



INNOVATIVE: Journal Of Social Science Research

Volume 3 Nomor 4 Tahun 2023 Page 10415-10425

E-ISSN 2807-4238 and P-ISSN 2807-4246

Website: <https://j-innovative.org/index.php/Innovative>

Prediksi Temperatur Pengosongan Baterai Lithium Menggunakan Metode Autoregressive Integrated Moving Average

Christio Revano Mege^{1✉}, Septia Eka Marsha Putra², Sefrani IG Siregar³

Teknik Fisika Institut Teknologi Sumatera

Email: christio.mege@tf.itera.ac.id^{1✉}

Abstrak

Baterai litium-ion merupakan kandidat terdepan dalam penggunaannya sebagai penyimpan energi untuk listrik yang dihasilkan energi alternatif. Salah satu keuntungan dari tipe penyimpanan energi ini adalah kerapatan energi yang tinggi. Namun kinerja setiap sel lithium ion dalam modul sangat bergantung pada temperatur operasi yaitu antara 0°C – 40°C . Kenaikan temperatur baterai melebihi batas tersebut dapat secara signifikan mengurangi kinerja baterai. Oleh sebab itu diperlukan prediksi temperatur untuk mengetahui kapan temperatur baterai bisa naik melewati batas 40°C . Dalam penelitian ini data temperatur yang diperoleh dari tahap pengambilan data digunakan sebagai data latih dan data uji untuk prediksi temperatur dengan metode Autoregressive Integrated Moving Average (ARIMA). Model kemudian dievaluasi dengan Root Mean Square Error (RMSE) dan Mean Absolute Deviation (MAD). Hasil menunjukkan model ARIMA dapat memprediksi kenaikan suhu baterai saat pengosongan pada kuat arus 10A, 20A, dan 30A. Model memiliki prediksi yang baik karena nilai RMSE dan MAD lebih kecil dari setengah standar deviasi data pengukuran.

Kata Kunci : ARIMA, Baterai Lithium, Kinerja Baterai, Prediksi Temperatur

Abstract

Lithium ion batteries are in the frontline as energy storage for electricity produced by alternative energy. One of the benefits from this kind of energy storage is the high energy density. However, performances of lithium cells in a module highly depend on operating temperature between 0°C – 40°C. Temperature increasing that exceeds the limit can significantly reduce battery performances. Therefore, temperature predictions are required in order to know when battery could exceed the 40°C limit. In this research temperature data acquired from data acquisition process is used as training data and test data to predict temperature using Autoregressive Integrated Moving Average (ARIMA). Then the models evaluated using Root Mean Square Error (RMSE) and Mean Absolute Deviation (MAD). The results show ARIMA models can predict the raising temperature of battery when discharged at current 10A, 20A, and 30A. The models have good predictions because RMSE and MAD values are smaller than half of the standard deviation of measurement data

Keyword: ARIMA, Battery Performances, Lithium Battery, Temperature Predictions

PENDAHULUAN

Berbagai penelitian mengenai energi terbarukan dan sistem penyimpanan energi telah dilakukan karena terbatasnya cadangan bahan bakar fosil dan karena permasalahan lingkungan seperti pemanasan global, yang disebabkan oleh sumber daya tersebut. Selama beberapa tahun terakhir, baterai lithium-ion telah banyak diimplementasikan dalam berbagai aplikasi seperti perangkat elektronik portabel, kendaraan listrik, kendaraan luar angkasa, dan sebagainya karena kepadatan energinya yang tinggi, self-discharge yang rendah, kinerja yang stabil, dan panjang siklus pemakaiannya (Diouf, 2015; Cao, 2023). Namun, baterai ini menghasilkan panas dalam jumlah besar selama pengoperasian, yang dapat memicu pelarian termal dan menyebabkan kecelakaan kebakaran jika panas tidak dikontrol dengan tepat (Feng, 2018).


Setelah material baterai berada pada kisaran suhu yang tidak normal, kinerja dan stabilitas baterai lithium-ion akan menurun dengan cepat (Saw, 2014). Suhu yang terlalu rendah akan meningkatkan resistansi internal dan resistansi internal polarisasi baterai lithium-ion, meningkatkan daya dan kehilangan energi, dan mengurangi kapasitas pengosongan baterai (Bandhauer, 2013); suhu yang terlalu tinggi akan meningkatkan laju degradasi baterai sehingga menurunkan kinerja dan siklus hidup (Wang, 2018). Kisaran suhu pengoperasian baterai yang optimal adalah dari 20°C hingga 40°C (Chao, 2019), dan perbedaan suhu harus dijaga 5°C (Esen, 2008). Oleh karena itu, sistem manajemen termal baterai yang sesuai dan efektif adalah kunci untuk mencegah baterai menjadi terlalu panas, menghindari pelarian termal, dan memastikan keamanan dan keandalan modul baterai (Murugan, 2022). Suhu permukaan rata-rata dan perbedaan suhu baterai sering digunakan

untuk merancang dan mengevaluasi sistem manajemen termal baterai. Ada banyak penyebab pelarian termal, tetapi prediksi suhu yang akurat dapat memantau masalah pelarian termal secara tepat waktu dan mengevaluasi sistem manajemen termal baterai (Wang, 2023).

Studi sebelumnya yang dilakukan pada baterai lithium-ion menggunakan pembelajaran mesin terutama berfokus pada estimasi state of charge (SOC), state of health (SOH) dan prediksi remaining useful life (RUL). Perkiraan SOC baterai dilakukan dengan menggunakan enam algoritma pembelajaran mesin: jaringan syaraf tiruan (ANN), mesin vektor dukungan (SVM), regresi proses Gaussian (GPR), regresi linier, ensemble bagging, dan ensemble boosting (Chandran, 2021). Hasilnya menunjukkan bahwa ANN dan GPR menampilkan kinerja terbaik. Selain itu model jaringan saraf konvolusional residu paralel hibrida untuk prediksi RUL online mencapai hasil yang andal dan akurat berdasarkan data dari kapasitas pengisian daya (Zhang, 2022). Metode prediksi SOH berdasarkan mesin vektor relevansi multi-kernel dan algoritma pengoptimalan Whale dan memverifikasi kinerjanya untuk prediksi jangka panjang dan jangka pendek menggunakan dua set data yang berbeda (Wang, 2021). Studi-studi tersebut yang dilakukan pada estimasi keadaan biasanya mempertimbangkan tegangan, suhu, resistansi internal, dan parameter lainnya sebagai input. Parameter ini secara signifikan dipengaruhi oleh kondisi operasi, yang memengaruhi keakuratan dan penerapan pembelajaran mesin (Mege, 2019) dalam estimasi online dan membutuhkan waktu komputasi yang lama. Oleh sebab itu penelitian ini mengusulkan prediksi temperatur baterai dengan analisis deret waktu yang lebih mudah untuk dilakukan.

METODE PENELITIAN

Baterai yang digunakan dalam penelitian ini adalah baterai lithium ferro phosphate (LiFePO_4) prismatic yang merupakan salah satu baterai lithium ion terbaru yang diperkenalkan. Baterai ini memiliki kapasitas spesifik sekitar 160 mAh/g dan tegangan rata-rata 3,45 V serta memiliki keunggulan karena tidak terlalu mahal dibandingkan dengan material lain dan ramah lingkungan. Pembangkitan kalor dalam sebuah sel baterai dapat dihubungkan kepada dua sumber utama yaitu: perubahan entropi akibat reaksi elektrokimia dan pemanasan ohm (efek Joule). Dalam penelitian ini diasumsikan kalor yang dihasilkan akibat reaksi elektrokimia dapat diabaikan, sehingga kalor hanya berasal dari pemanasan Ohm. Berdasarkan pasangan elektroda, kalor reaksi bisa endoterm untuk pengisian dan eksoterm untuk pengosongan. Pemanasan Ohm diakibatkan oleh transfer arus sepanjang resistansi internal.

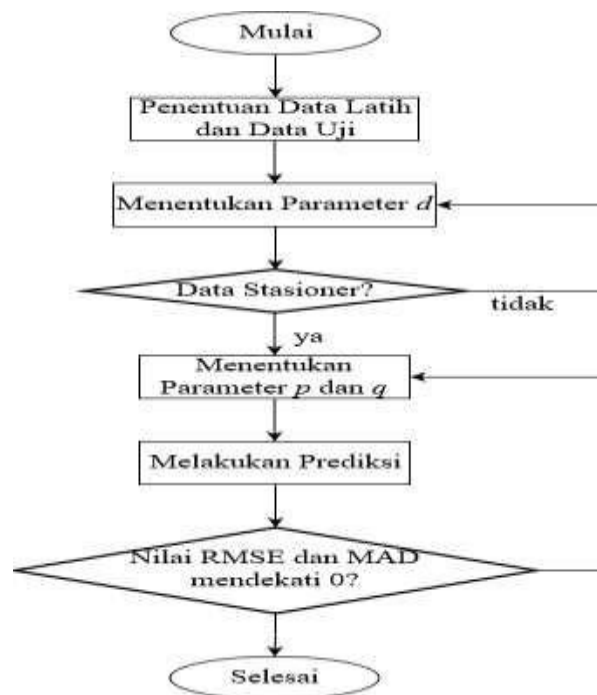


Gambar 1 Sistem pengosongan baterai

Sistem pengosongan baterai yang dibuat untuk pengambilan data terdiri dari pengatur beban BK Precision DC Programmable Load 8510, sensor temperature DHT11, perekam data Arduino Mega ATmega2560 dan baterai LiFePO4 seperti pada Gambar 1. Baterai dihubungkan ke pengatur beban untuk melakukan pengosongan serta merekam data tegangan dan kuat arus baterai tiap detik. Sensor temperature yang dihubungkan ke Arduino diletakkan di dekat elektroda baterai yang merupakan bagian paling panas dari baterai. Pengosongan dilakukan pada kuat arus 10A, 20A, dan 30A untuk tegangan yang konstan.

Model deret waktu yang tidak stasioner dapat dikatakan sebagai proses Autoregressive Integrated Moving Average ordo (p,d,q) atau disingkat ARIMA (p,d,q) , di mana p adalah ordo dari parameter autoregressive (AR), d adalah besaran yang menyatakan berapa kali dilakukan differencing sehingga proses menjadi stasioner dan q adalah ordo dari parameter moving average (MA).

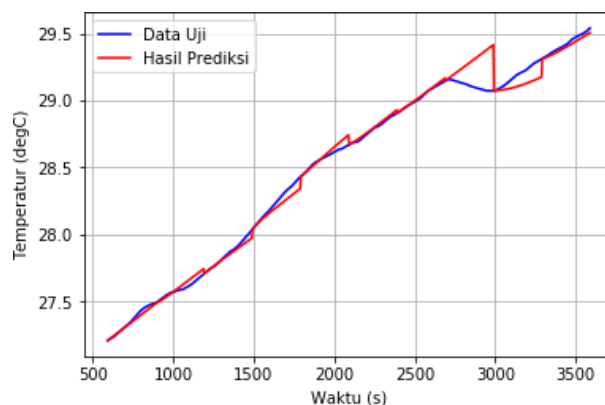
Gambar 2 menunjukkan algoritma prediksi temperatur menggunakan metode ARIMA yang akan dijalankan dengan program Python. Pada metode ARIMA, data latih harus merupakan data yang stasioner sehingga perlu differensiasi satu kali atau dengan kata lain orde d yang digunakan adalah 1. Jika data sudah stasioner, maka tahap selanjutnya adalah menentukan derajat autoregresi yaitu jumlah deret sebelumnya yang digunakan untuk memprediksi. Selain itu ditentukan juga derajat rata-rata berjalan yaitu jumlah kesalahan prediksi sebelumnya yang digunakan untuk memperbaiki hasil prediksi selanjutnya. Setelah itu prediksi dilakukan dan dievaluasi akurasi dengan root mean square error (RMSE) dan mean absolute deviation (MAD).



Gambar 2 Algoritma prediksi dengan metode ARIMA

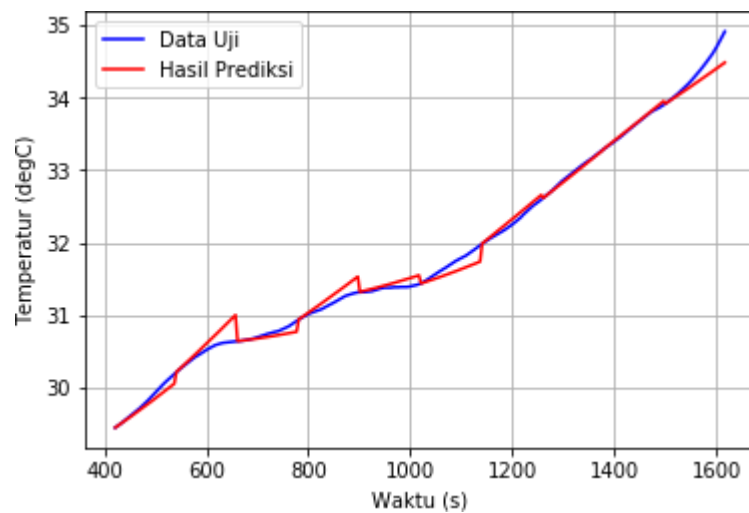
HASIL DAN PEMBAHASAN

Gambar 3 menunjukkan temperatur baterai meningkat dari $26,7^{\circ}\text{C}$ menjadi $29,7^{\circ}\text{C}$ dalam waktu 3592 detik pada pengosongan 10A. Prediksi temperatur pada kuat arus pengosongan 10A menggunakan data latih 5 menit untuk memprediksi 50 menit temperatur selanjutnya. Proses prediksi temperatur sel tunggal pada laju pengosongan ini dilakukan pada time step 300 detik atau dengan kata lain melalui hasil prediksi bisa diketahui perubahan temperatur saat operasi dalam rentang lima menit berikutnya. Parameter p, d, q yang paling optimal untuk memprediksi temperatur pada laju pengosongan ini adalah $p=2, d=1, q=1$. Gambar 3 menunjukkan model ARIMA bisa mengikuti perubahan temperatur yang terjadi. Hasil uji akurasi model menunjukkan nilai RMSE sebesar $0,07^{\circ}\text{C}$ dan MAD sebesar $0,04^{\circ}\text{C}$. Nilai RMSE dan MAD dari model yang lebih kecil dari setengah standar deviasi data pengukuran bisa dikategorikan baik.




Gambar 3 Prediksi temperatur dengan ARIMA pada 10A

Selanjutnya prediksi temperatur dengan metode ARIMA dilakukan untuk pengosongan 20A. Time step yang digunakan untuk laju pengosongan ini lebih kecil yaitu 120 detik atau 2 menit mengingat waktu pengosongannya yang lebih singkat dibandingkan dengan waktu pengosongan pada 10A. Pada laju pengosongan ini, ditemukan parameter p , d , q optimal dari metode ARIMA berturut-turut adalah 1, 1, 1. Gambar 4 menunjukkan perbandingan antara temperatur hasil prediksi metode ARIMA dengan temperatur pengukuran. Dapat dilihat bahwa hasil prediksi tetap membentuk pola yang cenderung naik meskipun ada beberapa titik temperatur cenderung konstan. Hasil uji akurasi pada laju pengosongan ini didapatkan nilai RMSE sebesar $0,10^{\circ}\text{C}$ dan MAD sebesar $0,07^{\circ}\text{C}$. Standar deviasi untuk laju pengosongan ini sebesar $1,87^{\circ}\text{C}$. Artinya model masih mempunyai akurasi yang baik karena nilainya masih kurang dari setengah standar deviasinya.



Gambar 4 Prediksi temperatur dengan ARIMA pada 20A

Pada pengosongan 30A baterai mencapai tegangan cut-off setelah 868 detik atau sekitar 15 menit. Sel tunggal mencapai tegangan cut-off dalam waktu yang lebih singkat karena kedalaman pengosongan yang dicapai hanya 52,00%. Prediksi yang dilakukan dengan metode ARIMA pada laju pengosongan ini menggunakan data dari detik ke-149 hingga detik ke-269 untuk memprediksi temperatur 10 menit selanjutnya dari detik ke-270 hingga detik ke-868. Time step pada laju pengosongan ini digunakan 60 detik karena waktu pengosongannya yang paling singkat.



Gambar 5 Prediksi temperatur dengan ARIMA pada 30A

Parameter p , d , q optimal ARIMA yang ditemukan melalui proses trial and error pada laju pengosongan ini berturut-turut adalah 0, 1, 1. Nilai parameter d tetap satu karena pada laju pengosongan 2,1C temperatur tetap memiliki kecenderungan untuk naik. Sedangkan untuk parameter p nilainya 0 karena data pada laju pengosongan ini memiliki kenaikan yang cukup tajam dibandingkan data pada laju pengosongan sebelumnya. Gambar 5 menunjukkan perbandingan temperatur hasil prediksi metode ARIMA dengan temperatur pengukuran. Hasil prediksi membentuk tren naik dan turun pada beberapa titik. Hal ini terjadi karena ARIMA tidak bisa digunakan pada data yang tidak stasioner sehingga ketika data mengalami perubahan yang tajam, maka sulit bagi metode ARIMA untuk mengikutinya dengan baik. Terbukti dengan menurunnya nilai akurasi yaitu RMSE sebesar $0,33^{\circ}\text{C}$ dan MAD sebesar $0,24^{\circ}\text{C}$ serta selisih temperatur terbesar $0,90^{\circ}\text{C}$. Nilai akurasi pada laju pengosongan ini menurun dibandingkan dengan laju pengosongan yang lain. Standar deviasi pada laju pengosongan ini yaitu sebesar $3,42^{\circ}\text{C}$ sehingga nilai RMSE dan MAD masih tergolong baik karena masih lebih kecil dari setengah standar deviasi. Ringkasan parameter optimal dan hasil evaluasi model dapat dilihat pada Tabel 1

Tabel 1 Parameter Optimal dan Evaluasi Model

Parameter	Laju pengosongan		
	0,7C	1,4C	2,1C
p	2	1	1
d	1	1	1
q	0	1	1
RMSE ($^{\circ}\text{C}$)	0,07	0,10	0,33
MAD ($^{\circ}\text{C}$)	0,04	0,07	0,24
Standar Deviasi ϵ_{\max} ($^{\circ}\text{C}$)	0,34	0,43	0,90

SIMPULAN

Model ARIMA dalam analisis deret waktu yang digunakan dalam penelitian ini bisa memprediksi perubahan temperatur baterai lithium prismatic saat dilakukan pengosongan dengan akurasi yang baik. Prediksi dengan model ARIMA dapat dilakukan dengan pemrograman yang lebih sederhana menggunakan Python sehingga lebih mudah untuk diaplikasikan pada sistem manajemen termal baterai. Penelitian selanjutnya dapat menggunakan model ARIMA dalam prediksi temperatur baterai yang dilengkapi sistem pendinginan. Model deret waktu yang lain juga dapat diuji untuk melakukan prediksi temperatur baterai lithium.

DAFTAR PUSTAKA

- Bandhauer, T. M., Garimella, S., & Fuller, T. F. (2014). Temperature-dependent electrochemical heat generation in a commercial lithium-ion battery. *Journal of Power Sources*, 247, 618–628. <https://doi.org/10.1016/j.jpowsour.2013.08.015>
- Cao, R., Zhang, X., & Yang, H. (2023). Prediction of the Heat Generation Rate of Lithium-Ion Batteries Based on Three Machine Learning Algorithms. *Batteries*, 9(3), 165. <https://doi.org/10.3390/batteries9030165>
- Cao, W., Zhao, C., Wang, Y., Dong, T., & Jiang, F. (2019). Thermal modeling of full-size-scale cylindrical battery pack cooled by channeled liquid flow. *International Journal of Heat and Mass Transfer*, 138, 1178–1187. <https://doi.org/10.1016/j.ijheatmasstransfer.2019.04.137>
- Chandran, V., Patil, C. K., Karthick, A., Ganeshaperumal, D., Rahim, R., & Ghosh, A. (2021). State of charge estimation of lithium-ion battery for electric vehicles using machine learning algorithms. *World Electric Vehicle Journal*, 12(1). <https://doi.org/10.3390/wevj12010038>
- Diouf, B., & Pode, R. (2015). Potential of lithium-ion batteries in renewable energy. In *Renewable Energy* (Vol. 76, pp. 375–380). Elsevier Ltd. <https://doi.org/10.1016/j.renene.2014.11.058>
- Esen, H., Inalli, M., Sengur, A., & Esen, M. (2008). Forecasting of a ground-coupled heat pump performance using neural networks with statistical data weighting pre-processing. *International Journal of Thermal Sciences*, 47(4), 431–441. <https://doi.org/10.1016/j.ijthermalsci.2007.03.004>
- Feng, X., Ouyang, M., Liu, X., Lu, L., Xia, Y., & He, X. (2018). Thermal runaway mechanism of lithium ion battery for electric vehicles: A review. In *Energy Storage Materials* (Vol. 10, pp. 246–267). Elsevier B.V. <https://doi.org/10.1016/j.ensm.2017.05.013>

- Kleiner, J., Stuckenberger, M., Komsijska, L., & Endisch, C. (2021). Real-time core temperature prediction of prismatic automotive lithium-ion battery cells based on artificial neural networks. *Journal of Energy Storage*, 39, 102588. <https://doi.org/10.1016/j.est.2021.102588>
- Mege, C. R., Nashirul Haq, I., Leksono, E., & Nugroho Soelami, F. X. (2019). Battery Discharging Temperature Prediction Using Holt's Double Exponential Smoothing. 2019 6th International Conference on Electric Vehicular Technology (ICEVT), 378–381. <https://doi.org/10.1109/ICEVT48285.2019.8993965>
- Murugan, M., Saravanan, A., Elumalai, P. V., Murali, G., Dhineshababu, N. R., Kumar, P., & Afzal, A. (2022). Thermal management system of lithium-ion battery packs for electric vehicles: An insight based on bibliometric study. *Journal of Energy Storage*, 52, 104723. <https://doi.org/10.1016/j.est.2022.104723>
- Saw, L. H., Ye, Y., & Tay, A. A. O. (2014). Electro-thermal characterization of Lithium Iron Phosphate cell with equivalent circuit modeling. *Energy Conversion and Management*, 87, 367–377. <https://doi.org/10.1016/j.enconman.2014.07.011>
- Wan, Z., Kang, Y., Ou, R., Xue, S., Xu, D., & Luo, X. (2023). Multi-step time series forecasting on the temperature of lithium-ion batteries. *Journal of Energy Storage*, 64, 107092. <https://doi.org/10.1016/j.est.2023.107092>
- Wang, H., He, F., & Ma, L. (2016). Experimental and modeling study of controller-based thermal management of battery modules under dynamic loads. *International Journal of Heat and Mass Transfer*, 103, 154–164. <https://doi.org/10.1016/j.ijheatmasstransfer.2016.07.041>
- Wang, S., Zhang, X., Chen, W., Han, W., Zhou, S., & Pecht, M. (2021). State of health prediction based on multi-kernel relevance vector machine and whale optimization algorithm for lithium-ion battery. *Transactions of the Institute of Measurement and Control*, 014233122110420. <https://doi.org/10.1177/01423312211042009>
- Wang, Y., Chen, X., Li, C., Yu, Y., Zhou, G., Wang, C., & Zhao, W. (2023). Temperature prediction of lithium-ion battery based on artificial neural network model. *Applied Thermal Engineering*, 228, 120482. <https://doi.org/10.1016/j.applthermaleng.2023.120482>
- Wang, Y., Xiong, C., Wang, Y., Xu, P., Ju, C., Shi, J., Yang, G., & Chu, J. (2023). Temperature state prediction for lithium-ion batteries based on improved physics informed neural networks. *Journal of Energy Storage*, 73, 108863. <https://doi.org/10.1016/j.est.2023.108863>
- Zhang, Q., Yang, L., Guo, W., Qiang, J., Peng, C., Li, Q., & Deng, Z. (2022). A deep learning

method for lithium-ion battery remaining useful life prediction based on sparse segment data via cloud computing system. Energy, 241, 122716.
<https://doi.org/10.1016/j.energy.2021.122716>