

Penyusun: Carla Benita (13321073) | Dosen Pembimbing: 1. Dr.-Ing. Justin Pradipta, S.T., M.T. ; 2. Rizki Armanto Mangkuto, S.T., M.T., Ph.D.

Latar Belakang

Penggunaan energi pada bangunan *Association of Southeast Asian Nations* (ASEAN) terus meningkat dan di tahun 2040 konsumsi energi finalnya diprediksi akan meningkat sampai 120%. Karena itu, bangunan konvensional mulai menerapkan *Building Energy Management System* (BEMS). Kontrol berbasis okupansi dapat mengurangi konsumsi listrik sebesar 55% untuk pemanasan dan pendinginan, 55% ventilasi, dan 75% pencahayaan. Pengembangan kontrol tersebut berawal dari *machine learning*. Untuk prediksi okupansi pada bangunan kampus, salah satu algoritma dengan potensi tinggi adalah *Long-Short Term Memory* (LSTM). Namun, dari segi data juga perlu dipastikan kualitasnya melalui rekayasa fitur.

Tujuan

1. Mengembangkan dan menyesuaikan parameter model LSTM untuk prediksi okupansi berbasis konsumsi listrik.
2. Menganalisis efektivitas rekayasa fitur dalam meningkatkan akurasi model prediksi okupansi berdasarkan perbandingan nilai galat.
3. Mengevaluasi model prediksi okupansi berdasarkan konsumsi listrik menggunakan LSTM, dengan validasi menggunakan data okupansi hasil pemantauan manual dari rekaman CCTV.


Batasan

1. Penelitian dilakukan pada ruang Laboratorium Manajemen Energi (ME) untuk hari kerja jam 06:00-18:00.
2. Perhitungan okupansi hanya didasarkan pada jumlah penghuni tanpa memperhitungkan distribusi spasial atau zonasi ruangan.
3. Pengukuran listrik tidak termasuk AC, hanya perangkat elektronik dan pencahayaan saja.

Asumsi


1. Aktivitas penghuni Laboratorium ME umumnya berupa bekerja, belajar, dan diskusi.
2. Tidak ada penghuni ruangan di luar jam 06:00 – 18:00 WIB.
3. Persebaran penghuni di dalam ruangan dianggap merata, sehingga tidak terjadi kerumunan pada satu titik tertentu.
4. Pengukuran konsumsi listrik dan jumlah okupansi ruangan akurat.

Objek Penelitian



Penelitian dilakukan pada Laboratorium ME, lantai 3 Labtek VI, ITB

Metodologi Penelitian



Persiapan Data

1. Data okupansi didapat dari pemantauan rekaman CCTV secara manual sedangkan data konsumsi listrik dari pengukuran *smart meter* (V, I, dan PF).
2. Periksa nilai NaN dan menangani *missing values*.
3. Mengolah data konsumsi listrik

$$p = \frac{(V_1 \times I_1 \times PF_1) + (V_2 \times I_2 \times PF_2) + (V_3 \times I_3 \times PF_3)}{1000}$$
$$E_T = \frac{1}{60} \times \left(\sum_{t=0}^{t=T} P(t) \right)$$

4. Mengatasi outlier dengan pengujian Z-score

$$Z = \frac{a - \mu}{\sigma}$$


5. Membandingkan nilai *Pearson Correlation Coefficient* (PCC) antara okupansi dan konsumsi listrik

Resolusi	PCC
15 menit	0,569
60 menit	0,439

$$r = \frac{n \sum xy - (\sum x)(\sum y)}{\sqrt{(n \sum x^2 - (\sum x)^2)(n \sum y^2 - (\sum y)^2)}}$$


6. Melakukan rekayasa fitur waktu, okupansi, dan energi.

- a. Fitur "Jam" → "Jam-Sin"




Pola numerik linear pada jam diubah ke dalam bentuk setengah positif gelombang sinusoidal untuk memberikan konteks harian yang sebenarnya.

- b. Fitur "Okupansi" → "Median Okupansi"



Nilai median okupansi didapat dari perhitungan median rerata okupansi berdasarkan 1-5 hari ke belakang.

7. Menguji nilai korelasi antara fitur dan target.



8. Seleksi fitur dilakukan dengan 2 metode: *Recursive Feature Elimination with Cross Validation* (RFECV) + *feature importance* dengan *estimator Extreme Gradient Boosting* (XGBoost) dan korelasi PCC.

9. Membagi data ke dalam proporsi 70:30 untuk data latih dan data uji.

10. Melakukan normalisasi dengan persamaan *Min-max Scaler*

$$u' = \frac{u - u_{\min}}{u_{\max} - u_{\min}}$$

Pemodelan

Melakukan penalaan *hyperparameter* model dengan metode *Grid Search* dan *trial and error*.

Model	Hidden layer	Neuron	Dropout rate	Batch size	Epoch	Sequence length
A	1	128	0,1	8	70	4
B	1	64	0,2	8	100	4
C	2	128	0	8	100	4
D	1	128	0,1	8	70	4

Evaluasi

1. Mengevaluasi kinerja model dengan metrik *Root Mean Squared Error* (RMSE) dan *Mean Absolute Error* (MAE).

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


$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|$$

2. Membandingkan galat antar model.

Model	Fitur	RMSE	MAE
A	Energi (t-1)	0,1666	0,1199
B	Energi (t-1) dan Energi (t-2)	0,1698	0,1203
C	Energi (t-1) dan Jam-Sin	0,1345	0,096
D	Energi (t-1), Energi (t-2), Jam-Sin, dan Median Okupansi	0,1429	0,1031


Nilai error terkecil dihasilkan oleh model C menggunakan fitur Energi (t-1) dan Jam-Sin. Jika dibandingkan dengan model A, penambahan fitur Jam-Sin, menurunkan nilai RMSE sebesar 19,27% dan MAE sebesar 19,93%.

2. Menganalisis kurva *loss function*



Kurva latih dan uji sama-sama menurun ke titik terendah sehingga model ada dalam kondisi *best fit*.

3. Menganalisis hasil prediksi okupansi secara *time-series*.



Berdasarkan visualisasi model C, pola okupansi ruangan pada pagi dan sore hari dapat ditangkap. Di waktu-waktu tersebut, Lab ME cenderung kosong maka model memprediksi okupansinya bernilai 0.

Kesimpulan

1. Penelitian ini berhasil mengembangkan model prediksi okupansi ruangan Laboratorium ME menggunakan pendekatan berbasis data dengan algoritma LSTM.
2. Fitur rekayasa "Jam-Sin" menghasilkan penurunan RMSE hingga 19,27% dan MAE hingga 19,93% sedangkan fitur "Jam-Sin" dan "Median Okupansi" menghasilkan penurunan RMSE hingga 15,84% dan MAE hingga 14,30%.
3. Model C dengan fitur "Energi (t-1)" dan "Jam-Sin" menghasilkan kesalahan paling kecil, yaitu RMSE bernilai 0,1345 dan MAE bernilai 0,0960. Secara *time series*, model telah berhasil menangkap pola umum dan memprediksi nilai okupansi yang cukup mendekati aktual.