fisik (hardware) dari sistem. Masing-masing pendekatan tersebut memiliki kelebihan dan kekurangan. Pada penelitian ini, digunakan pendekatan berbasis data dikarenakan kemudahan dalam implementasi [8]. Penelitian pertama terkait pendekatan berbasis data berawal dengan prediktif berdasarkan model CNN. untuk estimasi masalah RUL. Dalam penelitian itu, digunakan *layer* konvolusi, *pooling*, *squashing sigmoid*, hiperbolik, *rectifier*, dan normalisasi [9].

B. PENELITIAN SERUPA

Terdapat dua jenis model kecerdasan buatan, yakni prediksi non deret waktu dan prediksi deret waktu. Prediksi non deret waktu merupakan pemodelan yang datanya tidak berkaitan dengan waktu seperti model *Backpropagation*, *Neural Network*, dan lain-lain. Sebaliknya, prediksi deret waktu sangat bergantung dengan waktu rekaman data seperti *Autoregressive Integrated Moving Area* (ARIMA), *Gated Recurrent Unit* (GRU), dan lain-lain. Terdapat peningkatan popularitas terhadap pemanfaatan prediksi deret waktu yang ditampilkan pada Gambar 1.2. Bisa dilihat, dari tahun 2000 sampai tahun 2024, ditemui bahwa penggunaan prediksi deret waktu meningkat kurang lebih sebanyak 80% [10].

Penelitian serupa telah dilakukan dengan model kecerdasan buatan yang berbeda, yakni dengan model ARIMA untuk memprediksi RUL dari dataset NASA *Prognosis Centre of Excellence* (PCoE), di mana digunakan metrik *Root Mean Square Error*

(RMSE) yang bernilai 0.209 [11] untuk model tersebut. Selain dari model ARIMA, model sederhana *Random Forest* juga telah digunakan dalam memprediksi RUL dengan dataset yang sama. Hiperparameter yang digunakan pada pemodelan ini adalah 42 *estimator*, 9 fitur maksimum, 10, minimum sampel, dan 10 node maksimum. Metrik yang diukur dari penelitian tersebut adalah RMSE di mana didapatkan nilai metrik yang memuaskan yakni 3.7574 apabila dibandingkan dengan model *Linear Regression* (7.3853) dan *Bayesian Network* (7.3856) [12]. Berdasarkan Gambar 2 mengenai statistik penggunaan prediksi deret waktu, masih sedikit penelitian yang dilakukan terhadap pemodelan hibrida. Pada penelitian ini, akan dibuat pemodelan pembelajaran mesin hibrida yakni PSO-LSTM untuk meningkatkan akurasi dan efisiensi dari prediksi RUL baterai. Salah satu model hibrida yang pernah dimanfaatkan untuk melakukan prediksi terhadap RUL baterai adalah *Hawk Harris-Random Forest* model. Di mana model tersebut dibandingkan dengan *LightGBM*, dan model hibrida *Hawk Harris- LightGBM*. Model *Hawk Harris-Random Forest* memberikan hasil terbaik dengan nilai RMSE sekecil 46.35 [13].



Gambar 2. Statistik Penggunaan Prediksi Deret Waktu

Untuk estimasi masalah RUL. Dalam penelitian itu, digunakan *layer* konvolusi, pooling, *squashing sigmoid*, hiperbolik, rectifier, dan normalisasi [9].

C. MODEL PSO-LSTM

Terinspirasi dari kawanan hewan, algoritma metaheuristik PSO merupakan algoritma pencarian yang berbasis kecerdasan individu, di mana setiap partikel memiliki solusi terhadap penyelesaian masalah (*global best* dan *local best*). Algoritma ini mampu melakukan pembaharuan terhadap partikel-partikel di kawannya dengan rumus matematik sebagai berikut [14] :

$$v^{k+1}i, d = w^{k+1}i, d + c1r1 (pbest^{k+1} i, d - x^{k+1}i, d)(1)$$

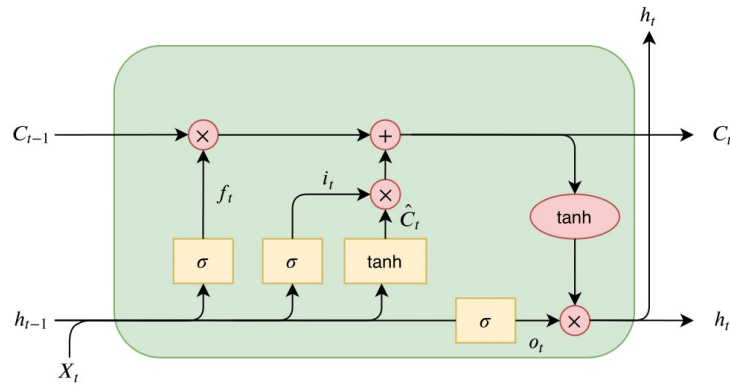
Algoritma cerdas ini akan dipadukan dengan model *Long LSTM* untuk memperoleh hasil akurasi yang lebih baik. LSTM merupakan pengembangan dari model *Recurrent Neural Network*(RNN). Model ini mengatasi masalah utama dari RNN, yakni masalah penurunan gradien pada saat pelatihan data berlebih. Hal tersebut diatasi dengan adanya fitur gerbang pada model LSTM. Terdapat tiga jenis gerbang pada model ini yakni gerbang *input* (2), *output* (3), dan *forget* (4). Ketiga gerbang tersebut dapat dirumuskan sebagai berikut [15] :

$$i(t) = \sigma(Wi [ht - 1, xt] + bi) \quad (2)$$

$$f(t) = \sigma(Wi [ht - 1, xt] + bf) \quad (3)$$

$$o(t) = \sigma(Wi [ht - 1, xt] + bo) \quad (4)$$

Pada penelitian ini, algoritma PSO diajukan sebagai alat optimisasi prediksi dari model LSTM. PSO dapat menentukan ukuran jendela dari model tersebut dengan cerdas [16]. Ukuran jendela dapat didefinisikan sebagai ukuran data yang diambil dalam satu *frame*, jumlah data yang diambil berpengaruh terhadap akurasi hasil akhir dari prediksi model [17].



Gambar 3. Arsitektur LSTM

D. DATASET NASA PCOE

Dataset di atas merupakan kumpulan data pengukuran baterai 18650 dalam beberapa kondisi eksperimen tertentu. Terdapat dua jenis pengambilan data utama yakni pengisian dan pengosongan, pada penelitian ini akan dimanfaatkan data dengan jenis pengosongan untuk prediksi lanjut. Variasi dari tegangan baterai saat pengosongan dimulai dari 2.2 V hingga 2.7 V, sementara nilai arus adalah konstan yang berada di 1.5 A [18]. Tabel 1 akan menampilkan fitur lengkap dari jenis data pengosongan dari dataset Nasa PCoE yang dimaksud.


TABEL I
 FITUR DATASET NASA PCOE

Fitur	Deskripsi
Tegangan diukur	Tegangan baterai (V)
Arus diukur	Arus yang keluar dari baterai (A)
Suhu yang diukur	Suhu baterai yang diukur (C)
Beban Arus	Arus pada beban (A)
Beban Tegangan	Tegangan pada beban (V)
Siklus	Waktu siklus
Kapasitas	Kapasitas Baterai (Ahr)

III. METODOLOGI PENELITIAN

A. METODOLOGI

Penelitian ini memanfaatkan Google Collab sebagai sarana pemrograman, di mana telah dimanfaatkan GPU bawaan milik perancang. Akan diunduh dataset B0007 yang bersumber dari NASA PCoE via Google drive yang dapat dihubungkan langsung kepada Google Colab. Terdapat dua fitur yang digunakan dari dataset tersebut, di antara lain adalah “Siklus” dan “Kapasitas”. Gambar 3 dapat dijadikan sebagai acuan untuk mempermudah pemahaman alur dari perencanaan yang sudah dibuat. Pengolahan data akan dilakukan sebesar 80:20 untuk pengujian dan pelatihan. 80:20 memberikan kestabilan yang lebih baik apabila dibandingkan dengan rasio lainnya seperti 70:30 ataupun 60:40 [19]. Akan diambil data sebanyak lima kali untuk mendapat rerata dari model yang sudah dibuat.



Gambar 4. Alur Metode Penelitian

B. KONFIGURASI HIPERPARAMETER

TABEL II
KONFIGURASI HIPERPARAMETER

PSO-LSTM	CNN	LSTM
Hidden Layer = Intelligent Window Size = Intelligent C1, C2 = 1.5, 2.0 W = 0.01 Epochs = 100 Batch Size = 32	Hidden Layer = 5 Filter = 5 Kernel = 5 Epochs = 100 Batch Size = 32	Hidden Layer = 5 Epochs = 100 Batch Size = 32

Untuk merealisasikan model hibrida PSO-LSTM yang akan dibuat, diperlukan juga beberapa konfigurasi dari hiperparameter model. Hiperparameter merujuk kepada parameter yang dimasukkan sesuai dengan keinginan pengguna. Hiperparameter umum yang digunakan di antara lain adalah *Hidden Layer*, *Window Size*, *Epochs*, dan *BatchSize*. Tabel 2 di atas sudah menampilkan konfigurasi dari hiperparameter yang akan dimanfaatkan pada penelitian ini [20].

C. METRIK EVALUASI

Sebagai tolak ukur dari keakuratan model yang sudah dirancang, akan digunakan beberapa metrik pengukuran standar yang digunakan, di antara lain adalah RMSE dan *Mean Absolute Error* (MAE). RMSE berfungsi untuk mengukur seberapa kecil kesalahan yang dimiliki berdasarkan pengurangan dari nilai asli dan nilai prediksi. Di mana, y_i merepresentasikan hasil prediksi dan y adalah bilangan data aktual. Berbeda dengan RMSE, MAE adalah kumpulan rata-rata kesalahan absolut tanpa membedakan antara kesalahan positif dan negatif. MAE. Nilai RMSE dan MAE yang baik berkisar dari 0 sampai 1, di mana nilai mendekati 0 memberikan hasil yang terbaik [21].

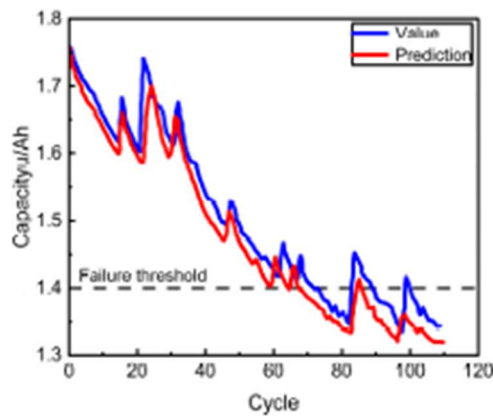
$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - y)^2}{N}} \quad (5)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y| \quad (6)$$

D. GRAFIK PREDIKSI

Selain dari pengukuran metrik, prediksi RUL dapat dilakukan secara visual dengan memanfaatkan grafik prediksi “siklus” terhadap “kapasitas”. Prediksi ini bertujuan untuk mengklasifikasi sifat *overfitting* dan *underfitting* pada data tersebut. Gambar 4


menampilkan contoh dari grafik prediksi yang akan dibuat. Pada contoh gambar 5, garis biru merupakan data asli yang digrafikan dan garis merah mengartikan hasil prediksi model.



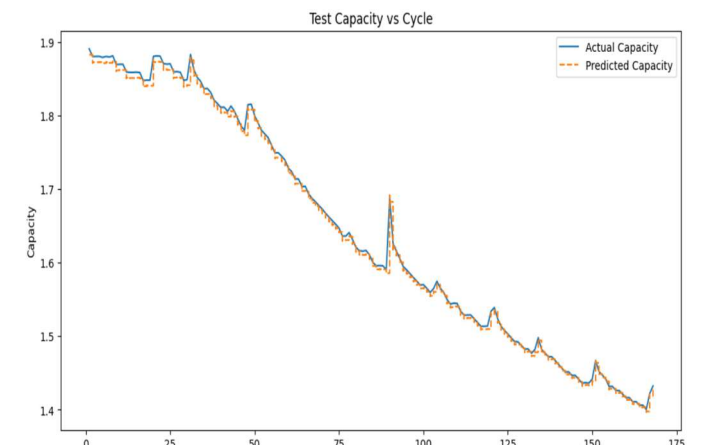
Gambar 5. Prediksi RUL

IV. HASIL DAN PEMBAHASAN

Gambar 6 dan 7 merupakan hasil visualisasi dari data yang asli dan terprediksi, di mana garis biru pada gambar menunjukkan hasil lsi sementara titik kuning merupakan hasil prediksi. Bisa dilihat bahwa hasil yang diprediksi cukup baik, namun model PSO-LSTM ini memiliki kecenderungan untuk *underfitting*. Hal ini dapat dicapai karena adanya terlalu banyak data yang digunakan pada model tersebut.



Gambar 6. Visualisasi PSO-LSTM Training



Gambar 7. Visualisasi PSO-LSTM Testing

TABEL III
HASIL PELATIHAN

Uji-Coba	PSO-LSTM		CNN		LSTM	
	MAE	RMSE	MAE	RMSE	MAE	RMSE
#1	0,073	0,021	0,136	0,173	0,080	0,91
#2	0,074	0,021	0,137	0,174	0,082	0,093
#3	0,073	0,022	0,137	0,171	0,079	0,092
#4	0,075	0,022	0,136	0,170	0,083	0,09
#5	0,077	0,023	0,137	0,171	0,081	0,094
Avg	0,074	0,021	0,136	0,172	0,081	0,092

TABEL IV
HASIL PENGUJIAN

Uji-Coba	PSO-LSTM		CNN		LSTM	
	MAE	RMSE	MAE	RMSE	MAE	RMSE
#1	0,069	0,02	0,132	0,167	0,090	0,093
#2	0,071	0,018	0,134	0,169	0,088	0,092
#3	0,070	0,019	0,133	0,168	0,089	0,095
#4	0,068	0,017	0,131	0,166	0,087	0,091
#5	0,072	0,021	0,135	0,170	0,091	0,095
Avg	0,070	0,021	0,133	0,168	0,089	0,093

Dapat dilihat dari hasil Tabel 3 maupun Tabel 4, model PSO-LSTM yang diajukan memberikan hasil terbaik dengan nilai kesalahan RMSE dan MAE terendah. Pada Tabel 3 dengan pelatihan (80%) didapati rerata MAE dan RMSE sebesar 0.074 dan 0.021. Hasil tersebut bisa dibandingkan dengan model CNN yang bernilai 0.136 dan 0.172. Model LSTM yang berdiri sendiri menghasilkan nilai 0.081 dan 0.092. Sifat serupa dapat dijumpai pada Tabel 4. Nilai MAE dan RMSE dari model PSO-LSTM yang didapatkan ketika pengujian adalah 0.070 dan 0.019, sementara rerata Model CNN adalah 0.133 dan 0.168 (MAE dan RMSE), lalu model LSTM menghasilkan nilai 0.089 dan 0.093 untuk masing-masing metrik. Model PSO-LSTM dapat memberikan nilai keakuratan tinggi untuk *deployment* pada sebuah *Battery Management System* (BMS) di kedepannya.

V. KESIMPULAN

Berdasarkan hasil prediksi dari grafik visualisasi dan metrik, dapat disimpulkan bahwa *window size* dan *hidden layer* model PSO-LSTM telah teroptimasi secara stokastik dengan baik. Hasil keakuratan tersebut dapat dilihat dari metrik pengukuran yang memiliki RMSE dan MAE sebesar 0.074 dan 0.021 untuk rata-rata data pelatihan, kemudian dengan nilai 0.070 dan 0.021 untuk pengujian. Model PSO-LSTM dapat dikembangkan lebih lanjut di dalam pembuatan BMS cerdas pada industri baterai EV.

KONFLIK KEPENTINGAN

Dengan ini, penulis menyatakan bahwa seluruh proses penelitian telah dilakukan secara independen dan objektif. Tidak terdapat konflik kepentingan, baik secara finansial, profesional, maupun pribadi, yang dapat memengaruhi representasi atau interpretasi hasil penelitian ini. Segala temuan disampaikan dengan integritas akademik demi kontribusi yang jujur terhadap pengembangan ilmu pengetahuan.

REFERENSI

- [1] G. Zola, D. Nugraheni, A. Rosiana, A. Dzamar, A. Pambudy, and N. Agustanta, "Inovasi kendaraan listrik sebagai upaya meningkatkan kelestarian lingkungan dan mendorong pertumbuhan ekonomi hijau di Indonesia," *Ekonomi Sumberdaya dan Lingkungan*, vol. 11, no. 3, pp. 2303–1220, 2023.
- [2] P. Hendratmoko and Y. E. R. U. Dewantoro, "Pemetaan Emisi CO₂ hasil kontribusi kegiatan transportasi di Kota Tegal Jawa Tengah," *Jurnal Keselamatan Transportasi Jalan (Indonesian Journal of Road Safety)*, vol. 5, no. 2, pp. 19–28, 2018. Available: <https://doi.org/10.46447/kjtj.v5i2.46>
- [3] X. Zhao, H. Hu, H. Yuan, and X. Chu, "How does adoption of electric vehicles reduce carbon emissions? Evidence from China," *Heliyon*, vol. 9, no. 9, p. e20296, 2023. Available: <https://doi.org/10.1016/j.heliyon.2023.e20296>
- [4] Perdana, F. A. (2021). Baterai Lithium. INKUIRI: Jurnal Pendidikan IPA, 9(2), 113. <https://doi.org/10.20961/inkui.v9i2.50082>
- [5] C. Xiongzi, Y. Jinsong, T. Diyin, and W. Yingxun, "Remaining useful life prognostic estimation for aircraft subsystems or components: A review," in *Proc. 10th IEEE Int. Conf. Electron. Meas. Instrum. (ICEMI)*, 2011, vol. 2, pp. 94.
- [6] Q. Dai, J. C. Kelly, L. Gaines, and M. Wang, "Life cycle analysis of lithium-ion batteries for automotive applications," *Batteries*, vol. 5, no. 2, 2019. Available: <https://doi.org/10.3390/batteries5020048>
- [7] L. Timilsina, P. R. Badr, P. H. Hoang, G. Ozkan, B. Papari, and C. S. Edrington, "Battery degradation in electric and hybrid electric vehicles: A survey study," *IEEE Access*, vol. 11, pp. 42431–42462, 2023.



- [8] M. S. Reza, M. Mannan, M. Mansor, P. J. Ker, T. M. I. Mahlia, and M. A. Hannan, "Recent advancement of remaining useful life prediction of lithium-ion battery in electric vehicle applications: A review of modelling mechanisms, network configurations, factors, and outstanding issues," *Energy Reports*, vol. 11, Apr. 2024, pp. 4824–4848. Available: <https://doi.org/10.1016/j.egy.2024.04.039>
- [9] S. B. Navathe, W. Wu, S. Shekhar, X. Du, X. S. Wang, and H. Xiong, "Deep convolutional neural network based regression approach for estimation of remaining useful life," pp. E1–E1, 2016.
- [10] S. S. W. Fatima and A. Rahimi, "A review of time-series forecasting algorithms for industrial manufacturing systems," *Machines*, vol. 12, no. 6, 2024. Available: <https://doi.org/10.3390/machines12060380>
- [11] Zhou, Y., & Huang, M. (2016). Microelectronics Reliability Lithium-ion batteries remaining useful life prediction based on a mixture of empirical mode decomposition and ARIMA model. MR. Available : <https://doi.org/10.1016/j.microrel.2016.07.151>
- [12] Sekhar, J. N. C., Domathoti, B., & Santibanez Gonzalez, E. D. R. (2023). Prediction of Battery Remaining Useful Life Using Machine Learning Algorithms. Sustainability (Switzerland), 15 (21). Available : <https://doi.org/10.3390/su152115283>
- [13] S. Jafari., & Y. C. Byun (2023). Optimizing Battery RUL Prediction of Lithium-Ion Batteries Based on Harris Hawk Optimization Approach Using Random Forest and LightGBM. IEEE Access, 11(July), 87034–87046. Available : <https://doi.org/10.1109/ACCESS.2023.3304699>
- [14] P. Collet, & J.-P. Rennard, (2011). Stochastic Optimization Algorithms. Intelligent Information Technologies, March. Available : <https://doi.org/10.4018/9781599049410.ch064>
- [15] Song, X., Yang, F., Wang, D., & Tsui, K. L. (2019). Combined CNN-LSTM Network for State-of-Charge Estimation of Lithium-Ion Batteries. IEEE Access, 7, 88894–88902. <https://doi.org/10.1109/ACCESS.2019.2926517>
- [16] A. Slowik (2016). Particle Swarm Optimization. The Industrial Electronics Handbook - Five Volume Set, July. Available : https://doi.org/10.1007/978-3-319-46173-1_2
- [17] Ermshaus, Schäfer., & Leser. (2023). Window Size Selection in Unsupervised Time Series Analytics: A Review and Benchmark. Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 13812 LNAI, 83–101. Available : https://doi.org/10.1007/978-3-031-24378-3_6
- [18] S, Hasib. A., Islam, S., Chakraborty, R. K., Ryan, M. J., Saha, D. K., Ahamed, M. H., Moyeen, S. I., Das, S. K., Ali, M. F., Islam, M. R., Tasneem, Z., & Badal, F. R. (2021). A Comprehensive Review of Available Battery Datasets, RUL Prediction Approaches, and Advanced Battery Management. IEEE Access, 9 (June), 86166–86193. Available : <https://doi.org/10.1109/ACCESS.2021.3089032>
- [19] Kebonye, N. M. (2021). Exploring the novel support points-based split method on a soil dataset. Measurement: Journal of the International Measurement Confederation, 186(June), 110131. Available : <https://doi.org/10.1016/j.measurement.2021.110131>
- [20] Loussaief, S., & Abdelkrim, A. (2018). Convolutional Neural Network hyper-parameters optimization based on Genetic Algorithms. International Journal of Advanced Computer Science and Applications, 9(10), 252–266. Available : <https://doi.org/10.14569/IJACSA.2018.091031>
- [21] Chai, T., & Draxler, R. R. (2014). Root mean square error (RMSE) or mean absolute error (MAE) -Arguments against avoiding RMSE in the literature. Geoscientific Model Development, 7(3), 1247–1250. Available : <https://doi.org/10.5194/gmd-7-1247-2014>