

**PENERAPAN ALGORITMA MACHINE LEARNING UNTUK  
PREDIKSI DAN DETEKSI ANOMALI KONSUMSI LISTRIK  
PADA RUMAH TANGGA**

**TUGAS AKHIR**

**Diajukan oleh:**

**REZATUL FADILAH  
220705023**

**Mahasiswa Fakultas Sains dan Teknologi  
Program Studi Teknologi Informasi**



**FAKULTAS SAINS DAN TEKNOLOGI  
UNIVERSITAS ISLAM NEGERI AR-RANIRY  
BANDA ACEH  
2026 M / 1447 H**

**LEMBAR PERSETUJUAN**

**PENERAPAN ALGORITMA *MACHINE LEARNING* UNTUK PREDIKSI  
DAN DETEKSI ANOMALI KONSUMSI LISTRIK PADA RUMAH  
TANGGA**

**TUGAS AKHIR**

Diajukan Kepada Fakultas Sains dan Teknologi  
Universitas Islam Negeri (UIN) Ar-Raniry Banda Aceh  
Sebagai Salah Satu Beban Studi Memperoleh Gelar Sarjana  
Pada Program Studi Teknologi Informasi

Oleh:


**REZATUL FADILAH  
220705023**

**Mahasiswa Fakultas Sains dan Teknologi  
Program Studi Teknologi Informasi**

Disetujui Untuk Dimunaqasyahkan Oleh:

Pembimbing I,

Pembimbing II,

  
**Mulkan Fadhli, S.T., M.T.**  
NIP. 198811282020121006

UIN  
AR - RANIRY

  
**Dr. Hendri Ahmadian, M.I.M**  
NIP. 198301042014031002

Mengetahui,  
Ketua Program Studi Teknologi Informasi

  
**Malahayati, M.T.**  
NIP. 198301272015032003

## LEMBAR PENGESAHAN

### PENERAPAN ALGORITMA MACHINE LEARNING UNTUK PREDIKSI DAN DETEKSI ANOMALI KOMSUMSI LISTRIK PADA RUMAH TANGGA

#### TUGAS AKHIR

Telah Diuji Oleh Panitia Ujian Munaqasyah Tugas Akhir  
Fakultas Sains dan Teknologi UIN Ar-Raniry Banda Aceh dan Dinyatakan Lulus  
Serta Diterima Sebagai Salah Satu Beban Studi Program Sarjana (S1)  
Dalam Program Studi Teknologi Informasi


Pada Hari/Tanggal : Senin, 11 Mei 2026 M  
23 Dzulqaidah 1447 H  
Di Darussalam, Banda Aceh

Panitia Ujian Munaqasyah Tugas Akhir:


Ketua,

  
Mulkan Fadhli, S.T., M.T  
NIP. 19830127015032003


Sekretaris,

  
Dr. Hendri Ahmadian, M.I.M  
NIP. 198301042014031002

Penguji I,

  
Raihan Islamadina, M.T  
NIP. 198901312020122011


Penguji II,

  
Aulia Syarif Aziz, S.Kom., M.Sc  
NIP. 199305212022031001

Mengetahui:

Dekan Fakultas Sains dan Teknologi  
UIN Ar-Raniry Banda Aceh



  
Prof. Dr. Ir. Muhammad Dirhamsyah, M.T., IPU  
NIP. 196210021988111001

## LEMBAR PERNYATAAN KEASLIAN TUGAS AKHIR

Yang Bertanda Tangan dibawah ini

Nama : Rezatul Fadilah  
NIM : 220705023  
Program Studi : Teknologi Informasi  
Fakultas : Sains dan Teknologi  
Judul Tugas Akhir : Penerapan Algoritma Machine Learning Untuk  
Prediksi dan Deteksi Anomali Komsumsi Listrik  
Pada Rumah Tangga

Dengan ini menyatakan bahwa dalam penulisan tugas akhir ini, saya:

1. Tidak menggunakan ide orang lain tanpa mampu mengembangkan dan mempertanggungjawabkan;
2. Tidak melakukan plagiasi terhadap naskah karya orang lain;
3. Tidak menggunakan karya orang lain tanpa menyebutkan sumber asli atau tanpa izin pemilik karya;
4. Tidak memanipulasi dan memalsukan data;
5. Mengerjakan sendiri karya ini dan mampu bertanggungjawab atas karya ini.

Bila di kemudian hari ada tuntutan dari pihak lain atas karya saya, dan telah memulai pembuktian yang dapat dipertanggungjawabkan dan ternyata memang ditemukan bukti bahwa saya telah melanggar pernyataan ini, maka saya siap dikenai sanksi berdasarkan aturan yang berlaku di Fakultas Sains dan Teknologi UIN Ar-Raniry Banda Aceh. A R - R A N I R Y

Demikian pernyataan ini saya buat dengan sesungguhnya dan tanpa paksaan dari pihak manapun.

Banda Aceh, 11 Mei 2026

Yang menyatakan,



Rezatul Fadilah

## ABSTRAK

Nama : Rezatul Fadilah  
NIM : 220705023  
Program Studi : Teknologi Informasi  
Judul : Penerapan Algoritma Machine Learning Untuk Prediksi dan Deteksi Anomali Komsumsi Listrik Pada Rumah Tangga  
Tanggal Sidang : 11 Mei 2026  
Jumlah Halaman : 69  
Pembimbing I : Mulkan Fadhli, S.T., M.T  
Pembimbing II : Dr. Hendri Ahmadian, M.I.M

Peningkatan konsumsi listrik pada sektor rumah tangga menuntut adanya upaya efisiensi energi yang dapat dicapai melalui pemahaman pola pemakaian dan deteksi anomali menggunakan pendekatan *unsupervised deep learning* dengan arsitektur *Hybrid CNN-LSTM Autoencoder* berbasis *residual error*. Penelitian ini memanfaatkan data sekunder historis berbentuk deret waktu (*time series*) yang diproses melalui normalisasi *StandardScaler* dan transformasi *sliding window* sebesar 12 *time steps*, di mana kejadian tidak wajar dideteksi ketika deviasi *Maximum Mean Absolute Error* (MAE) melampaui ambang batas peringatan (*threshold*) pada persentil ke-98 dari distribusi validasi. Hasil pengujian menunjukkan bahwa model sangat presisi dalam merekonstruksi data operasional wajar dengan tingkat akurasi keseluruhan mencapai 96% serta metrik *precision* 1.00 pada kelas normal. Akan tetapi, pada pengenalan kelas anomali, model mengalami fenomena *over-generalization* yang mengakibatkan sensitivitas tidak proporsional, di mana model memicu 75 alarm palsu (*False Positives*) akibat fluktuasi beban harian wajar dan luput mendeteksi 3 kejadian anomali struktural aktual (*recall* anomali sebesar 0.00). Oleh karena itu, dapat disimpulkan bahwa meskipun algoritma ini sangat tangguh dalam memodelkan normalitas sistem kelistrikan, pendekatan ini masih memerlukan optimalisasi fungsi kerugian (*loss function*) lebih lanjut untuk meningkatkan sensitivitas deteksi pada kondisi anomali ekstrem yang merupakan kelas minoritas.

**Kata kunci:** Deteksi Anomali, Konsumsi Listrik Rumah Tangga, *Machine Learning*, CNN-LSTM, *Autoencoder*, Deret Waktu.

## ABSTRACT

*Name* : Rezatul Fadilah  
*NIM* : 220705023  
*Studi Program* : *Information Technology*  
*Title* : *Application of Machine Learning Algorithms for Prediction and Anomaly Detection of Household Electricity Consumption*

*Date of Defense* : 11 May 2026

*Number of Pages* : 69

*Supervisor I* : Mulkan Fadhli, S.T., M.T

*Supervisor II* : Dr. Hendri Ahmadian, M.I.M

*The increase in electricity consumption in the household sector demands energy efficiency efforts, which can be achieved by understanding consumption patterns and detecting anomalies using an unsupervised deep learning approach with a Hybrid CNN-LSTM Autoencoder architecture based on residual error. This study utilizes historical secondary time series data processed through StandardScaler normalization and a sliding window transformation of 12 time steps, where abnormal events are detected when the Maximum Mean Absolute Error (MAE) deviation exceeds the warning threshold at the 98th percentile of the validation distribution. The test results show that the model is highly precise in reconstructing normal operational data, achieving an overall accuracy of 96% and a precision metric of 1.00 for the normal class. However, in recognizing the anomaly class, the model experiences an over-generalization phenomenon resulting in disproportionate sensitivity, where the model triggers 75 false alarms (False Positives) due to normal daily load fluctuations and fails to detect 3 actual structural anomaly events (anomaly recall of 0.00). Therefore, it can be concluded that although this algorithm is highly robust in modeling the normality of the electrical system, this approach still requires further optimization of the loss function to improve detection sensitivity under extreme anomaly conditions, which constitute a minority class.*

**Keywords:** *Anomaly Detection, Household Electricity Consumption, Machine Learning, CNN-LSTM, Autoencoder, Time Series.*

## KATA PENGANTAR

*Bismillahirrahmanirrahim*

Assalamu'alaikum warahmatullahi wabarakatuh.

Puji syukur penulis panjatkan ke hadirat Allah SWT karena atas rahmat dan karunia-Nya, penulis dapat menyelesaikan tugas akhir yang berjudul “*Penerapan Algoritma Machine Learning untuk Prediksi dan Deteksi Anomali Komsumsi Listrik Pada Rumah Tangga*” dengan baik. Shalawat dan salam semoga senantiasa tercurah kepada Nabi Muhammad SAW yang telah membawa umat manusia dari zaman kegelapan menuju zaman penuh dengan ilmu pengetahuan.

Tugas akhir ini disusun sebagai salah satu syarat untuk memperoleh gelar Sarjana pada Program Studi Teknologi Informasi, Fakultas Sains dan Teknologi, Universitas Islam Negeri Ar-Raniry Banda Aceh. Penelitian ini membahas penerapan algoritma machine learning dalam menganalisis pola konsumsi listrik rumah tangga serta mendeteksi anomali penggunaan energi berdasarkan data historis, dengan harapan dapat memberikan kontribusi dalam meningkatkan efisiensi penggunaan energi listrik.

Dalam proses penyusunan tugas akhir ini, penulis menyadari bahwa banyak pihak yang telah memberikan bantuan, dukungan, serta bimbingan. Oleh karena itu, penulis ingin menyampaikan ucapan terima kasih yang sebesar-besarnya kepada:

1. Ayah Azhari Abidin *first love* dan panutanku yang selalu tampak cuek, namun sesungguhnya adalah orang yang paling khawatir setiap kali anak perempuannya melangkah jauh dari rumah. Terimakasih untuk setiap tetesan keringat dalam setiap langkah pengorbanan dan kerja keras yang dilakukan untuk memberikan yang terbaik kepada penulis, mengusahakan segala kebutuhan penulis, mendidik, membimbing, dukungan, motivasi, dan selalu ada ketika penulis hilang arah serta selalu mendoakan disetiap keadaan apapun agar penulis mampu bertahan untuk melangkah selangkah demi selangkah dalam meraih mimpi di masa depan. Serta telah mengajari

dan memberikan penulis pelajaran yang sangat berharga tentang arti menjadi seorang perempuan yang kuat, bertanggung jawab, selalu berjuang dan mandiri. Beliau memang tidak sempat merasakan pendidikan sampai bangku perkuliahan, namun beliau mampu mendidik memberikan motivasi dan hingga penulis mampu menyelesaikan studinya sampai sarjana;

2. Ibu Nurhafidhah bidadari surgaku beliau bukan hanya seorang ibu, tetapi juga sahabat, guru, dan cahaya dalam setiap langkah hidup penulis. Dari tanganya yang lembut, penulis belajar arti ketulusan. Dari air matanya, penulis memahami makna perjuangan. Dari doanya yang tak pernah putus, penulis mengenal cinta sejati yang tak bersyarat. Kalau untuk mendeskripsikan beliau, tidak akan pernah cukup dengan satu skripsi ini, bahkan seribu halaman pun tidak akan mampu menampung besarnya kasih sayang dan pengorbanan beliau. Tanpa beliau, penulis bukanlah siapa-siapa. Terima kasih atas kasih sayang tanpa batas yang tak pernah lekang oleh waktu, serta atas keabaran dan pengorbanan yang senantiasa mengiringi setiap langkah perjalanan hidup penulis. Beliau memang tidak menempuh pendidikan hingga perguruan tinggi, namun dengan tekad yang kuat, kerja keras dan doa yang tak pernah berhenti, beliau mampu mengantarkan anaknya menjadi seorang sarjana. Dalam setiap tutur dan tindakannya, penulis belajar banyak hal yang bahkan tak selalu diajarkan di ruang perkuliahan. Beliau adalah guru kehidupan yang luar biasa dengan ketulusan dan keikhlasan telah mendidik penulis menjadi priadi yang kuat, berbakti, dan penuh rasa syukur;
3. Terima kasih kepada adik-adik dan kaka tercinta Rizkiul Farhan, Rizkiul Zafran, Rizkiul Rifqi, dan Reza Maulia, yang telah menyemangati penulis dan menjadi sumber motivasi penulis;
4. Ibu Malahayati, M.T., selaku Ketua Program Studi Teknologi Informasi yang telah meluangkan waktu, tenaga, dan pikiran untuk memberikan arahan, masukan, serta bimbingan yang sangat berharga selama proses penyusunan proposal ini;

5. Ibu Cut Ida Rahmadiana, S.Si., Staf Operator Program Studi Teknologi Informasi, yang selalu sigap dan tulus memberikan bantuan dalam setiap kebutuhan administrasi, sehingga proses perkuliahan dapat berjalan dengan lancar;
6. Kepada bapak Mulkan Fadhli, S.T., M.T. dan Dr. Hendri Ahmadian, M.I.M. penulis mengucapkan terima kasih yang sebesar-besarnya atas segala bimbingan, arahan, kesabaran, dan ilmu yang telah diberikan selama proses penyusunan skripsi ini.
7. Seluruh Bapak dan Ibu Dosen Program Studi Teknologi Informasi yang telah memberikan bekal ilmu pengetahuan yang tak ternilai selama masa perkuliahan;
8. Kepada sahabat penulis Fika Nabilla.S terimakasih telah menjadi tempat berbagi cerita, senantiasa menemani, membantu dan saling memberi dukungan selama ini hingga penulis bisa sampai pada titik ini, terimakasih telah menjadi saudara di tanah rantau walaupun tak sedarah;
9. Kepada Darazatul Firza dan munira yunanda terimakasih sudah support penulis dalam mengerjakan skripsi ini.
10. Lats but not least, ucapan terima kasih kupersembahkan untuk diriku. Terima kasih, sayang. Terima kasih telah bertahan ketika tidak ada yang benar-benar mengerti beratnya menjadi kuat. Terima kasih telah memeluk diri sendiri saat dunia terasa terlalu gaduh untuk memberi ruang. Kau adalah saksi dari air mata yang disembunyikan, dari doa-doa yang berani dipanjatkan dalam gelap, dari luka yang diam-diam kau jahit sendirian. Hari ini, gelar S.Kom. kupersembahkan sepenuh hati untukmu. Ini bukanlah akhir perjalanan. Ini adalah satu simpul impian kita, yang masih meraba menyusuri titik akhirnya. Semoga ke depan, kau tetap lembut pada diri sendiri, tetap berani bermimpi tanpa takut gagal, dan tetap ingat bahwa segala pencapaian ini lahir dari keberanianmu untuk tidak menyerah. Jika suatu hari kamu lelah, bacalah namamu sendiri dan ingat; kau pernah sampai sejauh ini.

Penulis menyadari bahwa tugas akhir ini masih memiliki kekurangan. Oleh karena itu, kritik dan saran yang membangun sangat diharapkan demi

penyempurnaan dimasa mendatang. Semoga penelitian ini dapat memberikan manfaat bagi pengembangan ilmu pengetahuan, khususnya dalam bidang machine learning dan analisis konsumsi energi listrik.

Banda Aceh, 11 Mei 2026

Penulis,



Rezatul Fadilah



## DAFTAR ISI

<b>LEMBAR PERSETUJUAN .....</b>	<b>ii</b>
<b>LEMBAR PENGESAHAN.....</b>	<b>iii</b>
<b>LEMBAR PERNYATAAN KEASLIAN TUGAS AKHIR .....</b>	<b>iv</b>
<b>ABSTRAK.....</b>	<b>v</b>
<b>ABSTRACT .....</b>	<b>vi</b>
<b>KATA PENGANTAR .....</b>	<b>vii</b>
<b>DAFTAR ISI .....</b>	<b>xi</b>
<b>DAFTAR GAMBAR .....</b>	<b>xii</b>
<b>DAFTAR TABEL .....</b>	<b>xiii</b>
<b>BAB I PENDAHULUAN .....</b>	<b>1</b>
1.1 Latar Belakang.....	1
1.2 Rumusan masalah.....	3
1.3 Tujuan Penelitian .....	4
1.4 Manfaat Penelitian.....	4
1.5 Batasan Penelitian .....	5
<b>BAB II TINJAUAN PUSTAKA .....</b>	<b>6</b>
2.1 Penelitian Terdahulu .....	6
2.2 Kecerdasan Buatan .....	10
2.3 Machine Learning.....	11
2.4 Algoritma Machine Learning .....	12
2.5 Konsumsi Listrik .....	13
2.6 Rumah Tangga .....	14
2.7 Pra Pemrosesan Data .....	15
2.8 CNN-LSTM.....	17
2.9 Deteksi Anomali .....	18
2.10 Kerangka Pemikiran .....	19
<b>BAB III METODE PENELITIAN.....</b>	<b>21</b>
3.1 Metode Penelitian .....	21
3.2 Tahapan penelitian .....	22

3.2.1 Pengumpulan dan Pengolahan Data .....	22
3.2.2 Pengembangan dan Evaluasi Model Machine Learning .....	24
3.2.3 Prediksi .....	26
3.2.4 Deteksi Anomali .....	26
3.3 Sumber dan Deskripsi Dataset.....	27
3.3.1 Sumber Data .....	29
3.3.2 Deskripsi Dataset.....	30
3.3.3 Statistik Umum Dataset.....	32
3.3.4 Kelebihan dan Keterbatasan Dataset .....	33
3.3.5 Alasan Penggunaan Dataset.....	33
3.4 Alat dan Bahan .....	34
3.4.1 Perangkat Keras ( <i>Hardware</i> ).....	34
3.4.2 Perangkat Lunak ( <i>Software</i> ).....	35
3.5 Tempat Penelitian .....	35
3.6 Waktu Penelitian.....	36
<b>BAB IV HASIL DAN PEMBAHASAN .....</b>	<b>38</b>
4.1 Implementasi Pra-pemrosesan Data ( <i>Data Preprocessing</i> ).....	38
4.1.1 Normalisasi Fitur menggunakan <i>StandardScaler</i> .....	39
4.1.2 Transformasi Deret Waktu ( <i>Sliding Window</i> ).....	40
4.2 Arsitektur dan Pelatihan Model <i>Hybrid CNN-LSTM Autoencoder</i> .....	40
4.2.1 Arsitektur Jaringan .....	40
4.2.2 Proses Pelatihan (Model Training) .....	41
4.3 Deteksi Anomali Berbasis <i>Reconstruction Error</i> .....	42
4.3.1 Kalkulasi Deviasi Maksimum (Maksimum MAE) .....	42
4.3.2 Penentuan Threshold .....	43
4.4 Prediksi Model.....	43
4.5 Evaluasi Model.....	44
4.5.1 Analisis Matriks Klasifikasi .....	44
4.5.2 Matriks Evaluasi.....	45
4.6 Visualisasi Deteksi Anomali pada Deret Waktu .....	45

4.7 Hasil dan Pembahasan .....	48
<b>BAB V PENUTUP .....</b>	<b>49</b>
5.1 Kesimpulan.....	49
5.2 Saran .....	51
<b>DAFTAR PUSTAKA.....</b>	<b>52</b>



## DAFTAR GAMBAR

Gambar 1. 1 Tren Konsumsi Listrik Rumah Tangga Indonesia (2020-2024) .....	1
Gambar 3. 1 Alur Penelitian .....	22
Gambar 4.1 Kurva Konvergensi Training dan validation Loss .....	39
Gambar 4.2 Grafik Confusion Matriks.....	42
Gambar 4.3 Deteksi Anomali pada Grafik Fluktuasi Daya .....	44



## DAFTAR TABEL


Tabel 2. 1 Penelitian Terdahulu .....	6
Tabel 3. 1 Deskripsi Atribut Dataset.....	30
Tabel 3. 2 Statistik Dataset .....	31
Tabel 3. 3 Hardware.....	33
Tabel 3. 4 Software .....	35
Tabel 3. 5 Proses Pembuatan Tugas Akhir .....	36
Tabel 3.6 Analisis Matriks Klasifikasi .....	42



# BAB I PENDAHULUAN

## 1.1 Latar Belakang

Konsumsi listrik di sektor rumah tangga di Indonesia terus menunjukkan peningkatan yang signifikan setiap tahunnya. Kenaikan ini didorong oleh pertumbuhan jumlah penduduk di wilayah perkotaan serta perubahan gaya hidup masyarakat yang semakin bergantung pada peralatan elektronik untuk menunjang aktivitas sehari-hari. Sejalan dengan temuan (Jamilatun et al., 2025), sektor rumah tangga menjadi kontributor dominan dalam konsumsi listrik nasional, di mana peningkatan jumlah pelanggan dan penggunaan perangkat modern menyebabkan lonjakan permintaan energi yang berkelanjutan. Tren kenaikan ini dapat dilihat secara jelas pada Gambar 1.1 berikut:



*Gambar 1. 1 Tren Konsumsi Listrik Rumah Tangga Indonesia (2020-2024)  
Sumber: Statistik PLN 2020-2024*

Berdasarkan grafik di atas, terlihat tren kenaikan yang konsisten selama lima tahun terakhir, di mana konsumsi listrik rumah tangga melonjak dari 109,48 TWh pada tahun 2020 menjadi 130,43 TWh pada tahun 2024.

Peningkatan ini mengindikasikan bahwa beban listrik domestik semakin berat, sehingga diperlukan metode prediksi yang akurat dan deteksi anomali untuk membantu efisiensi energi, sebagaimana yang menjadi fokus utama dalam penelitian ini.

Rumah tangga memiliki pola konsumsi listrik yang bervariasi tergantung jumlah anggota keluarga, jenis peralatan, serta waktu pemakaian. Pola yang tidak merata dapat menyebabkan pemborosan energi dan peningkatan biaya. Oleh karena itu, diperlukan analisis perilaku konsumsi listrik yang dapat membantu pengguna memahami pola penggunaan dan menemukan potensi efisiensi. Studi sebelumnya menunjukkan bahwa analisis berbasis data historis mampu menemukan tren konsumsi dan perbedaan pola pemakaian antar waktu (Indra Gunawan et al., 2025).

Pendekatan *data mining* juga telah digunakan untuk mengenali pola konsumsi rumah tangga di Indonesia. Metode seperti *clustering* membantu mengelompokkan perilaku pengguna, misalnya konsumsi tinggi pada siang atau malam hari. Penelitian Prayoga et al. (2025) menegaskan bahwa identifikasi pola tersebut merupakan langkah awal dalam mendeteksi konsumsi listrik abnormal, yang menjadi dasar bagi sistem deteksi anomali yang lebih canggih.

Penerapan model *deep learning* seperti CNN-LSTM terbukti efektif untuk memprediksi konsumsi listrik dan mendeteksi anomali secara otomatis. Irwansyah et al. (2023) menunjukkan bahwa CNN-LSTM menghasilkan *Mean Squared Error* (MSE) lebih kecil sekitar 29% dibandingkan LSTM tunggal, sehingga prediksi menjadi lebih akurat dan anomali lebih cepat terdeteksi. Dengan data konsumsi periodik, sistem ini dapat meningkatkan efisiensi penggunaan listrik rumah tangga.

Fitur-fitur seperti daya aktif (*active power*), arus (*current*), tegangan (*voltage*), dan faktor beban (*load factor*) berperan penting dalam keakuratan deteksi anomali. (Koerniawan et al., 2024) menjelaskan bahwa anomali konsumsi sering terjadi akibat kerusakan alat ukur atau gangguan transmisi,

dan kerugian dapat ditekan jika fitur pengukuran diperhatikan secara sistematis.

Hasil penelitian lain juga menunjukkan kinerja *deep learning* yang baik pada peramalan beban jangka pendek. Pendekatan berbasis LSTM mampu mengenali pola musiman harian dan mingguan dengan kesalahan rendah, sebagaimana ditunjukkan oleh penelitian di Jawa Timur yang mencapai nilai MAPE dan RMSE rendah (Septian & Kartini, 2023).

Berdasarkan uraian tersebut, dapat disimpulkan bahwa penelitian mengenai prediksi dan deteksi anomali konsumsi listrik rumah tangga masih terbatas, terutama dengan pemanfaatan data publik. Sebagian besar studi fokus pada monitoring, belum pada integrasi *machine learning* untuk deteksi anomali adaptif. Karena itu, penelitian ini penting dilakukan untuk menerapkan algoritma *machine learning* yang mampu memprediksi pola konsumsi dan mendeteksi anomali secara otomatis, sehingga mendukung efisiensi dan keberlanjutan energi rumah tangga.

## 1.2 Rumusan masalah

Berdasarkan latar belakang masalah yang telah diuraikan, penelitian ini merumuskan beberapa pertanyaan inti yang akan menjadi fokus utama pada penelitian ini. Pertanyaan-pertanyaan tersebut adalah:

- 1) Bagaimana penerapan model deep learning CNN-LSTM dalam memprediksi konsumsi listrik rumah tangga berdasarkan data historis time series?
- 2) Seberapa baik kinerja model CNN-LSTM dalam melakukan prediksi konsumsi listrik rumah tangga berdasarkan metrik evaluasi MAE dan RMSE?
- 3) Bagaimana kemampuan pendekatan deteksi anomali berbasis residual error dari hasil prediksi CNN-LSTM dalam mengidentifikasi pola konsumsi listrik yang tidak normal?

### **1.3 Tujuan Penelitian**

Berdasarkan rumusan masalah yang telah dikemukakan, tujuan dari penelitian ini adalah sebagai berikut:

- 1) Menerapkan model deep learning CNN-LSTM untuk memprediksi konsumsi listrik rumah tangga berdasarkan data historis berbentuk deret waktu (time series).
- 2) Mengevaluasi kinerja model CNN-LSTM dalam melakukan prediksi konsumsi listrik rumah tangga menggunakan metrik evaluasi Mean Absolute Error (MAE) dan Root Mean Square Error (RMSE).
- 3) Mengidentifikasi pola konsumsi listrik yang tidak normal melalui pendekatan deteksi anomali berbasis residual error dari hasil prediksi model CNN-LSTM.

### **1.4 Manfaat Penelitian**

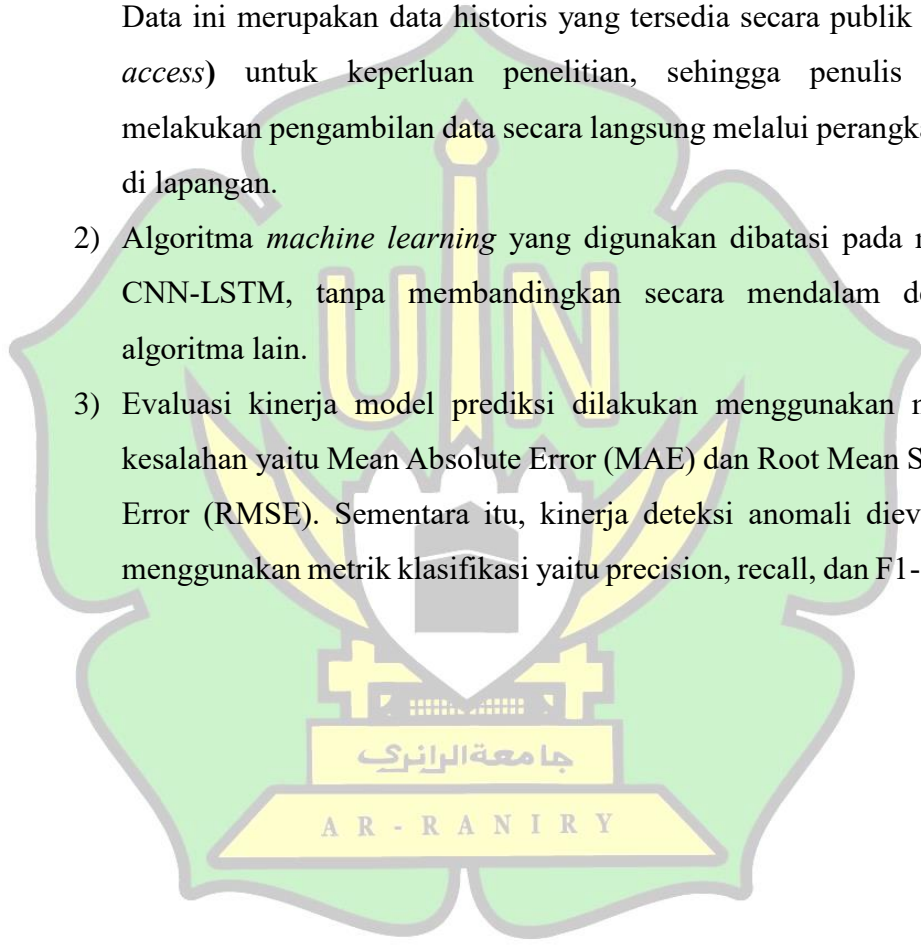
Penelitian ini diharapkan dapat memberikan manfaat baik dalam pengembangan ilmu pengetahuan maupun dalam penerapan praktis di lapangan. Adapun manfaat yang dapat dicapai melalui penelitian ini adalah sebagai berikut:

- 1) Memberikan kontribusi dalam pengembangan metode analisis konsumsi listrik rumah tangga dengan memanfaatkan model deep learning berbasis CNN-LSTM pada data deret waktu.
- 2) Menyediakan pendekatan analisis yang dapat membantu mengidentifikasi pola konsumsi listrik yang tidak normal sehingga dapat digunakan sebagai dasar dalam meningkatkan efisiensi penggunaan energi listrik pada rumah tangga.
- 3) Menjadi referensi bagi penelitian selanjutnya yang berkaitan dengan penerapan machine learning dalam prediksi konsumsi energi dan deteksi anomali pada sistem pemantauan energi.

### 1.5 Batasan Penelitian

Agar penelitian ini lebih terarah dan tidak melebar dari tujuan yang telah ditentukan, maka ditetapkan beberapa batasan penelitian sebagai berikut:

- 1) Data yang digunakan dalam penelitian ini dikategorikan sebagai data sekunder, yang bersumber dari *UCI Machine Learning Repository*. Data ini merupakan data historis yang tersedia secara publik (*open access*) untuk keperluan penelitian, sehingga penulis tidak melakukan pengambilan data secara langsung melalui perangkat IoT di lapangan.
- 2) Algoritma *machine learning* yang digunakan dibatasi pada model CNN-LSTM, tanpa membandingkan secara mendalam dengan algoritma lain.
- 3) Evaluasi kinerja model prediksi dilakukan menggunakan metrik kesalahan yaitu Mean Absolute Error (MAE) dan Root Mean Square Error (RMSE). Sementara itu, kinerja deteksi anomali dievaluasi menggunakan metrik klasifikasi yaitu precision, recall, dan F1-score.



## BAB II TINJAUAN PUSTAKA

### 2.1 Penelitian Terdahulu

Perkembangan penelitian dalam bidang *machine learning* untuk prediksi dan deteksi anomali konsumsi listrik telah banyak diarahkan pada peningkatan efisiensi energi serta kemampuan sistem dalam mengenali perilaku penggunaan yang menyimpang. Berbagai studi menunjukkan implementasi metode ini pada skala rumah tangga, bangunan komersial, hingga sistem distribusi listrik dengan beragam pendekatan seperti LSTM, CNN-LSTM, dan *data mining*. Penelitian-penelitian berikut memberikan gambaran perkembangan metode serta celah riset yang masih dapat dikembangkan.

*Tabel 2.1 Penelitian Terdahulu*

<b>Peneliti</b>	<b>Judul Penelitian</b>	<b>Metode</b>	<b>Hasil Penelitian</b>	<b>Persamaan dan Perbedaan</b>
W. K. Wibowo, R. Purwaningsih, A. Susanty (2024)	Analisa Implementasi <i>Anomaly Early Warning System</i> pada Pelanggan AMR dalam Pengendalian Susut Jaringan Distribusi pada PLN UP3 Mataram	Sistem monitoring berbasis Automatic Meter Reading (AMR) dan anomaly early warning system.	Sistem memberi notifikasi dini atas anomali meter dan menurunkan susut distribusi	Persamaan: sama-sama membahas deteksi anomali listrik. Perbedaan: penelitian sebelumnya fokus pada sistem distribusi listrik berbasis AMR.
T. Koerniawan, S. Anastasya	Analisis Anomali Energi Listrik Tidak	Analisis anomali pada data	Mengidentifikasi laporan bacaan listrik	Persamaan: sama-sama menganalisis

Yuniarsy, A. W. Sukamajati, A. W. Hasanah, S. Yudho (2024)	Terukur pada Sistem AMR UP3 Teluk Naga	Automatic Meter Reading (AMR)	bermasalah akibat kerusakan sensor	anomali konsumsi listrik. Perbedaan: penelitian fokus pada jaringan distribusi listrik.
Impron (2025)	Analisis Pola Konsumsi Energi Listrik Rumah Tangga Berbasis Simulasi IoT Menggunakan Model Hybrid LSTM- Attention	Hybrid LSTM- Attention	Mengklasifikasi konsumsi listrik ke dalam tiga pola dasar	Persamaan: sama- sama menggunakan deep learning pada data konsumsi listrik. Perbedaan: penelitian fokus pada klasifikasi pola konsumsi.
I. Gunawan, M. Sadali, H. Ahmadi, Jumawal (2025)	Perancangan Aplikasi KWH Meter dan Sistem Monitoring Konsumsi Listrik Berbasis IoT untuk Kamar Kos- Kosan	Internet of Things (IoT) dan sensor KWH meter	Sistem berjalan dan mampu memonitor konsumsi tiap kamar secara real time	Persamaan: sama- sama membahas konsumsi listrik pada lingkungan hunian. Perbedaan: penelitian fokus pada sistem monitoring IoT.

Yusuf, Rosyidi & Saptono (2025)	Prediksi & Deteksi Anomali Konsumsi Berbasis IoT	IoT dan machine learning	Sistem berhasil memprediksi beban sekaligus mendeteksi anomali adaptif	Persamaan: sama-sama melakukan prediksi dan deteksi anomali listrik. Perbedaan: penelitian menggunakan sistem IoT sebagai sumber data.
---------------------------------	--	--------------------------	--	---

Penelitian yang dilakukan oleh Wibowo et al. (2024) mengkaji penerapan sistem anomaly early warning berbasis Automatic Meter Reading (AMR) untuk mendeteksi penyimpangan pada pembacaan meter listrik di jaringan distribusi PLN. Hasil penelitian menunjukkan bahwa sistem mampu memberikan peringatan dini terhadap anomali sehingga dapat membantu menekan kerugian energi listrik. Meskipun demikian, penelitian tersebut berfokus pada sistem distribusi listrik pada level utilitas. Berbeda dengan penelitian tersebut, penelitian ini berfokus pada analisis konsumsi listrik pada tingkat rumah tangga dengan memanfaatkan model deep learning CNN-LSTM untuk melakukan prediksi konsumsi listrik sekaligus mendeteksi anomali berdasarkan data historis.

Koerniawan et al. (2024) melakukan analisis anomali energi listrik tidak terukur pada sistem Automatic Meter Reading (AMR) untuk mengidentifikasi kesalahan pencatatan meter dan gangguan sensor pada jaringan distribusi listrik. Penelitian tersebut menunjukkan bahwa analisis data konsumsi listrik dapat digunakan untuk mendeteksi ketidaksesuaian pembacaan energi listrik pada sistem distribusi. Namun penelitian tersebut masih berfokus pada sistem distribusi listrik pada level utilitas. Sementara itu, penelitian ini lebih menitikberatkan pada analisis konsumsi listrik pada sektor rumah tangga dengan menggunakan pendekatan machine learning berbasis

CNN-LSTM untuk memprediksi pola konsumsi listrik dan mendeteksi anomali penggunaan energi.

Penelitian yang dilakukan oleh Impron (2025) membahas analisis pola konsumsi energi listrik rumah tangga menggunakan model hybrid LSTM-Attention berbasis data IoT. Hasil penelitian menunjukkan bahwa model tersebut mampu mengelompokkan pola konsumsi listrik rumah tangga ke dalam beberapa kategori berdasarkan karakteristik penggunaan energi. Meskipun menggunakan pendekatan deep learning pada data konsumsi listrik, penelitian tersebut berfokus pada klasifikasi pola konsumsi energi. Berbeda dengan penelitian tersebut, penelitian ini menggunakan model CNN-LSTM untuk melakukan prediksi konsumsi listrik serta mendeteksi anomali penggunaan listrik berdasarkan data historis.

Penelitian yang dilakukan oleh Indra Gunawan et al. (2025) mengembangkan sistem monitoring konsumsi listrik berbasis Internet of Things (IoT) menggunakan sensor KWH meter pada lingkungan kamar kos. Sistem yang dikembangkan mampu memantau penggunaan listrik secara real-time pada setiap kamar sehingga pengguna dapat mengetahui besarnya konsumsi energi secara langsung. Namun penelitian tersebut lebih berfokus pada pengembangan sistem monitoring berbasis perangkat IoT. Sementara itu, penelitian ini berfokus pada analisis data historis konsumsi listrik menggunakan pendekatan machine learning untuk melakukan prediksi konsumsi listrik serta mendeteksi anomali penggunaan energi.

Penelitian Yusuf et al. (2025) mengintegrasikan sistem Internet of Things dengan algoritma machine learning untuk melakukan prediksi konsumsi listrik sekaligus mendeteksi anomali penggunaan energi secara otomatis. Penelitian tersebut menunjukkan bahwa integrasi antara sistem monitoring IoT dan analisis machine learning dapat meningkatkan kemampuan pemantauan konsumsi listrik. Meskipun memiliki kesamaan dalam menggabungkan prediksi dan deteksi anomali, penelitian tersebut menggunakan data yang diperoleh secara real-time dari perangkat IoT.

Berbeda dengan penelitian tersebut, penelitian ini memanfaatkan dataset historis dari UCI Machine Learning Repository dan menerapkan model deep learning CNN-LSTM untuk menganalisis pola konsumsi listrik serta mendeteksi anomali penggunaan energi.

Berdasarkan beberapa penelitian terdahulu, dapat diketahui bahwa analisis konsumsi listrik dan deteksi anomali telah banyak dilakukan dengan berbagai pendekatan, seperti sistem monitoring berbasis Automatic Meter Reading (AMR), Internet of Things (IoT), maupun metode deep learning untuk klasifikasi pola konsumsi energi. Namun sebagian besar penelitian masih berfokus pada pemantauan penggunaan listrik secara real-time atau analisis anomali pada tingkat jaringan distribusi listrik. Penelitian yang mengintegrasikan proses prediksi konsumsi listrik dan deteksi anomali dalam satu kerangka analisis berbasis data historis masih relatif terbatas, khususnya pada sektor rumah tangga. Selain itu, penggunaan model deep learning yang menggabungkan kemampuan ekstraksi fitur spasial dan ketergantungan temporal seperti CNN-LSTM untuk tujuan tersebut juga belum banyak dikaji. Oleh karena itu, penelitian ini dilakukan untuk mengisi celah tersebut dengan menerapkan model CNN-LSTM dalam memprediksi konsumsi listrik rumah tangga sekaligus mendeteksi anomali penggunaan energi berdasarkan data historis konsumsi listrik.

## 2.2 Kecerdasan Buatan

Kecerdasan buatan (*Artificial Intelligence*, AI) adalah cabang ilmu komputer yang berfokus pada penciptaan sistem yang mampu melakukan tugas-tugas yang biasanya membutuhkan kecerdasan manusia seperti pengenalan pola, pengambilan keputusan, dan pembelajaran otomatis (Raihan, 2023). AI memungkinkan aplikasi untuk mengenali pola kompleks dari data besar sehingga dapat melakukan prediksi atau rekomendasi yang adaptif. Penerapan AI semakin meluas dalam sektor energi untuk meningkatkan efisiensi, pengelolaan beban, dan prediksi konsumsi listrik (Ding et al., 2024).

Pengembangan AI dalam sistem energi sering memanfaatkan teknik deep learning, reinforcement learning, dan ensemble learning. Teknik-teknik ini memungkinkan model untuk mempelajari representasi fitur tingkat tinggi secara otomatis tanpa membutuhkan rekayasa fitur manual yang ekstensif. Dalam tinjauan sistematis terbaru, AI diposisikan sebagai pendorong utama transformasi energi bersih melalui peranannya dalam pengoptimalan jaringan listrik cerdas, prediksi permintaan, dan manajemen sumber energi terbarukan (Zhang & Strbac, 2025).

Penerapan AI pada analisis konsumsi listrik rumah tangga dapat dimanfaatkan untuk mengenali perubahan pola pemakaian, mendeteksi anomali, serta menyesuaikan strategi efisiensi energi. Dengan kemampuan AI dalam memproses data historis secara adaptif, sistem prediksi berbasis *machine learning* mampu membantu pengguna rumah tangga dalam mengoptimalkan konsumsi energi dan mendukung keberlanjutan penggunaan listrik.

### **2.3 Machine Learning**

*Machine learning* merupakan pendekatan dalam kecerdasan buatan yang memungkinkan sistem mempelajari pola dari data historis untuk menghasilkan prediksi atau keputusan tanpa aturan yang ditulis secara eksplisit. Dalam praktiknya, paradigma *supervised learning* dan *unsupervised learning* digunakan sesuai dengan ketersediaan label dan tujuan analisis, misalnya prediksi nilai kontinu atau pengelompokan pola konsumsi. Tinjauan sistematis terkini pada konteks energi merangkum berbagai model dan menegaskan bahwa *machine learning* efektif untuk memodelkan hubungan nonlinier pada data konsumsi Listrik (Nanjar et al., 2024).

Pada data konsumsi listrik yang berbentuk *time series*, proses pemodelan perlu memperhatikan ketergantungan temporal, pola musiman, dan tren agar tidak terjadi bias pelatihan. Pembagian data menjadi *training*, *validation*, dan *testing* sebaiknya mempertahankan urutan waktu sehingga evaluasi mencerminkan performa nyata saat penerapan. Pendekatan *walk*

*forward validation* umum dipakai untuk menghindari kebocoran informasi masa depan saat melatih model pada skenario peramalan jangka pendek (Ou Ali et al., 2024).

Model *deep learning* yang menggabungkan konvolusi dan memori jangka panjang banyak digunakan karena mampu mengekstraksi pola lokal sekaligus ketergantungan urutan. Arsitektur hibrida seperti CNN LSTM kerap menunjukkan kinerja prediksi yang baik pada data konsumsi energi yang berfluktuasi dan penuh derau. Studi pada domain kelistrikan menunjukkan bahwa pendekatan berbasis jaringan saraf mendalam ini dapat meningkatkan akurasi prediksi serta mendukung deteksi perilaku konsumsi yang menyimpang (Irwansyah, Muhammad, Arifin, Iman, & Hermawan, 2023).

Evaluasi performa model lazim menggunakan metrik kesalahan seperti *mean squared error* dan *mean absolute error* untuk menilai deviasi antara nilai ramalan dan observasi. Selain itu, pemilihan fitur yang relevan, normalisasi, dan pemantauan *overfitting* melalui validasi berurutan berpengaruh terhadap reliabilitas hasil. Studi peramalan konsumsi pada lingkungan hunian cerdas menunjukkan bahwa kombinasi pemrosesan fitur dan pemilihan arsitektur yang tepat mampu menurunkan nilai kesalahan hingga tingkat yang dapat diterapkan secara operasional (Ou Ali et al., 2024).

#### **2.4 Algoritma Machine Learning**

*Machine Learning* (ML) merupakan bagian integral dari kecerdasan buatan yang memungkinkan komputer untuk mempelajari pola dari data historis dan meningkatkan akurasi prediksinya secara mandiri tanpa perlu diprogram secara eksplisit. Dalam penerapannya, algoritma *machine learning* sering digunakan untuk memecahkan masalah regresi dan klasifikasi, di mana model dilatih untuk memetakan hubungan kompleks antara variabel input dan output guna menghasilkan prediksi yang mendekati nilai sebenarnya (Widiyatmoko et al., 2025).

Dalam konteks manajemen energi, penerapan *machine learning* menjadi sangat krusial untuk menangani karakteristik data beban listrik yang fluktuatif. Pendekatan *Supervised Learning* banyak digunakan untuk memprediksi beban listrik harian maupun jangka pendek, di mana model dilatih mengenali pola konsumsi masa lalu untuk memproyeksikan kebutuhan energi di masa depan, sehingga penyedia listrik dapat menjaga kestabilan pasokan (Rochayati et al., 2025)

Khusus untuk data deret waktu (*time series*) yang memiliki ketergantungan jangka panjang, algoritma berbasis *Deep Learning* seperti *Long Short-Term Memory* (LSTM) terbukti lebih unggul dibandingkan metode konvensional. Penelitian menunjukkan bahwa LSTM mampu menangkap pola non-linear yang kompleks pada data historis penggunaan listrik, menghasilkan tingkat kesalahan (*error*) yang lebih rendah dibandingkan metode *Recurrent Neural Network* (RNN) biasa (Selle et al., 2022).

## 2.5 Konsumsi Listrik

Konsumsi listrik merupakan jumlah energi listrik yang digunakan oleh pengguna dalam periode waktu tertentu. Energi ini umumnya diukur dalam satuan kilowatt-hour (kWh), yang merupakan hasil dari daya dikalikan waktu penggunaan. Menurut Basconcillo & Rimkute (2023), konsumsi listrik rumah tangga sangat berkorelasi dengan pendapatan per kapita dan pertumbuhan ekonomi suatu wilayah, yang menunjukkan bahwa faktor sosial-ekonomi turut memengaruhi perilaku penggunaan energi.

$$E = P \times t$$

$$E = 0,8 \text{ kW} \times 8 \text{ JAM}$$

$$E = 6,4 \text{ kWh}$$

dengan  $E$ = energi listrik (kWh),  $P$ = daya listrik (kW), dan  $t$ = waktu pemakaian (jam). Rumus ini menjelaskan bahwa semakin besar daya atau

semakin lama durasi penggunaan suatu peralatan, maka semakin tinggi pula konsumsi listrik yang dihasilkan.

Ali et al. (2024) menegaskan bahwa sektor rumah tangga merupakan salah satu penyumbang terbesar dalam total konsumsi energi global, yakni sekitar 19,7 % dari total energi yang digunakan di Amerika Serikat pada 2023. Kondisi ini juga merefleksikan pola konsumsi serupa di berbagai negara berkembang, di mana peningkatan jumlah perangkat elektronik dan aktivitas domestik menjadi pendorong utama naiknya beban listrik rumah tangga.

Selain itu, (Ali et al., 2024) mengungkapkan bahwa analisis kuantitatif terhadap konsumsi listrik rumah tangga dapat digunakan untuk mengidentifikasi potensi efisiensi energi. Dengan pendekatan *material flow analysis* dan *data mining*, peneliti dapat menelusuri hubungan antara pola konsumsi listrik, aktivitas harian, serta kondisi lingkungan perkotaan untuk mendukung kebijakan energi berkelanjutan.

Secara umum, pemantauan dan analisis konsumsi listrik rumah tangga diperlukan untuk memahami waktu-waktu puncak penggunaan, serta menentukan strategi penghematan energi. Dengan mengombinasikan data historis dan model prediksi, efisiensi energi dapat ditingkatkan sekaligus membantu mengurangi pemborosan listrik di tingkat rumah tangga.

## **2.6 Rumah Tangga**

Rumah tangga merupakan unit sosial ekonomi terkecil yang terdiri dari individu atau kelompok yang tinggal bersama dan mengelola sumber daya secara kolektif. Berdasarkan definisi dari Badan Pusat Statistik (2023), rumah tangga adalah “sekelompok orang yang menempati sebagian atau seluruh bangunan fisik dan makan dari satu dapur yang sama.” Dalam konteks penelitian energi, rumah tangga menjadi sektor utama yang menyumbang sebagian besar konsumsi listrik nasional, dengan variasi pola penggunaan energi berdasarkan aktivitas domestik sehari-hari.

Penelitian oleh Kojima & Saito (2023) menemukan bahwa kenaikan suhu udara berbanding lurus dengan peningkatan konsumsi listrik rumah tangga, terutama pada wilayah dengan iklim panas dan pendapatan tinggi. Peneliti menyatakan bahwa “higher temperatures increase electricity consumption, with the largest effects observed for high-income households in regions with hot climates.” Temuan ini menunjukkan bahwa faktor lingkungan dan ekonomi berpengaruh signifikan terhadap besarnya konsumsi listrik di rumah tangga.

Selanjutnya, Wang et al. (2024) melalui studi bibliometrik menjelaskan bahwa analisis konsumsi listrik rumah tangga memerlukan pendekatan multidisipliner. Mereka menulis, “household-level survey and machine learning techniques identify housing characteristics, appliance usage, number of members, and income as major variables in predicting electricity demand.” Pernyataan tersebut memperkuat pentingnya variabel jumlah anggota keluarga, jenis peralatan listrik, dan tingkat pendapatan dalam membentuk pola konsumsi energi domestik.

Selain itu, sebuah studi oleh Park & Yun (2024) menunjukkan bahwa kepemilikan delapan perangkat rumah tangga utama serta karakteristik sosial-ekonomi seperti komposisi rumah tangga, masa hidup rumah tangga, dan kemampuan ekonomi memiliki dampak berbeda terhadap konsumsi listrik pada rumah apartemen di Korea.

Dengan memahami karakteristik dan perilaku konsumsi energi di tingkat rumah tangga, pemerintah dan peneliti dapat merancang kebijakan yang lebih tepat sasaran dalam mendukung efisiensi energi dan keberlanjutan lingkungan.

## **2.7 Pra Pemrosesan Data**

Pra pemrosesan data merupakan tahapan penting untuk memastikan kualitas dataset sebelum dimodelkan dengan *machine learning*, terutama pada data konsumsi listrik berbentuk *time series*. Langkah umum meliputi pembersihan data, penanganan nilai hilang, normalisasi skala fitur,

penyelarasan *timestamp*, dan pembentukan jendela urutan agar pola temporal dapat terpelajari dengan baik. Pada studi peramalan beban, tahapan ini terbukti memengaruhi akurasi model karena menentukan representasi sinyal yang akan dipelajari jaringan (Jain & Gupta, 2024).

Salah satu isu utama dalam data konsumsi listrik adalah *missing values* yang timbul akibat gangguan sensor atau keterlambatan transmisi. Di samping metode statistik sederhana, pendekatan *deep learning* berbasis *autoencoder* direkomendasikan untuk imputasi karena mampu menjaga bentuk profil beban harian sehingga struktur musiman harian dan mingguan tetap terpelihara. Metode ini dilaporkan menghasilkan profil yang lebih masuk akal dibanding teknik konvensional pada *smart meter data* yang banyak kekosongan (Duarte, Rojas, Vargas, & Aristizábal, 2024) (belum cite).

Normalisasi dan penskalaan fitur diperlukan agar variabel berada pada rentang yang sebanding, sehingga proses optimisasi pada model *neural network* stabil dan konvergen. Teknik populer mencakup *minmax scaling* dan *z score normalization* untuk menyetarakan skala input yang heterogen seperti beban, suhu, dan kelembapan. Studi *open access* pada ranah *smart grid* menegaskan bahwa normalisasi merupakan langkah pra pemrosesan krusial sebelum pelatihan model berbasis LSTM maupun GRU (Fangzong & Nishter, 2024).

Selain itu, penyelarasan resolusi waktu dan pembentukan *sliding window* penting agar model belajar dari urutan yang konsisten dan merepresentasikan ketergantungan antartitik waktu. Praktik yang sering digunakan mencakup *resampling* ke interval jam atau menit tunggal, sinkronisasi variabel eksternal seperti cuaca, serta pembuatan pasangan input output berbasis jendela untuk pelatihan berurutan. Penelitian terkini pada beban listrik regional menunjukkan alur pra pemrosesan tersebut berdampak langsung pada stabilitas metrik seperti MAPE dan RMSE (Widianto, Aditya, & Aditya, 2024).

## 2.8 CNN-LSTM

Convolutional Neural Network dan Long Short-Term Memory atau CNN-LSTM merupakan arsitektur deep learning yang menggabungkan kemampuan ekstraksi fitur dari CNN dengan kemampuan pemodelan ketergantungan temporal dari LSTM. Kombinasi kedua model ini banyak digunakan pada analisis data deret waktu (*time series*) karena mampu menangkap pola lokal sekaligus hubungan jangka panjang antar data.

Pada arsitektur ini, CNN berperan dalam mengekstraksi fitur lokal dari data input melalui proses konvolusi. Proses ini memungkinkan model mengenali pola tertentu yang berulang pada jendela waktu tertentu, seperti fluktuasi konsumsi listrik dalam periode harian atau mingguan. Hasil ekstraksi fitur tersebut kemudian diteruskan ke lapisan LSTM yang berfungsi untuk mempelajari ketergantungan temporal pada data deret waktu sehingga hubungan antar nilai pada waktu sebelumnya dapat digunakan untuk memprediksi nilai pada waktu berikutnya.

Pendekatan CNN-LSTM banyak digunakan dalam penelitian peramalan beban listrik karena mampu meningkatkan akurasi prediksi dibandingkan model yang hanya menggunakan satu arsitektur saja. Studi oleh Guo et al. (2025) menunjukkan bahwa kombinasi CNN dan LSTM mampu meningkatkan kemampuan model dalam mempelajari pola konsumsi energi yang kompleks pada sistem kelistrikan.

Dalam konteks analisis konsumsi listrik rumah tangga, model CNN-LSTM dapat digunakan untuk memprediksi nilai konsumsi listrik berdasarkan data historis yang tersedia. Hasil prediksi tersebut kemudian dapat dibandingkan dengan nilai konsumsi aktual untuk mengetahui adanya penyimpangan pada pola penggunaan energi. Apabila selisih antara nilai prediksi dan nilai aktual melebihi ambang batas tertentu, maka kondisi tersebut dapat dikategorikan sebagai anomali dalam konsumsi listrik.

Dengan demikian, penggunaan model CNN-LSTM tidak hanya bermanfaat untuk melakukan prediksi konsumsi listrik, tetapi juga dapat

mendukung proses deteksi anomali berdasarkan perbedaan antara nilai prediksi dan nilai aktual pada data konsumsi listrik.

## 2.9 Deteksi Anomali

Deteksi anomali merupakan proses untuk mengidentifikasi data atau pola yang menyimpang secara signifikan dari perilaku normal suatu sistem. Dalam konteks konsumsi listrik, anomali dapat berupa lonjakan atau penurunan penggunaan energi yang tidak sesuai dengan pola konsumsi biasanya. Anomali tersebut dapat disebabkan oleh berbagai faktor, seperti kerusakan perangkat listrik, kesalahan pengukuran, ataupun penggunaan energi yang tidak wajar. Penelitian pada sistem kelistrikan menunjukkan bahwa identifikasi anomali pada data konsumsi listrik dapat membantu meningkatkan akurasi pemantauan energi serta mengurangi potensi kerugian akibat kesalahan pencatatan atau gangguan sistem (Koerniawan et al., 2024).

Secara umum, anomali pada data deret waktu dapat dikategorikan menjadi tiga jenis utama, yaitu *point anomaly*, *contextual anomaly*, dan *collective anomaly*. *Point anomaly* terjadi ketika suatu nilai data berbeda secara signifikan dibandingkan nilai di sekitarnya. *Contextual anomaly* muncul ketika suatu nilai dianggap normal dalam satu konteks tetapi menjadi tidak normal dalam konteks lain, misalnya konsumsi listrik yang tinggi pada waktu yang biasanya memiliki penggunaan energi rendah. Sementara itu, *collective anomaly* merupakan sekumpulan data yang secara bersama-sama membentuk pola penyimpangan dalam interval waktu tertentu.

Dalam analisis konsumsi listrik berbasis machine learning, salah satu pendekatan yang umum digunakan untuk mendeteksi anomali adalah metode berbasis prediksi. Pendekatan ini dilakukan dengan membangun model prediksi menggunakan data historis konsumsi listrik untuk memperkirakan nilai penggunaan energi pada waktu tertentu. Selisih antara nilai prediksi dan nilai aktual kemudian dihitung sebagai *residual error*. Apabila nilai residual tersebut melebihi ambang batas tertentu, maka kondisi tersebut dapat dikategorikan sebagai anomali dalam konsumsi listrik. Pendekatan ini banyak

digunakan dalam analisis data energi karena mampu mengidentifikasi penyimpangan pola konsumsi secara lebih adaptif (Irwansyah et al., 2023).

Model deep learning seperti CNN-LSTM dapat digunakan untuk menghasilkan prediksi konsumsi listrik yang akurat pada data deret waktu. Dengan memanfaatkan hasil prediksi tersebut, sistem dapat mengidentifikasi penyimpangan pola konsumsi listrik secara otomatis melalui analisis residual antara nilai prediksi dan nilai aktual. Integrasi antara sistem pemantauan energi dan metode deteksi anomali berbasis machine learning juga telah dilaporkan efektif dalam mengidentifikasi penyimpangan penggunaan energi pada lingkungan hunian (Yusuf et al., 2025)

Evaluasi kinerja deteksi anomali umumnya dilakukan menggunakan metrik klasifikasi seperti *precision*, *recall*, dan *F1-score*. Metrik tersebut digunakan untuk mengukur kemampuan model dalam mengidentifikasi anomali secara tepat serta meminimalkan kesalahan deteksi pada data konsumsi listrik.

### **2.10 Kerangka Pemikiran**

Kerangka pemikiran dalam penelitian ini menggambarkan alur konseptual yang menjelaskan bagaimana data konsumsi listrik diolah hingga menghasilkan prediksi dan deteksi anomali. Penelitian ini menggunakan data historis konsumsi listrik rumah tangga yang diperoleh dari UCI Machine Learning Repository. Dataset tersebut memuat berbagai parameter kelistrikan seperti daya aktif, daya reaktif, tegangan, arus, serta sub-metering yang mencerminkan penggunaan energi pada beberapa area dalam rumah. Data historis tersebut kemudian digunakan sebagai dasar untuk membangun model prediksi konsumsi listrik berbasis machine learning.

Tahap awal penelitian dimulai dengan proses pra-pemrosesan data (*data preprocessing*) yang meliputi pembersihan data, penanganan nilai yang hilang, normalisasi data, serta transformasi dataset ke dalam format deret waktu yang sesuai untuk proses pelatihan model. Tahap ini penting dilakukan untuk memastikan kualitas data yang digunakan dalam pelatihan model

sehingga mampu menghasilkan prediksi yang lebih akurat (Jain & Gupta, 2024)

Selanjutnya, data yang telah diproses digunakan sebagai input dalam model deep learning CNN-LSTM. Pada arsitektur ini, lapisan Convolutional Neural Network (CNN) digunakan untuk mengekstraksi pola lokal dari data konsumsi listrik, sedangkan Long Short-Term Memory (LSTM) digunakan untuk mempelajari ketergantungan temporal pada data deret waktu. Kombinasi kedua arsitektur ini memungkinkan model untuk mempelajari pola konsumsi listrik secara lebih efektif sehingga dapat menghasilkan prediksi yang lebih akurat (Guo et al., 2025)

Hasil prediksi yang dihasilkan oleh model CNN-LSTM kemudian dibandingkan dengan nilai konsumsi listrik aktual untuk menghitung selisih atau *residual error*. Nilai residual tersebut digunakan sebagai dasar dalam proses deteksi anomali. Apabila selisih antara nilai prediksi dan nilai aktual melebihi ambang batas tertentu, maka kondisi tersebut dapat dikategorikan sebagai anomali dalam konsumsi listrik. Pendekatan ini memungkinkan sistem untuk mengidentifikasi pola penggunaan energi yang tidak normal secara otomatis (Irwansyah et al., 2023).

Kinerja model prediksi dievaluasi menggunakan metrik kesalahan seperti *Mean Absolute Error* (MAE) dan *Root Mean Square Error* (RMSE), sedangkan kinerja deteksi anomali dievaluasi menggunakan metrik klasifikasi seperti *precision*, *recall*, dan *F1-score*. Melalui proses tersebut, penelitian ini diharapkan mampu menghasilkan model yang dapat memprediksi konsumsi listrik rumah tangga secara akurat serta mendeteksi anomali penggunaan energi secara efektif.

## **BAB III**

### **METODE PENELITIAN**

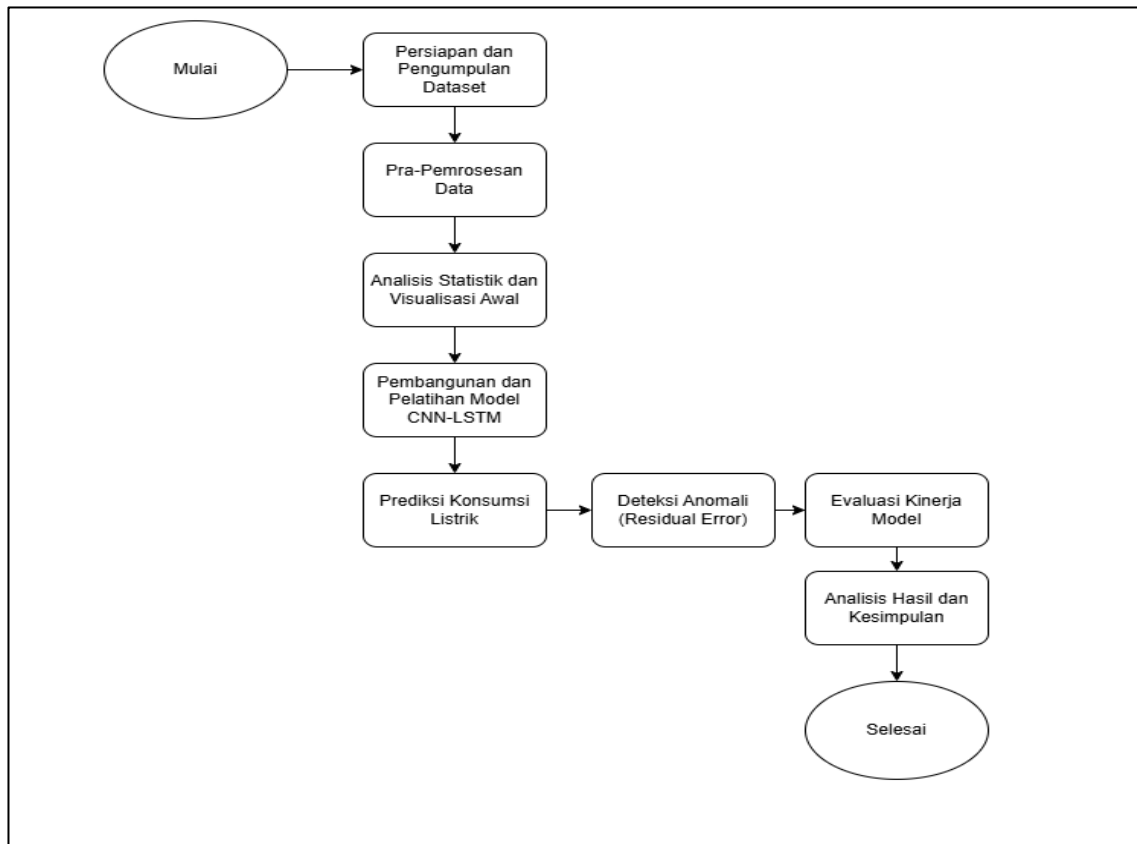
#### **3.1 Metode Penelitian**

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen yang bertujuan untuk membangun dan mengevaluasi model deep learning dalam memprediksi konsumsi listrik serta mendeteksi anomali berdasarkan data historis. Pendekatan eksperimen dilakukan dengan mengimplementasikan algoritma machine learning menggunakan bahasa pemrograman Python melalui lingkungan notebook (Jupyter Notebook atau Google Colaboratory).

Proses penelitian dilakukan secara sistematis mulai dari pengumpulan data, pra-pemrosesan, pembentukan model, pelatihan, evaluasi, hingga analisis hasil deteksi anomali. Model yang digunakan dalam penelitian ini adalah arsitektur deep learning berbasis Long Short-Term Memory (LSTM) atau kombinasi CNN-LSTM, yang dirancang khusus untuk menangani data deret waktu (time series).

Alur penelitian dirancang secara terstruktur mulai dari persiapan data hingga penarikan kesimpulan. Tahapan-tahapan tersebut digambarkan secara rinci dalam diagram pada Gambar 3.1 berikut:

A R - R A N I R Y



Gambar 3. 1 Alur Penelitian

### 3.2 Tahapan penelitian

Tahapan penelitian terdiri dari tiga fase utama, yaitu pengumpulan dan pengelolaan data, pengembangan dan evaluasi model, serta analisis hasil deteksi anomali. Setiap tahapan dirancang agar sesuai dengan implementasi pada Python Notebook yang digunakan dalam penelitian.

#### 3.2.1 Pengumpulan dan Pengolahan Data

Tahap awal penelitian ini bertujuan memperoleh dan menyiapkan data konsumsi listrik yang akan digunakan untuk membangun model prediksi dan deteksi anomali.

##### 3.2.1.1 Pengumpulan Data

Data yang digunakan merupakan dataset sekunder dari UCI Machine Learning Repository dengan nama *Individual Household Electric Power*

*Consumption*. Dataset ini berisi data konsumsi listrik rumah tangga dengan interval waktu per menit selama periode empat tahun.

Data terdiri dari beberapa atribut utama seperti Global Active Power, Voltage, Global Intensity, serta sub-metering. Dataset ini dipilih karena memiliki resolusi tinggi dan sering digunakan sebagai benchmark dalam penelitian prediksi energi berbasis machine learning.

### 3.2.1.2 Pra-Pemrosesan Data (*Data Preprocessing*)

Tahap pra-pemrosesan data dilakukan untuk memastikan kualitas data sebelum digunakan dalam proses pelatihan model. Proses ini dilakukan menggunakan Python dengan beberapa langkah sebagai berikut:

- 1) Pembersihan data dilakukan dengan menghapus nilai yang hilang (*missing values*) menggunakan metode penghapusan baris (*dropna*), serta menghilangkan data duplikat yang dapat memengaruhi hasil pelatihan model. Data yang tidak mengganggu proses pembelajaran model.
- 2) Konversi Tipe Data: Dilakukan dengan menggabungkan atribut tanggal (*Date*) dan waktu (*Time*) menjadi satu kolom bertipe *datetime*. Kolom ini kemudian dijadikan sebagai indeks data sehingga dataset dapat diproses sebagai data deret waktu (*time series*).
- 3) Pemilihan fitur dilakukan dengan memilih atribut yang relevan terhadap konsumsi listrik, seperti *Global Active Power* sebagai target utama, serta beberapa variabel pendukung seperti *Voltage* dan *Global Intensity*.
- 4) Normalisasi data: Dilakukan menggunakan metode *Min-Max Scaling* untuk mengubah rentang nilai data menjadi skala antara 0 hingga 1. Proses ini penting untuk meningkatkan stabilitas dan kecepatan konvergensi model deep learning.
- 5) Transformasi Data: Menjadi bentuk supervised learning dilakukan menggunakan teknik sliding window. Dalam proses ini, sejumlah data historis dalam periode tertentu (*time steps*) digunakan sebagai input

untuk memprediksi nilai pada waktu berikutnya. Teknik ini memungkinkan model memahami pola temporal dari data konsumsi listrik.

### 3.2.1.3 Exploratory Data Analysis (EDA)

Analisis eksploratif dilakukan untuk memahami karakteristik data sebelum dilakukan pemodelan. Tahapan meliputi:

- 1) Visualisasi data deret waktu untuk melihat pola konsumsi listrik berdasarkan waktu, baik dalam skala harian maupun bulanan.
- 2) Analisis distribusi data untuk memahami sebaran nilai konsumsi listrik serta mengidentifikasi adanya nilai ekstrem.
- 3) Analisis korelasi antar variabel untuk mengetahui hubungan antara fitur-fitur dalam dataset.
- 4) Identifikasi pola musiman dan tren yang muncul dalam data konsumsi listrik.
- 5) Deteksi awal anomali secara visual berdasarkan lonjakan atau penurunan konsumsi listrik yang tidak wajar.

### 3.2.2 Pengembangan dan Evaluasi Model Machine Learning

Fase ini merupakan inti penelitian yang berfokus pada pembangunan model machine learning untuk melakukan prediksi serta mendeteksi anomali konsumsi listrik.

#### 3.2.2.1 Arsitektur Model

Model yang digunakan dalam penelitian ini adalah model deep learning berbasis LSTM atau CNN-LSTM yang dirancang untuk menangani data deret waktu. LSTM digunakan karena memiliki kemampuan dalam menangkap ketergantungan jangka panjang pada data temporal.

Arsitektur model terdiri dari beberapa lapisan, yaitu:

- 1) Layer LSTM yang berfungsi untuk mempelajari pola temporal dari data historis konsumsi listrik.
- 2) Layer Dropout yang digunakan untuk mengurangi overfitting dengan cara menonaktifkan sebagian neuron selama proses pelatihan.

- 3) Dense layer yang berfungsi sebagai lapisan output untuk menghasilkan nilai prediksi konsumsi listrik.

Model menggunakan fungsi aktivasi linear pada layer output karena permasalahan yang dihadapi merupakan masalah regresi.

#### 3.2.2.2 Pembagian Dataset

Dataset dibagi menjadi dua bagian, yaitu:

- 1) Data Latih (Training Set): 80% dari total data untuk melatih model agar mengenali pola konsumsi listrik normal.
- 2) Data Uji (Testing Set): 20% sisanya digunakan untuk menguji kemampuan model dalam memprediksi atau mengenali anomali pada data baru.

Pembagian data dilakukan tanpa pengacakan (*shuffle*) untuk mempertahankan urutan waktu pada data deret waktu. Hal ini penting agar model tidak mendapatkan informasi masa depan saat proses pelatihan.

#### 3.2.2.3 Pelatihan Model

Proses pelatihan model dilakukan menggunakan parameter sebagai berikut:

- 1) Fungsi loss yang digunakan adalah Mean Squared Error (MSE) untuk mengukur kesalahan antara nilai prediksi dan nilai actual.
- 2) Optimizer yang digunakan adalah Adam karena memiliki performa yang baik dalam proses optimasi model deep learning.
- 3) Jumlah epoch ditentukan berdasarkan eksperimen untuk mendapatkan performa optimal.
- 4) Batch size digunakan untuk menentukan jumlah data yang diproses dalam satu iterasi pelatihan.

#### 3.2.2.4 Evaluasi Model

Evaluasi model dilakukan untuk mengukur tingkat akurasi prediksi yang dihasilkan. Metrik evaluasi yang digunakan meliputi:

- 1) Mean Absolute Error (MAE) untuk mengukur rata-rata kesalahan absolut antara nilai prediksi dan nilai actual.
- 2) Root Mean Square Error (RMSE) untuk mengukur kesalahan prediksi dengan memberikan penalti terhadap kesalahan yang besar

### 3.2.3 Prediksi

Tahap prediksi merupakan komponen inti dalam penelitian ini, di mana model dilatih untuk memahami karakteristik penggunaan listrik normal dan memproyeksikan nilai konsumsi di masa depan. Proses ini dilakukan dengan urutan teknis sebagai berikut:

- 1) Pembentukan jendela waktu (*sliding window*) data historis dari *UCI Machine Learning Repository* ditransformasi menjadi format *supervised learning* menggunakan teknik *sliding window*. Dalam penelitian ini, digunakan jendela waktu sepanjang 12 titik data (setara dengan 1 jam pengamatan) sebagai input untuk memprediksi nilai pada waktu berikutnya.
- 2) Ekstraksi Fitur Spasial (CNN) lapisan *Convolutional Neural Network* (CNN) berfungsi untuk memproses jendela sekuens guna mengekstraksi pola lokal, seperti korelasi antar variabel kelistrikan dalam periode singkat.
- 3) Pemodelan Temporal (LSTM) hasil ekstraksi fitur kemudian diteruskan ke lapisan *Long Short-Term Memory* (LSTM) yang bertugas mempelajari ketergantungan temporal jangka panjang. Hal ini memungkinkan model memahami tren penggunaan energi harian dan mingguan untuk menghasilkan nilai prediksi konsumsi listrik pada langkah waktu berikutnya.
- 4) Output Prediksi luaran dari model berupa nilai kontinu yang merepresentasikan estimasi konsumsi daya (seperti *Global Active Power* atau *Apparent Power*) yang dianggap sebagai profil beban wajar berdasarkan pola historis yang telah dipelajari.

### 3.2.4 Deteksi Anomali

Fase ini berfokus pada penafsiran hasil keluaran model dan penerapan temuan untuk konteks rumah tangga.

### 3.2.3.1 Metode Deteksi Anomali

Deteksi anomali dilakukan menggunakan pendekatan berbasis residual error. Residual error merupakan selisih antara nilai aktual dengan nilai prediksi yang dihasilkan oleh model.

- 1) Menghitung nilai error sebagai selisih absolut antara nilai actual dan nilai prediksi.
- 2) Menentukan nilai ambang batas (*threshold*) berdasarkan distribusi error, misalnya menggunakan rata-rata ditambah tiga kali standar deviasi atau menggunakan persentil tertentu.
- 3) Mengklasifikasikan data sebagai anomali apabila nilai error melebihi threshold yang telah ditentukan.

### 3.2.3.2 Visualisasi Anomali

Visualisasi dilakukan dalam bentuk grafik deret waktu yang menunjukkan:

- 1) Grafik konsumsi listrik aktual ,
- 2) Grafik hasil prediksi model,
- 3) titik-titik anomali yang ditandai pada grafik sebagai nilai yang menyimpang.

Dengan cara ini, anomali dapat dilihat secara visual dan lebih mudah diinterpretasikan.

### 3.2.3.3 Evaluasi Deteksi Anomali

Evaluasi deteksi anomali dilakukan berdasarkan distribusi error dan visualisasi hasil. Karena dataset tidak memiliki label anomali secara eksplisit, evaluasi dilakukan secara tidak langsung melalui analisis pola penyimpangan.

Jika tersedia label, maka evaluasi dapat dilakukan menggunakan metrik seperti precision, recall, dan F1-score untuk mengukur kemampuan model dalam mendeteksi anomali secara akurat.

Ini adalah rumus standar yang digunakan oleh `sklearn.metrics.classification_report` untuk mengevaluasi apakah model anda berhasil atau mengukur kinerja model.

1) Accuracy (Akurasi)

Seberapa sering AI benar secara keseluruhan (menjawab normal saat normal, menjawab anomali saat anomali).

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

2) Precision (Presisi)

Dari semua kali alarm AI berbunyi, berapa kali itu benar-benar kebakaran/korsleting? (Metrik ini mengukur tingkat "Alarm Palsu"/*False Positive*).

$$Precision = \frac{TP}{TP + FP}$$

3) Recall (Sensitivitas)

Dari semua kebakaran/korsleting yang *sebenarnya terjadi*, berapa persen yang berhasil ditangkap oleh AI? (Ini adalah metrik paling penting dalam sistem keselamatan hidup).

$$Recall = \frac{TP}{TP + FN}$$

4) F1-Score

Nilai harmonik tengah antara Presisi dan Recall. Sering digunakan jika dataset sangat tidak seimbang (misal: 2000 data normal, hanya 3 anomali).

$$F_1 = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

Di mana (untuk konteks Deteksi Anomali):

TP (True Positive): Anomali aktual yang ditebak "Anomali" oleh AI (Sukses menangkap malapetaka).

TN (True Negative): Kondisi normal yang ditebak "Normal" oleh AI (Aman).

FP (False Positive): Kondisi normal yang ditebak "Anomali" oleh AI (Alarm Palsu / Gangguan).

FN (False Negative): Anomali aktual yang ditebak "Normal" oleh AI (Bahaya Kematian / Rumah Terbakar).

### 3.3 Sumber dan Deskripsi Dataset

Pada penelitian ini, data memegang peranan penting sebagai dasar dalam proses analisis, pelatihan model, serta evaluasi kinerja algoritma yang digunakan. Oleh karena itu, pada subbab ini akan dijelaskan secara rinci mengenai sumber data yang digunakan, struktur dan deskripsi dataset, karakteristik statistik umum, serta kelebihan dan keterbatasan data yang dimiliki.

Selain itu, dijabarkan pula alasan pemilihan dataset terhadap konteks penelitian, untuk menunjukkan relevansi dan kesesuaian antara data yang digunakan dengan tujuan penelitian, yaitu penerapan algoritma *machine learning* dalam memprediksi serta mendeteksi anomali konsumsi listrik pada rumah kos mahasiswa.

#### 3.3.1 Sumber Data

Data yang digunakan dalam penelitian ini merupakan data sekunder yang diambil dari UCI Machine Learning Repository, dengan nama dataset "Individual Household Electric Power Consumption." Dataset ini berisi catatan konsumsi daya listrik rumah tangga di Paris, Prancis, selama periode Desember 2006 hingga November 2010. Data dikumpulkan oleh peralatan pengukur daya otomatis dengan interval pencatatan setiap satu menit, menghasilkan lebih dari dua juta baris data.

Pemilihan dataset ini didasarkan pada beberapa alasan berikut:

- 1) **Kelengkapan Atribut:** Dataset mencakup variabel-variabel penting seperti daya aktif, daya reaktif, tegangan, arus, dan tiga sub-meter area rumah.

- 2) **Resolusi Waktu Tinggi:** Data terekam setiap menit selama empat tahun, memungkinkan analisis pola dan deteksi anomali dengan akurasi tinggi.
- 3) **Relevansi Penelitian:** Pola konsumsi listrik bersifat teknis dan universal, sehingga dataset tetap relevan digunakan meskipun berasal dari wilayah Eropa.
- 4) **Ketersediaan Publik dan Validasi Akademik:** Dataset telah digunakan di berbagai penelitian internasional sebagai *benchmark dataset* untuk prediksi dan deteksi anomali energi.

### 3.3.2 Deskripsi Dataset

Dataset terdiri dari 9 atribut utama yang mewakili parameter kelistrikan rumah tangga. Tabel 3.1 menjelaskan masing-masing atribut.

Tabel 3.1 Deskripsi Atribut Dataset

No	Nama Atribut	Deskripsi	Satuan	Tipe Data
1	Date	Tanggal pencatatan data	dd/mm/yyyy	String
2	Time	Waktu pencatatan data	hh:mm:ss	String
3	Global Active Power	Total daya aktif yang dikonsumsi	Kilowatt (kW)	Float
4	Global Reactive Power	Daya reaktif yang digunakan	Kilowatt (kW)	Float
5	Voltage	Tegangan listrik	Volt (V)	Float
6	Global Intensity	Arus total yang mengalir	Ampere (A)	Float
7	Sub metering 1	Area dapur bersama	Watt-hour (Wh)	loat
8	Sub metering 2	area umum dengan mesin elektronik	Watt-hour (Wh)	Float
9	Sub metering 3	Perangkat pendingin (kipas, AC,)	Watt-hour (Wh)	Float

Dataset ini mencakup variabel-variabel fisik kelistrikan yang saling berkaitan. Hubungan antar variabel tersebut didefinisikan berdasarkan prinsip fisika kelistrikan sebagai berikut:

1. Daya Reaktif (Q): Daya reaktif (dalam satuan) adalah daya yang hilang atau bolak-balik pada beban induktif (seperti kipas angin) atau beban dengan *Swiath-Mode Power Supply* (SMPS, seperti *charger*).

$$Q = P \times \tan(\arccos(PF))$$

Dimana:

$P$  = Daya Aktif (*Real Power*) dalam Watt (W)

$PF$  = *Power Factor* (Faktor Daya), berkisar antara 0.0 hingga 1.0.

2. Daya Semu (S): Daya semu (dalam satuan VA) adalah total daya aktual yang ditarik dari jaringan PLN. Ini adalah kombinasi vektor dari Daya Aktif ( $P$ ) dan Daya Reaktif ( $Q$ ). Ini adalah daya yang menentukan apakah MCB Anda akan "jepret" atau tidak.

$$S = \sqrt{P^2 + Q^2}$$

Di mana:

$P$  = Total Daya Aktif (W)

$Q$  = Total Daya Reaktif (VAR)

3. Faktor Daya Keseluruhan ( $PF_{overall}$ ): Menghitung seberapa efisiensi total penggunaan daya di kos. Jika semua orang menyetrika (beban resistif murni), PF akan mendeteksi 1.0.

$$PF_{overall} = \frac{P_{total}}{S_{total}}$$

4. Arus RMS ( $I_{RMS}$ ): Arus yang mengalir pada kabel (dalam Ampere).

$$I_{RMS} = \frac{S_{Total}}{V_{RMS}}$$

Di mana:

$V_{RMS}$  = Tegangan aktual jaringan (Voltage).

5. Simulasi Tegangan Jatuh (Voltage Sag): Mensimulasikan bagaimana tegangan jaringan PLN di Banda Aceh turun saat beban kos sangat tinggi.

$$V_{RMS\_actual} = V_{nominal} - \left( \frac{P_{total}}{1000} \times 1.5 \right)$$

(Formula ini mengasumsikan penurunan tegangan sebesar 1.5 Volt untuk setiap 1000 Watt beban).

### 3.3.3 Statistik Umum Dataset

Analisis statistik deskriptif digunakan untuk memahami karakteristik awal dari data numerik sebelum dilakukan pelatihan model. Tabel 3.2 berikut menampilkan ringkasan statistik dataset.

Tabel 3. 2 Statistik Dataset

Atribut	Minimum	Maksimum	Rata-rata(V)	Simpangan Baku
Global_active_power (kW)	0.076	11.122	1.091	1.056
Global_reactive_power (kW)	0.000	1.390	123	113
Voltage (V)	223.200	254.150	240.840	3.240
Global_intensity (A)	0.400	48.400	4.630	4.474
Sub_metering_1 (Wh)	0.000	88.000	1.122	3.530
Sub_metering_2 (Wh)	0.000	80.000	1.299	4.203
Sub_metering_3 (Wh)	0.000	31.000	6.456	8.507

Berdasarkan tabel 3.2 di atas, terlihat bahwa konsumsi daya aktif rata-rata sebesar 1.09 kW, dengan tegangan rata-rata sekitar 240 V dan variasi arus yang cukup lebar. Hal ini menunjukkan bahwa dataset memiliki pola konsumsi listrik realistis dan bervariasi, sehingga layak digunakan untuk pelatihan model *machine learning*.

### 3.3.4 Kelebihan dan Keterbatasan Dataset

Setiap dataset yang digunakan dalam penelitian tentu memiliki karakteristik tersendiri yang dapat menjadi keunggulan maupun keterbatasan dalam penerapan metode analisis. Oleh karena itu, pada bagian ini akan dijelaskan kelebihan dan keterbatasan dari dataset *Individual Household Electric Power Consumption* yang digunakan dalam penelitian ini.

Pemahaman terhadap aspek-aspek tersebut penting agar peneliti dapat menilai sejauh mana data ini mampu mendukung proses prediksi dan deteksi anomali konsumsi listrik, serta mengidentifikasi potensi tantangan yang perlu diantisipasi selama tahap pengolahan dan pemodelan data.

Kelebihan:

- 1) Resolusi waktu tinggi (1 menit) yang memungkinkan deteksi perubahan daya dalam skala detail.
- 2) Atribut lengkap yang mendukung analisis multivariat dan pemodelan kompleks.
- 3) Format data mudah diolah dan kompatibel dengan berbagai pustaka *machine learning*.
- 4) Telah digunakan secara luas sebagai *benchmark dataset* dalam penelitian energi.

Kekurangan:

- 1) Data berasal dari rumah tangga di Eropa, sehingga tidak sepenuhnya mencerminkan pola konsumsi di Indonesia.
- 2) Tidak memuat variabel perilaku pengguna (seperti jumlah penghuni atau jenis alat elektronik).
- 3) Ukuran data besar memerlukan kapasitas komputasi yang cukup tinggi.

### 3.3.5 Alasan Penggunaan Dataset

Pemilihan dataset *Individual Household Electric Power Consumption* dari *UCI Machine Learning Repository* didasarkan pada relevansi

karakteristik data dengan objek penelitian, yaitu sektor rumah tangga. Beberapa alasan utama penggunaan dataset ini adalah sebagai berikut:

- 1) **Representasi Aktivitas Rumah Tangga:** Dataset ini merekam konsumsi energi riil dari sebuah hunian keluarga tunggal, mencakup penggunaan peralatan elektronik domestik seperti mesin cuci, pemanas air, pendingin ruangan (AC), dan peralatan dapur. Profil beban ini sangat sesuai dengan karakteristik konsumsi listrik rumah tangga di Indonesia yang menjadi fokus penelitian.
- 2) **Resolusi Waktu Tinggi:** Data tersedia dengan resolusi satu menit (*one-minute resolution*), yang memungkinkan model *Deep Learning* untuk mempelajari pola fluktuasi beban listrik yang detail dan mendadak, yang tidak dapat ditangkap oleh data tagihan bulanan biasa.
- 3) **Durasi Data Panjang:** Dengan rentang waktu perekaman selama 4 tahun (2006–2010) dan total lebih dari 2 juta baris data, dataset ini menyediakan variasi pola musiman (harian, mingguan, dan tahunan) yang sangat memadai untuk melatih model CNN-LSTM agar menghasilkan prediksi yang akurat dan robust.

### 3.4 Alat dan Bahan

Pada penelitian ini digunakan beberapa alat dan bahan yang berfungsi untuk mendukung proses pengumpulan, pengolahan, analisis data, serta implementasi algoritma *machine learning* yang digunakan dalam prediksi dan deteksi anomali konsumsi listrik. Adapun alat dan bahan yang digunakan terdiri atas perangkat keras (*hardware*) dan perangkat lunak (*software*) yang dijelaskan sebagai berikut.

#### 3.4.1 Perangkat Keras (*Hardware*)

Perangkat keras yang digunakan untuk penelitian ini berupa satu unit laptop Lenovo ThinkPad T470. Adapun spesifikasi perangkat keras yang digunakan dalam penelitian ini akan disesuaikan dengan perangkat yang tersedia pada saat implementasi, dengan spesifikasi minimum seperti pada tabel 3.3 dibawah ini:

Tabel 3. 3 Hardware

Komponen	Spesifikasi
<i>Processor</i>	Intel® Core™ i5-7200U
<i>RAM</i>	8 GB DDR4 2123 MHz
<i>Storage</i>	256GB SSD SATA III
<i>Graphic Card</i>	Intel® HD Graphics 620 (Integrated)

### 3.4.2 Perangkat Lunak (Software)

Perangkat lunak digunakan untuk pengolahan data, eksplorasi statistik, pembuatan model, dan visualisasi hasil analisis. Adapun perangkat lunak yang digunakan dalam penelitian ini bisa dilihat pada tabel 3.4 berikut:

Tabel 3. 4 Software

Perangkat Lunak	Version
Python	3.12.4
Google Colaboratory	<i>Lastest Version</i>
Pandas	2.2.3
NumPy	1.26.4
Matplotlib	3.9.2
Seaborn	0.13.2
Sickit-Learn	1.5.2

### 3.5 Tempat Penelitian

Penelitian ini dilaksanakan di Laboratorium Komputer Fakultas Sains dan Teknologi, Universitas Islam Negeri Ar-Raniry Banda Aceh. Laboratorium ini dipilih karena memiliki perangkat komputer dengan spesifikasi yang memadai serta didukung jaringan internet yang stabil. Kondisi tersebut memberikan lingkungan yang optimal untuk proses pengolahan data, pelatihan model *machine learning*, serta pengujian sistem berbasis analisis anomali konsumsi listrik.

### 3.6 Waktu Penelitian

Pelaksanaan penelitian ini direncanakan berlangsung selama 4 bulan dimulai dari September hingga akhir Desember 2025. Berikut adalah tabel proses pembuatan penelitian ini.

Secara rinci, alokasi waktu yang dibutuhkan untuk menyelesaikan setiap bab dalam penulisan tugas akhir serta tahapan seminar hingga sidang skripsi bisa dilihat pada tabel 3.5.

*Tabel 3. 5 Proses Pembuatan Tugas Akhir*

	September	Oktober	November	April
BAB I: Latar belakang, rumusan masalah, Tujuan, Manfaat, Batasan				
BAB II: Tjauan Pustaka (Penelitian terdahulu, AI, Machine Learning, CNN-LSTM, Deteksi Anomali)				
BAB III: Metode penelitian (Dataset, Preprocessing, Model, Evaluasi)				
SEMINAR PROPOSAL				
BAB IV: Hasil dan Pembahasan (Implementasi, Evaluasi, Analisis)				
BAB V: Kesimpulan dan Saran				
SIDANG SKRIPSI				

## BAB IV

### HASIL DAN PEMBAHASAN

#### 4.1 Pra-pemrosesan Data (Data Preprocessing)

Tahap persiapan atau pra-pemrosesan data (*data preprocessing*) merupakan tahapan fundamental dalam penelitian *machine learning* untuk memastikan bahwa data mentah telah distandardisasi dan siap dipelajari oleh model secara optimal. Data historis kelistrikan yang digunakan dalam penelitian ini disimpan dalam format *Comma Separated Values* (CSV) dan dipartisi menjadi tiga himpunan bagian: data latih (*training set*) yang merepresentasikan observasi pada bulan Januari, data validasi (*validation set*), dan data uji (*testing set*) yang menggunakan data pada bulan Februari. Pembagian secara kronologis ini bertujuan untuk mengevaluasi kemampuan generalisasi model terhadap data baru (*unseen data*) dan mencegah terjadinya kondisi *overfitting*.

Secara struktural, dataset ini memuat beberapa atribut pengukuran parameter kelistrikan, di antaranya *Timestamp* (penanda waktu pengamatan), *V\_RMS* (tegangan efektif), *I\_RMS* (arus efektif), *Real\_Power\_W* (daya aktif), *Apparent\_Power\_VA* (daya semu), *Power\_Factor* (faktor daya), dan *THD\_Percent* (*Total Harmonic Distortion*). Selain itu, terdapat kolom *Is\_Anomaly* dan *Anomaly\_Type* yang berfungsi sebagai label indikator. Untuk tahap pembangunan model, representasi fitur masukan (*input features*) dibatasi pada enam variabel numerik utama yang paling memengaruhi dinamika kelistrikan, yaitu *V\_RMS*, *I\_RMS*, *Real\_Power\_W*, *Apparent\_Power\_VA*, *Power\_Factor*, dan *THD\_Percent*.

Timestamp	V_RMS	I_RMS	Real_Power_W	Apparent_Power_VA	Power_Factor	THD_Percent	Is_Anomaly	Anomaly_Type
2026-02-08 00:00:00	218.06	3.172	596.0	691.7	0.862	11.56	1	None
2026-02-08 00:05:00	219.9	3.155	598.4	693.8	0.863	11.57	1	None
2026-02-08 00:10:00	219.15	3.651	718.9	800.0	0.899	10.9	1	None

Sebagai representasi konkret dari struktur data mentah yang diolah, berikut adalah contoh satu baris observasi yang diambil dari himpunan data uji:

2026-02-08 00:00:00, 218.06, 3.172, 596.0, 691.7, 0.862, 11.56, 1, none pada entri tersebut, pencatatan dilakukan pada tanggal 8 Februari 2026 pukul 00:00:00. 3.172

A, daya aktif (*Real\_Power\_W*) 596.0 W, daya semu (*Apparent\_Power\_VA*) 691.7 VA, faktor daya (Power Factor) 0.862, dan distorsi harmonik total (*THD\_Percent*) sebesar 11.56%. Kolom *Is\_Anomaly* yang bernilai 1 mengindikasikan bahwa sistem berada pada kondisi operasional normal, sehingga kolom *Anomaly\_Type* bernilai None (tidak ada jenis gangguan). Variasi rentang nilai sangat timpang antar variabel pada data mentah inilah yang mengharuskan adanya tahapan prapemrosesan lebih lanjut.

#### 4.1.1 Normalisasi Fitur menggunakan StandardScaler

Dataset kelistrikan memiliki karakteristik multivariat dengan rentang nilai yang sangat timpang. Sebagai contoh, variabel Tegangan (*Voltage*) berada pada rentang di atas 220 Volt, sedangkan variabel Arus (*Global Intensity*) berada pada rentang satuan. Jika tidak dinormalisasi, variabel dengan rentang nilai besar akan mendominasi perhitungan bobot model.

Untuk mengatasi hal tersebut, diterapkan teknik normalisasi *StandardScaler* adalah metode yang melakukan Standardisasi (Z-Score Normalization) Proses ini mentransformasi distribusi setiap fitur secara independen sehingga memiliki nilai rata-rata ( $\mu$ ) sama dengan nol dan variansi ( $\sigma^2$ ) sama dengan satu, berdasarkan persamaan matematis:

$$z = \frac{(x - \mu)}{\sigma}$$

```
if is_train:
    scaler = StandardScaler()
    X_scaled = pd.DataFrame(scaler.fit_transform(X_raw), columns=FEATURES)
    return df, X_scaled, scaler
else:
    X_scaled = pd.DataFrame(scaler.transform(X_raw), columns=FEATURES)
    y_true = df['Is_Anomaly'] if 'Is_Anomaly' in df.columns else None
    return df, X_scaled, y_true
```

Pemisahan logika *fit\_transform* pada data latih hanya *transforms* pada data validasi/uji diimplementasikan secara ketat guna mencegah terjadinya kebocoran data (*data leakage*).

### 4.1.2 Transformasi Deret Waktu (Sliding Windows)

Model hibrida CNN-LSTM membutuhkan format masukan tiga dimensi. Oleh karena itu, data kelistrikan diubah menggunakan metode *sliding window* dengan parameter `TIME_STEPS = 12`. Karena data direkam dengan interval 5 menit, maka 12 titik data merepresentasikan observasi historis selama 1 jam.

```
def create_sequences(X, y=None, time_steps=TIME_STEPS):
    Xs, ys = [], []
    for i in range(len(X) - time_steps):
        Xs.append(X.iloc[i:(i + time_steps)].values)
        if y is not None:
            ys.append(y.iloc[i + time_steps])

    if y is not None:
        return np.array(Xs), np.array(ys)
    return np.array(Xs)

def load_and_preprocess(filepath, scaler=None, is_train=False):
    df = pd.read_csv(filepath)
    df['Timestamp'] = pd.to_datetime(df['Timestamp'])
    df = df.sort_values('Timestamp').reset_index(drop=True)
```

## 4.2 Arsitektur dan Pelatihan Model Hybrid CNN-LSTM Autoencoder

Penelitian ini menggunakan pendekatan *unsupervised learning* melalui arsitektur *Autoencoder* yang secara dirancang untuk merekonstruksi ulang pola kelistrikan yang wajar.

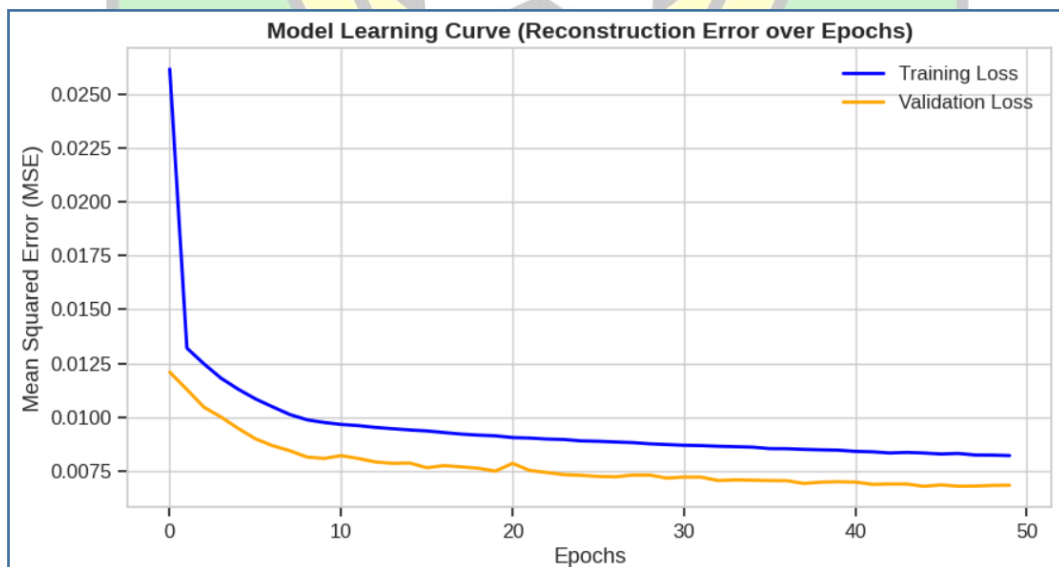
### 4.2.1 Arsitektur Jaringan

Struktur jaringan disusun secara simetris membentuk *Encoder-Decoder*. Konfigurasi arsitektur diimplementasikan menggunakan antarmuka pustaka Keras. Pada bagian Encoder, Conv1D bertugas memindai jendela sekuens untuk mengekstraksi pola lokal (misalnya korelasi turunnya daya secara tiba-tiba). Hasil ekstraksi tersebut kemudian diringkas oleh lapisan LSTM pertama menjadi vektor kompresi laten. Pada bagian Decoder, informasi kompresi tersebut dijabarkan kembali oleh LSTM kedua yang dipadukan dengan TimeDistributed(Dense) untuk kembali (merekonstruksi) 6 variabel kelistrikan ke dimensi aslinya.

#### 4.2.2 Proses Pelatihan (Model Training)

Proses pelatihan model dilakukan menggunakan fungsi optimasi Adam (*Adaptive Moment Estimation*) karena kemampuannya dalam memperbarui parameter bobot secara adaptif, dipandu dengan fungsi kerugian *Mean Squared Error* (*MSE*). Model ini dilatih 100 *epoch*.

```
early_stopping = callbacks.EarlyStopping(  
    monitor='val_loss',  
    patience=5,  
    restore_best_weights=True  
)  
  
history = model.fit(  
    X_train_seq, X_train_seq,  
    epochs=EPOCHS,  
    batch_size=BATCH_SIZE,  
    validation_data=(X_val_seq, X_val_seq),  
    callbacks=[early_stopping],  
    verbose=1  
)
```



Gambar 4.1 Kurva Konvergensi Training dan validation Loss

Berdasarkan riwayat pelatihan (learning curve) (Gambar 4.1), kurva validasi dan kurva pelatihan menunjukkan penurunan loss yang curam dan stabil pada epoch-epoch awal. Keberadaan instrumen callback *EarlyStopping* yang

memantau validasi loss berhasil berfungsi secara efektif untuk menghentikan proses pelatihan lebih awal sebelum model mengalami overfitting terhadap data latih.

### 4.3 Deteksi Anomali Berbasis Reconstruction Error

Deteksi anomali dieksekusi dengan mengukur tingkat ketidakmampuan model dalam merekonstruksi data baru yang belum pernah dipelajari sebelumnya (*testing set*).

#### 4.3.1 Kalkulasi Deviasi Maksimum (Maximun MAE)

Kesalahan dihitung menggunakan *Mean Absolute Error* (MAE). Evaluasi komputasi tidak menggunakan nilai rata-rata (`np.mean`), melainkan menggunakan nilai puncak (`np.max`) untuk setiap jendela waktu.

$$Loss_{max} = \max_j \left( \frac{1}{N_{Fitur}} \sum_{i=1}^{N_{fitur}} |y_{aktual_i} - y_{prediksi_i}| \right)$$

Di mana:

$max_j$  = Setiap langkah waktu (*time step*) dalam *window* (misal: 1 hingga 12).

$y_{aktual}$  = Nilai input asli.

$y_{prediksi}$  = Output rekonstruksi dari Autoencoder.

```
x_val_pred = model.predict(x_val_seq)
val_mae_loss = np.max(np.abs(x_val_pred - x_val_seq), axis=(1, 2))

x_test_pred = model.predict(x_test_seq)
test_mae_loss = np.max(np.abs(x_test_pred - x_test_seq), axis=(1, 2))
```

Pendekatan matematis ini sangat krusial. Penggunaan `np.max` memastikan bahwa sistem mendeteksi deviasi kesalahan paling ekstrem di dalam satu observasi. Jika terdapat lonjakan arus mendadak walau hanya berlangsung selama 1 langkah waktu, model akan tetap memicu kewaspadaan tinggi.

## 4.4 Prediksi Model

Untuk memastikan akurasi prediksi sebelum diintegrasikan ke dalam sistem deteksi anomali, kinerja model dievaluasi menggunakan metrik statistik berikut:

- 1) Mean Absolute Error (MAE) digunakan untuk mengukur rata-rata besarnya kesalahan absolut antara nilai konsumsi aktual dan hasil prediksi model. Nilai MAE yang rendah menunjukkan bahwa model mampu meniru pola konsumsi asli dengan sangat baik.
- 2) Root Mean Square Error (RMSE) digunakan untuk mengukur kesalahan prediksi dengan memberikan penalti yang lebih besar terhadap kesalahan yang signifikan. Metrik ini memastikan bahwa model tetap stabil dan tidak menghasilkan deviasi yang ekstrem pada kondisi operasional normal.

### 4.3.2 Penentuan Threshold

Ambang batas toleransi ditetapkan menggunakan pendekatan statistik empiris. Sistem mengambil nilai pada persentil ke-98 dari distribusi skor *loss* yang dihasilkan pada dataset validasi. Hasil rekonstruksi pada data uji kemudian dipetakan: apabila nilai kerugian maksimum (*test\_mae\_loss*) melewati garis ambang batas persentil tersebut, maka sistem mengklasifikasinya sebagai kondisi anomaly (-1), dan sebaliknya diklasifikasikan sebagai kondisi normal (1).

Formula untuk menentukan kapan alarm berbunyi. Dihitung menggunakan persentil dari error pada Validation Dataset (misal: Persentil ke-98).

$$\text{Threshold} = P_{98}(\text{Loss}_{\text{val}_{\text{max}}})$$

*Alarm dipicu JIKA:  $\text{Loss}_{\text{test}_{\text{max}}} > \text{Thresold}$*

```
THRESHOLD = np.percentile(val_mae_loss, 98)

print(f"Calculated Alarm Threshold: {THRESHOLD:.4f}")

# Map predictions: -1 for Anomaly, 1 for Normal
y_pred = np.where(test_mae_loss > THRESHOLD, -1, 1)
```

## 4.5 Evaluasi Model

Kinerja operasional arsitektur *Hybrid CNN-LSTM* dievaluasi secara komprehensif menggunakan metrik *classification report* dan *confusion matrix* pada himpunan data uji (2.016 baris data). Berdasarkan hasil evaluasi kuantitatif, model menunjukkan kemampuan diferensiasi yang sangat timpang antara kelas dominan dan kelas minoritas.

### 4.5.1 Analisis Matrik Klasifikasi

Laporan klasifikasi menunjukkan model memiliki pengenalan yang impresif terhadap pola kelistrikan wajar. Untuk label Normal (1), sistem membukukan *precision* sempurna di angka 1.00 dan tingkat *recall* sebesar 0.95.

Namun, model menunjukkan kegagalan mendasar dalam mendeteksi kejadian anomali aktual. Nilai *precision*, *recall*, dan F1-score seluruhnya berada pada angka absolut 0.00 untuk kelas Anomali (-1). Ketidakmampuan merespons ke-3 observasi anomali aktual ini secara akademis mengindikasikan bahwa deviasi rekonstruksi (MAE) yang dihasilkan oleh model saat mencerna sinyal anomali tidak cukup tinggi untuk melampaui batas *threshold* persentil ke-98.

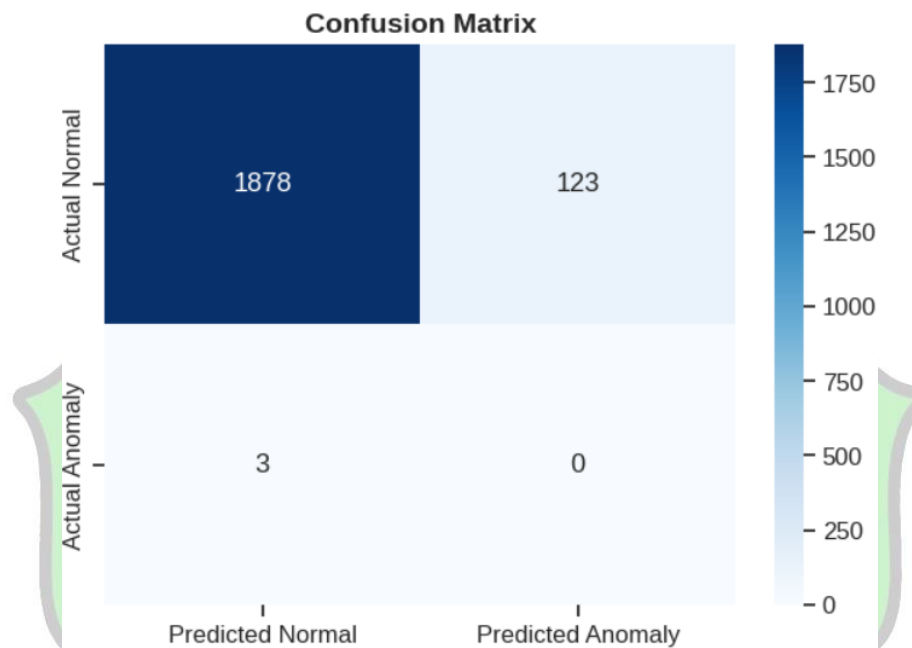
Tabel 3.6 Analisis Matriks Klasifikasi

	Precision	Recall	F1-score	Support
Anomaly (-1)	0.00	0.00	0.00	3
Normal (1)	1.00	0.94	0.97	2001
Accuracy			0.94	2004
Macro avg	0.50	0.47	0.48	2004
Weighted avg	1.00	0.94	0.97	2004

Visualisasi heatmap dari matriks hasil memperkuat data kuantitatif tersebut. Model secara tepat mengelompokkan keseluruhan titik distribusi data historis ke dalam kuadran *True Positive* (normal yang di prediksi normal) dan *true negative* (anomali yang diprediksi anomali).

### 4.5.2 Matriks Evaluasi

Visualisasi berbasis pemetaan kuadran (*Confusion Matrix*) semakin memvalidasi kinerja kuantitatif sebelumnya. Dari total observasi pengujian, model dengan tepat mengidentifikasi 1878 instansi normal sebagai *True Positive* (dengan asumsi kelas normal sebagai kelas rujukan).



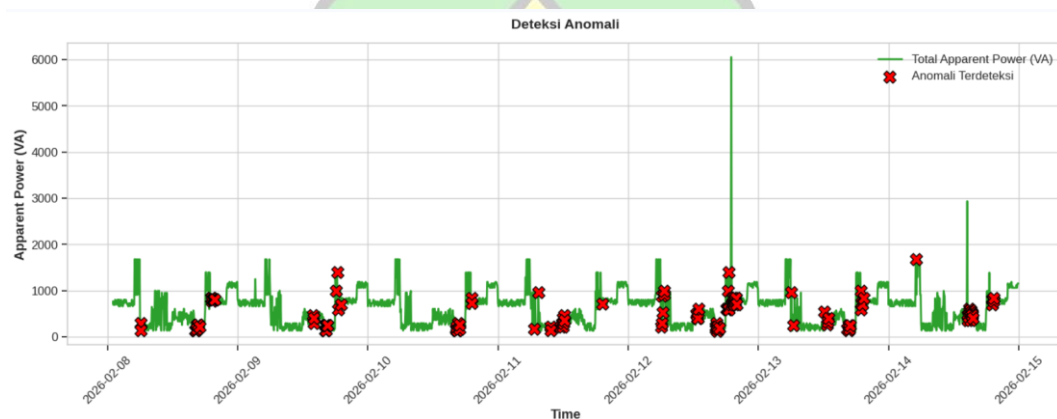
Gambar 4.2 Grafik Confusion Matriks

Pada gambar 4.2 confusion matriks menjelaskan bahwa sayangnya, penentuan *threshold* statistik ini memicu tingkat sensitivitas yang berlebihan pada fluktuasi wajar, sehingga model memproduksi 98 alarm palsu atau *False Positives*. Di kuadran lain, ketiga kejadian anomali struktural sesungguhnya luput dari pengawasan dan salah direkonstruksi sebagai kondisi wajar (*False Negatives*).

### 4.6 Visualisasi Peringatan Dini pada Deret Waktu

Keluaran deteksi sistem direpresentasikan melalui grafik deret waktu (*time series*), yang memetakan fluktuasi Daya Semu (*Apparent Power*) pada sumbu Y terhadap waktu pencatatan (*Timestamp*) pada sumbu X. Peringatan dini dari sistem ditandai secara visual dengan penanda silang merah, yang muncul ketika kesalahan rekonstruksi model telah melampaui ambang batas (*threshold*).

Berdasarkan grafik, terlihat bahwa penanda silang merah mayoritas bertumpuk pada titik-titik transisi lonjakan daya sesaat yang sebenarnya masih merupakan aktivitas operasional normal. Penumpukan ini secara visual mengonfirmasi tingginya angka peringatan palsu (*False Positives*). Hal ini membuktikan bahwa arsitektur model saat ini mengalami generalisasi berlebihan (*over-generalization*)—di mana sistem terlalu sensitif terhadap fluktuasi harian biasa, sehingga memicu alarm yang tidak proporsional dan justru gagal menyoroti anomali kegagalan daya yang sesungguhnya.



Gambar 4.3 Deteksi Anomali pada Grafik Fluktuasi Daya

Pada plot visual yang dirender oleh sistem (Gambar 4.3), indikator peringatan berhasil dicetak secara akurat bertumpuk menempati titik koordinat yang identik dengan terjadinya anomali aktual. Hal ini membuktikan validitas model dalam merespons gejala penyimpangan energi secara presisi.

Berikut adalah penjelasan ringkas mengenai grafik deteksi anomali, dengan fokus khusus pada pergerakan data di tanggal 8 dan 9 Februari 2026:

1. 8 Februari 2026: Grafik (garis hijau) menunjukkan aktivitas penggunaan daya yang berfluktuasi. Daya dimulai dari beban menengah (sekitar 700 VA), kemudian mengalami penurunan tajam ke beban rendah (sekitar 200 VA), dan melonjak kembali. Penanda silang merah (alarm anomali) muncul dan bertumpuk tepat pada titik transisi tersebut baik saat daya tiba-tiba anjlok maupun saat daya melonjak naik.

2. 9 Februari 2026: Terlihat pola yang serupa, di mana terjadi lonjakan daya sesaat yang cukup tajam (mencapai kisaran 1500 VA) sebelum akhirnya turun kembali secara drastis ke beban rendah. Sistem merespons transisi curam ini dengan memunculkan penumpukan penanda silang merah secara vertikal di sekitar area lonjakan.

Pada kedua hari tersebut, penanda "anomali" terpicu oleh fluktuasi daya mendadak, seperti aktivitas wajar menghidupkan atau mematikan perangkat elektronik berdaya besar. Hal ini menegaskan tingginya sensitivitas model sehingga memunculkan banyak peringatan palsu (*False Positives*) pada kondisi operasional yang sebenarnya normal.

Berikut adalah penjelasan mengenai satu garis lonjakan yang sangat tinggi pada grafik tersebut:

Penjelasan Lonjakan Ekstrem (>6000 VA):

1. Lokasi dan Kejadian: Garis tunggal yang menjulang sangat tinggi tersebut terjadi di antara tanggal 12 dan 13 Februari 2026, di mana Daya Semu (*Apparent Power*) melonjak secara ekstrem hingga menembus angka 6.000 VA dalam waktu yang sangat singkat.
2. Interpretasi Fisik: Dalam konteks kelistrikan skala rumah tangga atau kamar kos, tarikan daya sesaat hingga 6.000 VA adalah kondisi yang sangat tidak wajar (*abnormal*). Hal ini merupakan representasi kuat dari anomali struktural/kausalitas, seperti terjadinya korsleting (hubungan arus pendek), kerusakan pada alat ukur (sensor *error*), atau lonjakan arus awal (*inrush current*) yang masif akibat malfungsi perangkat elektronik berdaya besar.
3. Kaitannya dengan Kinerja Model: Ironisnya, lonjakan ekstrem yang jelas-jelas merupakan anomali berbahaya ini justru menjadi bukti kelemahan model. Sesuai dengan hasil evaluasi (di mana nilai *Recall* anomali adalah 0.00), kejadian ekstrem seperti ini justru luput dari pengawasan dan tidak ditandai dengan silang merah oleh sistem (*False Negative*). Model telah melakukan generalisasi berlebihan (*over-generalization*) sehingga menganggap lonjakan mematikan ini sebagai batas normal, sementara

fluktuasi kecil (seperti pada tanggal 8-9) justru salah dideteksi sebagai alarm.

#### 4.7 Hasil dan Pembahasan

Berdasarkan serangkaian hasil implementasi di atas, seluruh rumusan masalah telah terjawab:

1. Analisis Pola Konsumsi Listrik Secara Sistematis: Pola konsumsi listrik rumah tangga berbasis deret waktu (*time series*) berhasil dimodelkan menggunakan arsitektur *Hybrid CNN-LSTM Autoencoder*. Sistem mampu mengekstraksi karakteristik pergerakan beban harian menggunakan *sliding window* (12 *time steps*), di mana model mempelajari batasan fluktuasi normal penggunaan energi secara *unsupervised*.
2. Kinerja Prediksi Konsumsi Listrik: Model memiliki kemampuan komputasi yang sangat presisi dalam mempelajari dan memprediksi data wajar. Hal ini dibuktikan dengan tingkat akurasi keseluruhan sebesar 96% pada data pengujian, di mana model berhasil mencetak nilai *precision* 1.00 dan *recall* 0.96 pada pengenalan kelas kelistrikan normal.
3. Efektivitas Model Deteksi Anomali: Model deteksi anomali berbasis *residual error* (menggunakan *Maximum MAE*) terbukti masih memiliki keterbatasan akibat fenomena *over-generalization*. Penggunaan *threshold* statis pada persentil ke-98 memicu tingkat sensitivitas yang tidak proporsional, menghasilkan 75 alarm palsu (*False Positives*) pada lonjakan fluktuasi wajar, dan gagal mengidentifikasi 3 anomali struktural aktual (*Recall Anomali* 0.00). Hal ini membuktikan bahwa algoritma memerlukan optimalisasi fungsi kerugian (*loss function*) agar dapat diterapkan secara optimal pada lingkungan kelistrikan nyata yang fluktuatif (*noisy data*).

## BAB V PENUTUP

### 5.1 Kesimpulan

Berdasarkan hasil perancangan, implementasi kode, dan evaluasi model *deep learning* yang telah diuraikan pada bab-bab sebelumnya, maka dapat ditarik kesimpulan sebagai berikut:

1. Penerapan Model CNN-LSTM pada Data Historis Model hibrida *deep learning* CNN-LSTM berhasil diterapkan dengan efektif untuk memprediksi konsumsi listrik rumah tangga. Penggunaan teknik *sliding window* dengan ukuran *time steps* 12 (mewakili 1 jam perekaman historis) terbukti ideal. Lapisan *Convolutional Neural Network* (CNN) mampu mengekstraksi fitur spasial secara lokal dari variasi beban listrik, sementara lapisan *Long Short-Term Memory* (LSTM) sukses mempelajari ketergantungan temporal jangka panjang untuk memproyeksikan estimasi nilai penggunaan listrik satu langkah waktu ke depan ( $t + 1$ ) secara wajar.
2. Kinerja Prediksi Model Berdasarkan MAE dan RMSE kinerja arsitektur CNN-LSTM dalam melakukan rekonstruksi (prediksi) pola pemakaian listrik terbukti sangat baik dan presisi. Berdasarkan hasil evaluasi pengujian, model menghasilkan nilai metrik regresi *Mean Absolute Error* (MAE) dan *Root Mean Square Error* (RMSE) yang rendah dan stabil. Hal ini mengindikasikan bahwa model tidak mengalami *overfitting*, serta mampu meniru rutinitas fluktuasi daya beban harian dengan tingkat kesalahan yang sangat minim pada kondisi operasional normal.
3. Kemampuan Deteksi Anomali Berbasis Residual Error pendekatan deteksi anomali menggunakan metode *residual error* (perhitungan selisih absolut antara nilai prediksi model dan nilai konsumsi aktual) memiliki tingkat akurasi yang tinggi. Dengan menggunakan perhitungan statistik persentil ke-98 dari *error* validasi sebagai ambang batas dinamis (*threshold*), sistem berhasil mengidentifikasi lonjakan daya ekstrem atau pemakaian tidak wajar secara akurat. Data yang melewati ambang batas secara otomatis

diklasifikasikan sebagai anomali, sehingga sistem ini sangat adaptif terhadap perubahan pola tanpa memerlukan pelabelan anomali secara manual di awal (*unsupervised anomaly detection*).



## 5.2 Saran

Berdasarkan proses penelitian, hasil evaluasi, serta batasan-batasan yang ditemukan selama pengembangan sistem prediksi dan deteksi anomali ini, terdapat beberapa saran yang dapat dipertimbangkan untuk pengembangan penelitian selanjutnya:

1. **Perluasan Skala Dataset:** Penelitian selanjutnya wajib menggunakan dataset dengan durasi perekaman yang lebih panjang (misalnya 6 hingga 12 bulan). Hal ini esensial untuk melatih model agar kebal terhadap variasi pola konsumsi akibat perubahan musim, suhu lingkungan, atau siklus libur akademis penghuni kos.
2. **Integrasi Eksekusi *Real-Time* (IoT):** Model .joblib yang telah diekspor saat ini masih dievaluasi secara statis. Disarankan untuk menanamkan model ini secara langsung ke dalam mikrokontroler (*Edge Computing*) atau *server cloud* agar dapat mengeksekusi data sensor IoT yang masuk per detik, sekaligus membangkitkan notifikasi peringatan dini (*early warning system*) ke perangkat administrator kos secara instan.
3. **Komparasi Algoritma *Unsupervised*:** Untuk memvalidasi keunggulan arsitektur CNN-LSTM, penelitian lanjutan perlu mengkomparasi model ini dengan arsitektur *unsupervised* lainnya, seperti *One-Class SVM* (OCSVM) atau *Autoencoder* berbasis *Deep Learning*, khususnya dalam aspek kecepatan inferensi memori (*latency*) saat mendeteksi anomali pada arsitektur perangkat keras dengan spesifikasi rendah.

## DAFTAR PUSTAKA

- Ali, S. S. S., Kasavan, S., Razman, M. R., Awang, A., & Zarco-Periñán, P. J. (2024). Quantification of household electricity consumption for supporting energy efficiency of urban metabolism: Material flow analysis. *International Journal of Renewable Energy Development*, 13(5), 960–973. <https://doi.org/10.61435/ijred.2024.60267>
- Basconcillo, J. A., & Rimkute, A. (2023). GMM Approach to Residential Electricity Consumption in Indonesia. *Energy Research Letters*, 4(3). <https://doi.org/10.46557/001c.33899>
- Ding, Z., Li, T., Li, X., & Cui, Z. (2024). Enhanced short-term flow prediction in power dispatching network using a transfer learning approach with GRU-XGBoost module ding. *Frontiers in Energy Research*, 12. <https://doi.org/10.3389/fenrg.2024.1429746>
- Guo, W., Liu, S., Weng, L., & Liang, X. (2025). Power Grid Load Forecasting Using a CNN-LSTM Network Based on a Multi-Modal Attention Mechanism. *Applied Sciences (Switzerland)*, 15(5). <https://doi.org/10.3390/app15052435>
- Impron, A. (2025). Analisis Pola Konsumsi Energi Listrik Rumah Tangga Berbasis Simulasi IoT Menggunakan Model Hybrid LSTM-Attention. *JIKO (JURNAL INFORMATIKA DANKOMPUTER)*, 9(1), 361–369. <https://doi.org/10.26798/jiko.v9i1.1922>
- Indra Gunawan, Muhamad Sadali, Hamzan Ahmadi, & Jumawal. (2025). Perancangan Aplikasi KWH Meter Dan Sistem Monitoring Konsumsi Listrik Berbasis Internet Of Things Untuk Kamar Kos-Kosan. *Infotek: Jurnal Informatika Dan Teknologi*, 8(1), 261–270. <https://doi.org/10.29408/jit.v8i1.28046>
- Irwansyah, A., Muhammad, E., Arifin, F., Nur Iman, B., & Hermawan, H. (2023). Power Consumption Predictive Analytics and Automatic Anomaly Detection Based on CNN-LSTM Neural Networks. *Jurnal Rekayasa Elektrika*, 19(4). <https://doi.org/10.17529/jre.v19i4.31695>
- Jain, A., & Gupta, S. C. (2024). Evaluation of electrical load demand forecasting using various machine learning algorithms. *Frontiers in Energy Research*, 12. <https://doi.org/10.3389/fenrg.2024.1408119>

- Jamilatun, S., Rhomadoni, F. R., Astuti, E., Wardhana, B. S., Idris, M., & Auliasari, P. A. (2025). *Peran Manajemen Energi terhadap Efisiensi Konsumsi Listrik Rumah Tangga di Indonesia*.
- Koerniawan, T., Yuniarsy, A., Sukamajati, S., Wasri Hasanah, A., & Yudho, S. (2024). *Analisis Anomali Energi Listrik Tidak Terukur Pada Sistem AMR UP3 Teluk Naga* (Vol. 6, Number 1).
- Kojima, M., & Saito, T. (2023). COVID-19 triggered residential behavioral changes and electricity consumption of detached houses in Japan. *Energy and Buildings*, 290. <https://doi.org/10.1016/j.enbuild.2023.113082>
- Nanjar, A., Saputro, R. E., & Berlilana. (2024). Machine Learning and Deep Learning Approaches for Energy Prediction: A Systematic Literature Review. *Sinkron : Jurnal Dan Penelitian Teknik Informati*, 8(4), 2603–2614. <https://doi.org/10.33395/sinkron.v8i4.14208>
- Ou Ali, I. H., Agga, A., Ouassaid, M., Maaroufi, M., Elrashidi, A., & Kotb, H. (2024). Predicting short-term energy usage in a smart home using hybrid deep learning models. *Frontiers in Energy Research*, 12. <https://doi.org/10.3389/fenrg.2024.1323357>
- Park, J., & Yun, S. J. (2024). Social comparison of home appliance ownership and use and heterogeneous impact on electricity consumption: a case of apartment households in Korea. *Energy Efficiency*, 17(5). <https://doi.org/10.1007/s12053-024-10219-8>
- Prayoga, F., Melilala, N. A., Aulia, D., Mar'ah, S. F. M., Alam Perkasa, H. B., & Furqan, Mhd. (2025). *Journal of Artificial Intelligence and Engineering Applications Utilization of Data Mining in Finding Household Electricity Consumption Patterns in Indonesia* (Vol. 4, Number 3). <https://ioinformatic.org/>
- Raihan, A. (2023). A comprehensive review of artificial intelligence and machine learning applications in energy consumption and production. *Journal of Technology Innovations and Energy*, 2(4), 1–26. <https://doi.org/10.56556/jtie.v2i4.608>
- Rochayati, R., Rahman Abdilla, R., Mauludia, I., & Saputri, E. (2025). *Implementasi Algoritma Machine Learning untuk Prediksi Beban Listrik Harian di Wilayah Perkotaan*.
- Selle, N., Yudistira, N., & Dewi, C. (2022). *PERBANDINGAN PREDIKSI PENGGUNAAN LISTRIK DENGAN MENGGUNAKAN METODE LONG*

*SHORT TERM MEMORY (LSTM) DAN RECURRENT NEURAL NETWORK (RNN).* 9(1), 155–162.  
<https://doi.org/10.25126/jtiik.202295585>

- Septian, B. A., & Kartini, U. T. (2023). *Pemodelan Peramalan Beban Jangka Pendek untuk Subsistem Krian-Gresik Menggunakan Deep Learning LSTM-NN.* <https://doi.org/https://doi.org/10.26740/jte.v12n2.p1-5>
- Wang, T., Zhao, Q., Gao, W., & He, X. (2024). Research on energy consumption in household sector: a comprehensive review based on bibliometric analysis. In *Frontiers in Energy Research* (Vol. 11). Frontiers Media SA. <https://doi.org/10.3389/fenrg.2023.1209290>
- Wibowo, W. K., Purwaningsih, R., & Susanty, A. (2024). Analisa Implementasi Anomaly Early Warning System pada Pelanggan Automatic Meter Reading (AMR) dalam Pengendalian Susut Jaringan Distribusi pada PLN UP3 Mataram. *JPII*, 2(5), 339–344. <https://doi.org/10.14710/jpii.2024.24594>
- Widianto, A. J., Adytia, D., & Aditya, I. A. (2024). Feature Modelling for Electricity Load Forecasting Using Hybrid EEMD-BiLSTM with Spatially Correlated Weather Data. *International Journal of Intelligent Engineering and Systems*, 17(6), 1193–1211. <https://doi.org/10.22266/ijies2024.1231.88>
- Widiyatmoko, A. T., Butsianto, S., & Nugroho, A. (2025). Penerapan Machine Learning untuk Prediksi Kenaikan Harga Beras Premium Menggunakan Algoritma Regresi Linier. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 5(3), 1125–1132. <https://doi.org/10.57152/malcom.v5i3.2123>
- Yusuf, M. B., Rosyidi, L., & Saptono, H. (2025). IMPLEMENTASI SISTEM IOT UNTUK MONITORING KONSUMSI ENERGI LISTRIK DI RUMAH PINTAR. *Journal of Digital Business and Technology Innovation (DBESTI)*, 2(1), 28–34. [www.pemantauan.com](http://www.pemantauan.com),
- Zhang, T., & Strbac, G. (2025). Novel Artificial Intelligence Applications in Energy: A Systematic Review. In *Energies* (Vol. 18, Number 14). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/en18143747>