

Prediksi Degradasi Kesehatan Baterai Kendaraan Listrik Berbasis Machine Learning pada Pengisian Cepat DC

Zulham Kentjie¹, Samsurizal², Septianissa Azahra³, Dwi Listiawati⁴, Dody⁵, Kartika Tresya Mauriraya⁶

^{1,4}Teknik Sistem Energi, Institut Teknologi PLN

^{2,3}Teknik Elektro, Institut Teknologi PLN

⁵Teknik Sistem Informasi, Institut Teknologi PLN

⁶Teknologi Listrik, Institut Teknologi PLN

E-mail: ¹m.zulham@itpln.ac.id, ²samsurizal@itpln.ac.id

³septianissa@itpln.ac.id, ⁴dwilistiawati@itpln.ac.id, ⁵dody@itpln.ac.id, ⁶kartika@itpln.ac.id

Abstrak – Perkembangan kendaraan listrik mendorong penerapan sistem pengisian cepat untuk meningkatkan kenyamanan pengguna. Namun, pengisian cepat dengan arus dan daya tinggi berpotensi mempercepat degradasi kesehatan baterai (*State of Health / SoH*), yang berdampak pada umur pakai dan keandalan baterai kendaraan listrik. Oleh karena itu, diperlukan pendekatan prediktif yang mampu mengidentifikasi degradasi kesehatan baterai secara akurat sejak dini. Penelitian ini mengusulkan pendekatan *machine learning* berbasis *Random Forest Regressor* untuk memprediksi degradasi kesehatan baterai kendaraan listrik pada proses pengisian cepat DC. Dataset diperoleh dari hasil simulasi pengisian cepat yang mempertimbangkan parameter arus pengisian, tegangan DC, suhu baterai, dan *State of Charge (SoC)*. Model dilatih untuk mempelajari hubungan nonlinier antara parameter pengisian cepat dan degradasi kesehatan baterai yang dinyatakan sebagai ΔSoH . Kinerja model dievaluasi menggunakan metrik *Mean Absolute Error (MAE)*, *Root Mean Square Error (RMSE)*, dan koefisien determinasi (R^2). Hasil penelitian menunjukkan bahwa model *Random Forest* mampu memprediksi degradasi kesehatan baterai dengan nilai MAE sebesar 0.00000009, RMSE sebesar 0.00000015, serta nilai R^2 sebesar 0.999998, yang menunjukkan tingkat akurasi prediksi yang sangat tinggi. Pendekatan ini berpotensi digunakan sebagai dasar pengambilan keputusan dalam pengelolaan sistem pengisian cepat DC yang lebih aman dan berkelanjutan, serta mendukung pengembangan sistem pengisian kendaraan listrik yang cerdas dan berorientasi pada umur pakai baterai.

Kata Kunci — *Machine Learning, Prediksi Degradasi, Fast Charging DC*

1. PENDAHULUAN

Perkembangan kendaraan listrik (*Electric Vehicles/EV*) yang pesat mendorong kebutuhan akan sistem pengisian daya yang cepat dan efisien[1], [2]. Salah satu solusi yang banyak diterapkan adalah pengisian cepat arus searah (DC *fast charging*), yang mampu secara signifikan mengurangi waktu pengisian baterai. Namun, peningkatan arus dan daya pengisian pada sistem ini berpotensi menimbulkan kenaikan suhu baterai yang tinggi, sehingga dapat mempercepat degradasi kesehatan baterai (*State of Health/SoH*) dan menurunkan umur pakai baterai[3], [4]. Kesehatan baterai merupakan parameter penting yang merepresentasikan kondisi internal baterai dan kemampuannya dalam menyimpan energi dibandingkan dengan kondisi awal. Penurunan SoH yang tidak terkontrol dapat berdampak pada penurunan performa kendaraan listrik, meningkatnya risiko kegagalan sistem, serta tingginya biaya penggantian baterai. Oleh karena itu, diperlukan pendekatan yang mampu memprediksi degradasi kesehatan baterai secara akurat sejak dini, khususnya pada kondisi pengisian cepat DC[5], [6].


Pendekatan konvensional dalam analisis degradasi baterai umumnya berbasis model fisika atau empiris yang membutuhkan parameter kompleks dan sulit diimplementasikan secara *real-time*[7], [8]. Sebagai alternatif, *machine learning* menawarkan kemampuan untuk mempelajari hubungan nonlinier antara parameter pengisian dan degradasi baterai berdasarkan data, sehingga lebih adaptif dan efisien. Sejumlah penelitian sebelumnya telah membahas permasalahan degradasi kesehatan baterai kendaraan listrik akibat pengisian cepat. Penelitian pertama mengkaji dampak arus pengisian tinggi terhadap peningkatan suhu baterai dan menunjukkan bahwa kenaikan temperatur yang berlebih dapat mempercepat penurunan *State of Health (SoH)*. Penelitian lain mengembangkan model degradasi baterai berbasis pendekatan fisika dan empiris untuk memperkirakan umur pakai baterai selama proses pengisian cepat DC, namun model tersebut memerlukan parameter internal baterai yang kompleks dan sulit diperoleh secara *real-time*. Studi selanjutnya menganalisis hubungan antara *State of Charge (SoC)*, arus pengisian, dan degradasi kapasitas baterai, serta menegaskan bahwa kombinasi SoC tinggi dan arus besar berkontribusi signifikan terhadap degradasi baterai.

Selain pendekatan berbasis model fisika, beberapa penelitian terbaru mulai menerapkan *machine learning* untuk memprediksi kondisi baterai kendaraan listrik[9], [10]. Sebuah penelitian menggunakan algoritma regresi dan neural network untuk memperkirakan SoH baterai berdasarkan data operasional, namun akurasi masih terbatas pada kondisi pengisian tertentu. Penelitian lain menerapkan metode *ensemble learning* untuk meningkatkan akurasi prediksi degradasi baterai dan menunjukkan hasil yang lebih stabil dibandingkan metode tunggal. Meskipun demikian, sebagian besar penelitian tersebut masih berfokus pada estimasi SoH secara langsung dan belum secara eksplisit memodelkan degradasi kesehatan baterai (Δ SoH) pada skenario pengisian cepat DC[11], [12]. Oleh karena itu, penelitian ini mengisi celah tersebut dengan mengusulkan pendekatan *machine learning* berbasis *Random Forest* untuk memprediksi degradasi kesehatan baterai kendaraan listrik secara akurat pada kondisi pengisian cepat DC.

Berdasarkan permasalahan tersebut, penelitian ini mengusulkan pendekatan *machine learning* berbasis *Random Forest Regressor* untuk memprediksi degradasi kesehatan baterai kendaraan listrik pada pengisian cepat DC[13], [14]. Model dikembangkan menggunakan data simulasi yang mencakup parameter arus pengisian, tegangan DC, suhu baterai, dan *State of Charge* (SoC), dengan keluaran berupa nilai degradasi SoH (Δ SoH). Diharapkan hasil penelitian ini dapat mendukung pengembangan sistem pengisian cepat yang lebih aman, cerdas, dan berkelanjutan.

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif berbasis simulasi dan *machine learning* untuk memprediksi degradasi kesehatan baterai kendaraan listrik pada pengisian cepat DC. Tahapan penelitian secara umum ditunjukkan pada Gambar 1.



Gambar 1. Diagram Alir Penelitian

Diagram alir metode penelitian menggambarkan tahapan penerapan machine learning dalam memprediksi degradasi kesehatan baterai kendaraan listrik. Proses diawali dengan pengumpulan data hasil simulasi pengisian cepat yang mencakup parameter arus, tegangan, suhu, dan *State of Charge* (SoC). Data kemudian melalui tahap pra-pemrosesan untuk memastikan kualitas dan keseragaman data sebelum digunakan dalam pemodelan. Selanjutnya, model machine learning dilatih menggunakan data pelatihan untuk mempelajari hubungan antara parameter pengisian dan *State of Health* (SoH) baterai. Model yang telah dilatih kemudian diuji menggunakan data uji, dan kinerjanya dievaluasi berdasarkan metrik kesalahan prediksi. Hasil prediksi dianalisis untuk menilai kemampuan model dalam mengidentifikasi degradasi kesehatan baterai selama proses pengisian cepat.

2.1 Model Matematis

Daya pengisian baterai pada sistem pengisian cepat DC dihitung menggunakan persamaan:

$$P = \frac{V \times I}{1000} \quad \dots \dots \dots (1)$$

dengan P adalah daya pengisian (kW), V adalah tegangan pengisian DC (V), I adalah arus pengisian (A).

Perubahan *State of Charge* (SoC) baterai dihitung berdasarkan energi yang tersimpan selama proses pengisian, sedangkan degradasi kesehatan baterai dimodelkan secara sederhana sebagai fungsi dari throughput energi:

$$\Delta SoH = SoH_0 - SoH(t) \quad \dots \dots \dots (2)$$

dengan SoH_0 adalah kondisi kesehatan baterai awal dan $SoH(t)$ adalah kondisi kesehatan baterai pada waktu tertentu. Nilai ΔSoH selanjutnya digunakan sebagai target prediksi pada model machine learning.

2.2 Pemodelan Machine Learning

Dataset dibentuk dari hasil simulasi pengisian cepat DC dengan variabel masukan berupa arus pengisian, tegangan DC, suhu baterai, dan SoC. Data kemudian dibagi menjadi data pelatihan dan data pengujian dengan proporsi 80:20. Model Random Forest Regressor dilatih untuk mempelajari hubungan antara variabel masukan dan degradasi kesehatan baterai. Kinerja model dievaluasi menggunakan metrik Mean Absolute Error (MAE), Root Mean Square Error (RMSE), dan koefisien determinasi (R^2).

3. HASIL DAN PEMBAHASAN

Parameter simulasi yang digunakan dalam penelitian ini ditunjukkan pada Tabel 1. Parameter tersebut mencakup karakteristik baterai, pengisian cepat DC, kondisi termal, serta parameter degradasi kesehatan baterai.

Tabel 1. Parameter

Kelompok	Parameter	Nilai	Satuan
Baterai	Kapasitas	71.4	kWh
Pengisian	Tegangan DC	20	kV
Pengisian	Arus maksimum	10	A
Waktu	Durasi maksimum	180	menit
Termal	Suhu lingkungan	35	°C
Termal	Suhu maksimum	45	°C
Termal	Konstanta termal	0.02	°C/kW
Termal	Laju pendinginan	0.10	1/menit
Degradasi	SoH awal	1.0	–
Degradasi	Faktor degradasi	5×10^{-6}	–


3.1. Hasil Prediksi Degradasi Kesehatan Baterai

Penelitian ini bertujuan untuk memprediksi degradasi kesehatan baterai kendaraan listrik (ΔSoH) pada kondisi pengisian cepat DC menggunakan pendekatan *machine learning* berbasis *Random Forest Regressor*. Model menggunakan dataset hasil simulasi pengisian cepat yang mencakup parameter arus pengisian, tegangan

DC, suhu baterai, dan *State of Charge* (SoC) sebagai variabel masukan, dengan degradasi *State of Health* (ΔSoH) sebagai variabel keluaran.

Untuk memperoleh hasil prediksi degradasi kesehatan baterai, terlebih dahulu dilakukan proses simulasi pengisian cepat DC untuk menghasilkan dataset yang merepresentasikan perilaku baterai kendaraan listrik. Simulasi ini mempertimbangkan parameter utama pengisian cepat, yaitu arus pengisian, tegangan DC, suhu baterai, dan *State of Charge* (SoC). Selama proses pengisian, perubahan suhu dan energi yang masuk ke baterai digunakan untuk memodelkan penurunan *State of Health* (SoH) secara bertahap, sehingga diperoleh nilai degradasi kesehatan baterai yang dinyatakan sebagai ΔSoH .

Dataset hasil simulasi kemudian digunakan untuk membangun *model machine learning berbasis Random Forest Regressor*. Variabel masukan model terdiri dari arus pengisian, tegangan DC, suhu baterai, dan SoC, sedangkan variabel keluarannya adalah degradasi kesehatan baterai (ΔSoH). Data dibagi menjadi data pelatihan dan data pengujian, di mana model dilatih untuk mempelajari hubungan nonlinier antara parameter pengisian cepat DC dan degradasi kesehatan baterai. Setelah proses pelatihan selesai, model digunakan untuk memprediksi nilai ΔSoH pada data pengujian, yang selanjutnya dibandingkan dengan nilai degradasi aktual hasil simulasi.



Gambar 2. Hasil prediksi degradasi kesehan baterai


Gambar 2 menunjukkan perbandingan antara nilai degradasi kesehatan baterai aktual (ΔSoH aktual) dan hasil prediksi model *machine learning* (ΔSoH prediksi) pada data pengujian. Sumbu horizontal merepresentasikan indeks sampel yang telah diurutkan berdasarkan nilai degradasi, sedangkan sumbu vertikal menunjukkan besarnya degradasi kesehatan baterai (ΔSoH). Pengurutan indeks sampel dilakukan untuk memperjelas tren peningkatan degradasi seiring bertambahnya energi pengisian. Berdasarkan grafik tersebut, terlihat bahwa kurva ΔSoH prediksi hampir sepenuhnya berimpit dengan kurva ΔSoH aktual di seluruh rentang sampel. Hal ini menunjukkan bahwa model Random Forest mampu mengikuti pola degradasi kesehatan baterai dengan sangat baik. Selisih antara nilai aktual dan nilai prediksi relatif kecil dan tidak menunjukkan penyimpangan yang signifikan, baik pada nilai degradasi rendah maupun tinggi. Dengan kata lain, model memiliki kemampuan generalisasi yang baik dalam memprediksi degradasi kesehatan baterai pada berbagai kondisi pengisian cepat DC.

Kesesuaian yang tinggi antara nilai aktual dan prediksi ini sejalan dengan hasil evaluasi kuantitatif yang ditunjukkan oleh nilai MAE dan RMSE yang sangat kecil serta koefisien determinasi (R^2) yang mendekati satu. Hasil tersebut menegaskan bahwa pendekatan machine learning berbasis Random Forest efektif digunakan untuk memprediksi degradasi kesehatan baterai kendaraan listrik pada pengisian cepat DC, sehingga berpotensi menjadi dasar dalam pengembangan sistem pemantauan dan pengelolaan pengisian baterai yang lebih aman dan berkelanjutan. Model Random Forest Regressor digunakan untuk memprediksi degradasi kesehatan baterai kendaraan listrik (ΔSoH) berdasarkan parameter pengisian cepat DC. Hasil evaluasi kinerja model ditunjukkan pada Tabel 2.

Tabel 2. Evaluasi kinerja model	
MAE	0.00000009
RMSE	0.00000015
R ²	0.999998

Selain evaluasi akurasi, analisis feature importance pada model Random Forest menunjukkan bahwa parameter suhu baterai dan arus pengisian memiliki kontribusi terbesar terhadap degradasi kesehatan baterai. Hal ini mengindikasikan bahwa peningkatan suhu akibat arus pengisian tinggi merupakan faktor dominan dalam mempercepat degradasi SoH. Sementara itu, State of Charge (SoC) berperan sebagai indikator kondisi pengisian yang memengaruhi laju degradasi seiring bertambahnya energi tersimpan di dalam baterai. Temuan ini sejalan dengan karakteristik fisik baterai lithium-ion yang sensitif terhadap stres termal dan arus tinggi selama pengisian cepat.

Hasil evaluasi kinerja model ditunjukkan pada Tabel 2, yang merangkum nilai *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan koefisien determinasi (R^2). Nilai MAE dan RMSE yang relatif kecil menunjukkan bahwa model mampu memprediksi degradasi kesehatan baterai dengan tingkat kesalahan yang rendah. Selain itu, nilai R^2 yang mendekati satu mengindikasikan bahwa sebagian besar variasi degradasi SoH dapat dijelaskan dengan baik oleh model Random Forest. Untuk memperkuat hasil analisis tren degradasi kesehatan baterai yang telah dibahas sebelumnya, dilakukan evaluasi lanjutan terhadap kesesuaian antara nilai degradasi aktual dan hasil prediksi model machine learning. Evaluasi ini divisualisasikan dalam bentuk grafik sebar (scatter plot) antara degradasi aktual dan degradasi prediksi, sebagaimana ditunjukkan pada Gambar 3.



Gambar 3. Perbandingan Degradasi Kesehatan Baterai Aktual dan Prediksi Menggunakan Random Forest

Gambar 3 menunjukkan hubungan antara degradasi kesehatan baterai aktual (ΔSoH aktual) dan hasil prediksi model Random Forest (ΔSoH prediksi). Sumbu horizontal merepresentasikan nilai degradasi aktual, sedangkan sumbu vertikal menunjukkan nilai degradasi hasil prediksi. Garis putus-putus diagonal merepresentasikan kondisi ideal di mana nilai prediksi sama dengan nilai aktual ($y = x$). Berdasarkan grafik tersebut, terlihat bahwa hampir seluruh titik data berada sangat dekat dengan garis referensi $y = x$. Hal ini menunjukkan tingkat kesesuaian yang sangat tinggi antara nilai degradasi aktual dan nilai degradasi hasil prediksi. Penyebaran titik yang minimal di sekitar garis diagonal mengindikasikan bahwa kesalahan prediksi relatif kecil dan tidak menunjukkan adanya bias sistematis, baik pada nilai degradasi rendah maupun tinggi.

Hasil ini menegaskan bahwa model Random Forest tidak hanya mampu mengikuti tren degradasi kesehatan baterai, tetapi juga memiliki tingkat akurasi prediksi yang sangat baik. Temuan ini selaras dengan hasil evaluasi

kuantitatif yang ditunjukkan oleh nilai MAE dan RMSE yang rendah serta koefisien determinasi (R^2) yang mendekati satu, sehingga memperkuat validitas model dalam memprediksi degradasi kesehatan baterai kendaraan listrik pada pengisian cepat DC.

4. SIMPULAN

Penelitian ini mengusulkan pendekatan machine learning berbasis Random Forest Regressor untuk memprediksi degradasi kesehatan baterai kendaraan listrik pada pengisian cepat DC. Berdasarkan hasil simulasi dan pengujian model, diperoleh tingkat akurasi yang sangat tinggi dengan nilai MAE dan RMSE yang rendah serta koefisien determinasi (R^2) yang mendekati satu. Hasil ini menunjukkan bahwa model mampu memprediksi degradasi kesehatan baterai secara akurat berdasarkan parameter arus pengisian, tegangan DC, suhu baterai, dan *State of Charge* (SoC). Pendekatan yang diusulkan berpotensi digunakan sebagai sistem pendukung dalam pemantauan kesehatan baterai serta pengelolaan pengisian cepat yang lebih aman dan berkelanjutan.

5. SARAN

Penelitian selanjutnya disarankan untuk menggunakan data pengisian baterai hasil eksperimen atau data operasional kendaraan listrik secara real-time guna meningkatkan validitas model. Selain itu, pengembangan dapat dilakukan dengan membandingkan beberapa algoritma machine learning lainnya atau mengintegrasikan model prediksi degradasi ini ke dalam sistem manajemen baterai kendaraan listrik secara langsung.

6. UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada tim C-GREEN Riset Center, yang telah berusaha menyelesaikan penelitian ini dari awal hingga selesai paper ini. Institut Teknologi PLN dan LPPM ITPLN, yang memfasilitas kegiatan penelitian ini sehingga penelitian ini menghasilkan paper serta dapat di tulis dan dipublikasi. Semoga tulisan ini bermanfaat dan menjadi bahan referensi dan pengembangan penelitian selanjutnya.

DAFTAR PUSTAKA

- [1] K. T. Chau, C. C. Chan, S. Niu, W. Liu, and T. Liu, "Graduate Degree in Electric Vehicles—A Timely Programme for Modern Society," *World Electric Vehicle Journal*, vol. 16, no. 1, p. 31, Jan. 2025, doi: 10.3390/wevj16010031.
- [2] F. Alanazi, "Electric Vehicles: Benefits, Challenges, and Potential Solutions for Widespread Adaptation," *Applied Sciences*, vol. 13, no. 10, p. 6016, May 2023, doi: 10.3390/app13106016.
- [3] R. R. Kumar, C. Bharatiraja, K. Udhayakumar, S. Devakirubakaran, K. S. Sekar, and L. Mihet-Popa, "Advances in Batteries, Battery Modeling, Battery Management System, Battery Thermal Management, SOC, SOH, and Charge/Discharge Characteristics in EV Applications," *IEEE Access*, vol. 11, pp. 105761–105809, 2023, doi: 10.1109/ACCESS.2023.3318121.
- [4] P. Dini, A. Colicelli, and S. Saponara, "Review on Modeling and SOC/SOH Estimation of Batteries for Automotive Applications," *Batteries*, vol. 10, no. 1, p. 34, Jan. 2024, doi: 10.3390/batteries10010034.
- [5] B. Babu, P. Simon, A. Balducci, B. Babu, A. Balducci, and P. Simon, "Fast Charging Materials for High Power Applications," 2020, doi: 10.1002/aenm.202001128.
- [6] "A Quick Guide to Fast Charging 1."
- [7] A. Tomaszewska *et al.*, "Lithium-ion battery fast charging: A review," *eTransportation*, vol. 1, p. 100011, Aug. 2019, doi: 10.1016/j.etrans.2019.100011.
- [8] C. Miller, M. Goutham, X. Chen, and S. Stockar, "DC Fast Charging Optimization for Capacity Fade Minimization," 2022.
- [9] S. Samsurizal, A. N. Afandi, and M. R. Faiz, "A Comparative Analysis of Fast Charging Performance and Battery Life Against Charging Current Variations," *ITEGAM- Journal of Engineering and Technology for Industrial Applications (ITEGAM-JETIA)*, vol. 11, no. 52, pp. 81–86, 2025, doi: 10.5935/jetia.v11i52.1536.
- [10] A. N. Afandi and Y. Sulistyorini, "Transformation of Thunderstorm Mechanisms into Computational Intelligence Applied to the Load Dispatch," in *2019 International Conference on Information and Communications Technology (ICOIACT)*, IEEE, Jul. 2019, pp. 773–778. doi: 10.1109/ICOIACT46704.2019.8938531.
- [11] J. G. Qu, Z. Y. Jiang, and J. F. Zhang, "Investigation on lithium-ion battery degradation induced by combined effect of current rate and operating temperature during fast charging," *J Energy Storage*, vol. 52, p. 104811, Aug. 2022, doi: 10.1016/J.EST.2022.104811.

- [12] P. Makeen, H. A. Ghali, and S. Memon, “A Review of Various Fast Charging Power and Thermal Protocols for Electric Vehicles Represented by Lithium-Ion Battery Systems,” Mar. 01, 2022, *Multidisciplinary Digital Publishing Institute (MDPI)*. doi: 10.3390/futuretransp2010015.
- [13] H. Rathore, H. K. Meena, and P. Jain, “Prediction of EV Energy consumption Using Random Forest And XGBoost,” in *2023 International Conference on Power Electronics and Energy (ICPEE)*, IEEE, Jan. 2023, pp. 1–6. doi: 10.1109/ICPEE54198.2023.10060798.
- [14] H. A. Salman, A. Kalakech, and A. Steiti, “Random Forest Algorithm Overview,” *Babylonian Journal of Machine Learning*, vol. 2024, pp. 69–79, Jun. 2024, doi: 10.58496/BJML/2024/007.