

ANALISIS DAMPAK EFEK MEMORI PADA ESTIMASI KONDISI MUATAN LiFePO4 MENGGUNAKAN PHYSICS INFORMED MACHINE LEARNING

Oleh: Han Sen 13321033 | Dosen Pembimbing 1: Prof. Ir. Edi Leksono, M.Eng., Ph.D | Dosen Pembimbing 2: Dr. Ing. Thomas Budiarto, S.T., M.T




Program Studi Teknik Fisika
Fakultas Teknologi Industri
Institut Teknologi Bandung



LATAR BELAKANG

Seiring meningkatnya penggunaan baterai di **sektor kendaraan listrik** maupun **penyimpanan energi terbarukan**, risiko **overcharge** dan **overdischarge** semakin sering dijumpai. Hal ini menegaskan pentingnya penerapan **Sistem Manajemen Baterai (SMB)** yang dapat mengestimasi kondisi muatan secara andal.



Saat ini masih ada **research gap** mengenai **efek memori** di mana efek memori jarang direpresentasikan sebagai **informasi fisika** dalam pemodelan estimasi kondisi muatan baterai.

TUJUAN

- Menyelidiki **pengaruh efek memori** yang direpresentasikan dalam **fitur akumulasi energi** terhadap kinerja estimasi KM dari model.
- Menganalisis dan membandingkan beberapa algoritma **physics informed machine learning** dalam proses estimasi KM.

KONDISI MUATAN

Kondisi Muatan (KM) merepresentasikan **jumlah energi yang tersisa** di dalam baterai dibandingkan dengan **kapasitas totalnya**. Salah satu metode yang banyak digunakan adalah Coulomb Counting.

$$SOC_{(t+\Delta t)} = SOC_{(t)} \pm \frac{\eta \cdot I(t) \cdot \Delta t}{Q_n}$$

EFEK MEMORI

Efek memori merujuk pada sifat baterai yang **mengingat pola** pemakaian tertentu sehingga **kapasitasnya tampak menurun**. Efek memori pada penelitian ini direpresentasikan oleh **energi akumulasi**.



PHYSICS INFORMED MACHINE LEARNING

adalah pendekatan yang mengintegrasikan **pengetahuan fisika** ke dalam **kerangka pembelajaran mesin** sebagai pengetahuan awal (prior knowledge).



Informasi Fisika = Energi Akumulasi

Energi akumulasi adalah total energi listrik yang telah **disimpan/dilepaskan** oleh baterai dalam kurun waktu tertentu.

$$E_{akumulasi\ pengisian} \approx \sum_{k=1}^n V(k) \cdot I_{pengisian}(k) \cdot \Delta t$$


$$E_{akumulasi\ pengosongan} \approx \sum_{k=1}^n V(k) \cdot I_{pengosongan}(k) \cdot \Delta t$$

PERSIAPAN DATA

Pengujian baterai dilakukan **dengan variasi arus** 180 mA, 210 mA, 240 mA, 360 mA, dan 600 mA. Kemudian seluruh variasi arus tersebut **dipisahkan** ke **data pengujian** dan **data validasi** dengan spesifikasi sebagai berikut.


Data pelatihan : 180 mA, 210 mA, 240 mA, dan 360 mA
Data pengujian : 180 mA dan 600 mA

Profil tegangan dan arus data pelatihan model ditampilkan sebagai berikut.



PEMODELAN

Alur pemodelan dilakukan sesuai dengan diagram alir untuk **pemodelan berbasis informasi fisika**. Untuk alur **pemodelan berbasis data (non-informasi fisika)**, diagram alir cenderung serupa namun tidak ditambahkan informasi fisika di pemilihan fitur.



Fitur masukan pelatihan model untuk:

- Model berbasis data = tegangan dan arus.**
- Model berbasis informasi fisika = tegangan, arus, dan energi akumulasi.**

90% data latih dan 10% data uji

Jumlah pohon (number of estimators) algoritma random forest dan XGBoost adalah 100

Kemudian diperoleh hasil sebagai berikut.

Parameter	Random forest model berbasis data	Random forest model berbasis informasi fisika	Perubahan akurasi random forest	XGBoost model berbasis data	XGBoost model berbasis informasi fisika	Perubahan akurasi XGBoost
R2	0.996	0.999	0.4%	0.996	0.999	0.4%
RMSE	0.02	0.0004	98%	0.02	0.0043	77.1%
Waktu pelatihan (s)	33.41	72.54	-117.1%	1.23	2.4	-95.8%
Waktu pengujian (s)	0.82	6.22	-656.8%	0.04	0.08	-70.5%

Indikator performa menunjukkan bahwa R2 model cenderung **meningkat** dan RMSE **menurun**. Hasil ini menunjukkan bahwa penambahan informasi fisika yang merepresentasikan efek memori dalam bentuk energi akumulasi **mampu memberikan kontribusi nyata** terhadap peningkatan performa model.

PENGUJIAN KASUS KHUSUS

Pengujian dilakukan dengan **mengeksport model** dan dinilai indikator performanya ke **dataset yang berbeda** untuk menguji apakah model mampu **menggeneralisasi** set data di luar set data latih.

Arus	Parameter	Random forest model berbasis data	Random forest model berbasis informasi fisika	XGBoost model berbasis data	XGBoost model berbasis informasi fisika
180 mA	R2	0.83	0.90	0.86	0.84
	RMSE	0.12	0.09	0.11	0.12
600 mA	R2	0.86	0.80	0.74	0.81
	RMSE	0.10	0.13	0.14	0.12

KESIMPULAN

- Model berbasis informasi fisika secara signifikan **meningkatkan performa** dibanding model berbasis data, ditunjukkan oleh **penurunan RMSE** pada random forest (0,018 → 0,0004) dan XGBoost (0,019 → 0,004).
- Random forest lebih efektif pada **arus rendah**, sedangkan XGBoost unggul pada **arus tinggi**. Integrasi informasi fisika seperti efek memori energi akumulasi terbukti meningkatkan akurasi estimasi KM, meski **sangat bergantung** pada algoritma dan profil arus yang diuji.

