

**Pemodelan Ensemble Learning untuk Prediksi
Konsumsi dan Estimasi Tagihan Energi Listrik
Rumah Tangga Berdasarkan Karakteristik
Penggunaan Perangkat dan Pola Temporal**

PROYEK AKHIR

Disusun Oleh:

MUHAMMAD FATHU AL RAZI

3312301098

Disusun untuk memenuhi salah satu syarat memperoleh gelar Ahli Madya
Teknik Informatika



**PROGRAM STUDI TEKNIK INFORMATIKA
JURUSAN TEKNIK INFORMATIKA
POLITEKNIK NEGERI BATAM**

2026

KATA PENGANTAR

Puji syukur penulis panjatkan ke hadirat Tuhan Yang Maha Esa atas limpahan rahmat dan karunia-Nya, sehingga laporan Proyek Akhir dapat diselesaikan. Laporan ini disusun untuk memenuhi salah satu syarat menyelesaikan pendidikan Diploma Tiga pada Program Studi Teknik Informatika, Politeknik Negeri Batam.

Penyusunan laporan ini tidak lepas dari bantuan, bimbingan, dan dukungan berbagai pihak. Oleh karena itu, penulis menyampaikan terima kasih kepada:

1. Bapak Ir. Bambang Hendrawan, ST., MSM., CIPMP., CISCIP., selaku Direktur Politeknik Negeri Batam.
2. Bapak Ir. Ahmad Hamim Thohari, S.S.T., M.T., selaku Ketua Jurusan Teknik Informatika.
3. Ibu Yeni Rokhayati, S.Si., M.Sc, selaku Ketua Program Studi Teknik Informatika.
4. Bapak Muchamad Fajri Amirul Nasrullah, S.ST., M.Sc, selaku dosen pembimbing yang telah meluangkan waktu untuk memberikan arahan, masukan, dan koreksi selama proses pengerjaan proyek hingga penyusunan laporan ini.
5. Seluruh dosen dan staf Program Studi Teknik Informatika atas ilmu dan bantuan yang diberikan selama masa perkuliahan.
6. Kedua orang tua dan keluarga penulis atas doa, dukungan moral, dan semangat yang tidak pernah putus.
7. Semua pihak yang tidak dapat disebutkan satu per satu, yang telah membantu hingga laporan ini selesai.

Laporan ini disusun untuk mendokumentasikan proses pengembangan model prediksi konsumsi dan estimasi tagihan listrik rumah tangga beserta implementasinya dalam bentuk aplikasi. Penulis berharap laporan ini dapat memberikan manfaat bagi pengembangan penelitian di bidang machine learning dan efisiensi energi. Penulis menyadari bahwa laporan ini masih memiliki kekurangan. Oleh karena itu, penulis terbuka menerima kritik dan saran yang membangun demi perbaikan di masa mendatang.

DAFTAR ISI

KATA PENGANTAR	ii
DAFTAR ISI.....	iii
DAFTAR TABEL.....	vi
DAFTAR GAMBAR	vii
DAFTAR LAMPIRAN.....	ix
ABSTRAK	x
BAB I PENDAHULUAN	1
1.1. Latar Belakang	1
1.2. Rumusan Masalah	3
1.3. Tujuan	3
1.4. Batasan Masalah.....	4
1.5. Manfaat	4
1.6. Kolaborasi dan Sinergi dalam Pelaksanaan	5
BAB II TINJAUAN PUSTAKA.....	7
2.1. Tinjauan Solusi dan Sistem Terkait	7
2.2. Landasan Konsep dan Teknologi.....	8
2.2.1. Prediksi Konsumsi Energi Listrik Rumah Tangga.....	8
2.2.2. Konsep Dasar Energi Listrik dan Konsumsi.....	8
2.2.3. <i>Machine Learning, Supervised Learning</i> , dan Regresi.....	9
2.2.4. <i>Ensemble Learning</i>	10
2.2.5. <i>Linear Regression</i>	10
2.2.6. <i>Random Forest</i>	11
2.2.7. <i>Extreme Gradient Boosting (XGBoost)</i>	12
2.2.8. <i>Feature Engineering</i>	12
2.2.9. <i>Cross Validation</i>	14
2.2.10. <i>Hyperparameter Tuning</i>	15
2.2.11. Metrik Evaluasi Regresi.....	15
2.2.12. <i>Explainable AI</i> dan SHAP.....	16
2.2.13. Struktur Tarif Tenaga Listrik PLN dan Estimasi Tagihan	17
2.2.14. <i>Dataset individual Household Electric Power Consumption</i>	17
2.3. Metode Pengembangan Produk.....	17

2.3.1. Pemahaman Bisnis (<i>Business Understanding</i>).....	18
2.3.2. Pemahaman Data (<i>Data Understanding</i>).....	18
2.3.3. Persiapan Data (<i>Data Preparation</i>)	19
2.3.4. Pemodelan (<i>Modeling</i>).....	19
2.3.5. Evaluasi (<i>Evaluation</i>).....	19
2.3.6. Penerapan (<i>Deployment</i>)	20
BAB III ANALISIS DAN PERANCANGAN	21
3.1. Pengumpulan Data	21
3.2. <i>Preprocessing</i> Data	22
3.3. Penerapan Metode AI.....	23
3.3.1. Rekayasa Fitur.....	23
3.3.2. Model dan Justifikasi	24
3.3.3. Studi Ablasi.....	24
3.3.4. Penyetelan Hiperparameter	24
3.3.5. Interpretabilitas	25
3.4. Integrasi ke Aplikasi	25
3.5. Evaluasi Hasil.....	26
3.5.1. Metrik Evaluasi	26
3.5.2. Strategi Validasi	26
3.5.3. Prosedur Pengujian Bertahap	27
BAB IV HASIL DAN PEMBAHASAN	28
4.1. Pengumpulan Data	28
4.2. <i>Preprocessing</i> Data	29
4.3. Pengolahan Data.....	33
4.3.1. Hasil <i>Baseline</i>	33
4.3.2. Hasil Studi Ablasi	33
4.3.3. Hasil Perbandingan Model.....	34
4.3.4. Hasil Penyetelan Hiperparameter.....	35
4.4. Integrasi ke Aplikasi	36
4.5. Hasil Evaluasi.....	41
BAB V KESIMPULAN	45
5.1 Kesimpulan	45
5.2 Saran.....	46
DAFTAR PUSTAKA	47

DAFTAR LAMPIRAN	50
-----------------------	----

DAFTAR TABEL

Tabel 1. 1 Pembagian Peran dan Tanggung Jawab.....	6
Tabel 2. 1 Kajian Penelitian Terdahulu.....	7
Tabel 3. 1 Variabel Mentah Dataset UCI IHEPC	21
Tabel 3. 2 Rancangan Fitur Model.....	23
Tabel 3. 3 Rancangan Konfigurasi Studi Ablasi.....	24
Tabel 3. 4 Metrik Evaluasi	26
Tabel 4. 1 Ringkasan Dataset yang Terkumpul	28
Tabel 4. 2 Hasil Reduksi Data per Tahap <i>Preprocessing</i>	29
Tabel 4. 3 Statistik Deskriptif Target `total_kwh`	30
Tabel 4. 4 Tabel Hasil Studi Ablasi (<i>Random Forest, TimeSeriesSplit</i> 5-fold)....	33
Tabel 4. 5 Perbandingan Model Sebelum dan Sesudah <i>Tuning</i> (Config D, <i>TimeSeriesSplit</i> 5-fold).....	34
Tabel 4. 6 Hiperparameter Terbaik XGBoost Hasil Tuning	35
Tabel 4. 7 Hasil Verifikasi Modul Tarif PLN (Konsumsi 120 kWh/Bulan).....	36
Tabel 4. 8 Daftar Endpoint API Hasil Implementasi	37
Tabel 4. 9 Hasil Evaluasi Model Final pada <i>Hold-out Test Set</i>	41
Tabel 4. 10 Sepuluh Fitur Teratas Berdasarkan Rata-rata SHAP	42

DAFTAR GAMBAR

Gambar 1. 1 Listrik yang Didistribusikan Kepada Pelanggan Rumah Tangga Periode 2020–2024	1
Gambar 2. 1 Taksonomi <i>Machine Learning</i> dan Posisi Regresi.....	9
Gambar 2. 2 Perbandingan <i>Bagging</i> dan <i>Boosting</i>	10
Gambar 2. 3 Ilustrasi <i>Linear Regression</i>	10
Gambar 2. 4 Ilustrasi <i>Random Forest</i> untuk Regresi.....	11
Gambar 2. 5 Ilustrasi XGBoost untuk Regresi	12
Gambar 2. 6 Ilustrasi <i>Feature Engineering</i> pada tahap <i>Preprocessing</i>	12
Gambar 2. 7 <i>Cross Validation</i> dengan <i>TimeSeriesSplit</i>	14
Gambar 2. 8 <i>Hyperparameter Tuning</i> pada Model <i>Machine Learning</i>	15
Gambar 2. 9 Ilustrasi Evaluasi Model Regresi.....	15
Gambar 2. 10 Kerangka Kerja Metode CRISP-DM	18
Gambar 3. 1 Profil Dataset <i>Individual Household Electric Power Consumption</i>	21
Gambar 3. 2 Profil Dataset <i>Appliances Energy Prediction</i>	22
Gambar 3. 3 Arsitektur Sistem Aplikasi	25
Gambar 4. 1 Pola Deret Waktu Konsumsi Energi Harian Hasil Agregasi (2007- 2010)	31
Gambar 4. 2 Distribusi Konsumsi Energi Harian dan Perbandingan Musiman ...	31
Gambar 4. 3 Heatmap Korelasi Antar Fitur	32
Gambar 4. 4 Korelasi Fitur terhadap Target `total_kwh`	32
Gambar 4. 5 Hasil Studi Ablasi Empat Konfigurasi Fitur	34
Gambar 4. 6 Perbandingan Performa Model Sebelum dan Sesudah Penyetelan..	35
Gambar 4. 7 Perbandingan Estimasi Tagihan Antar Golongan Tarif PLN	37
Gambar 4. 8 Halaman Login Aplikasi	38
Gambar 4. 9 Halaman Registrasi Aplikasi.....	38
Gambar 4. 10 Halaman Formulir Prediksi dengan Hasil Prediksi dan Tarif Tagihan.....	39
Gambar 4. 11 Halaman Histori Prediksi Tersimpan	39
Gambar 4. 12 Halaman Detail Historis Prediksi	40

Gambar 4. 13 Hasil Evaluasi Prediksi vs Aktual dan Analisis Residual pada <i>Hold-out Test Set</i>	42
Gambar 4. 14 SHAP Kepentingan Fitur pada Final Model	43
Gambar 4. 15 Arah dan Besaran Pengaruh Fitur dalam SHAP Beeswarm Plot ...	43
Gambar 4. 16 SHAP Waterfall pada Tiga Representative Case	44

DAFTAR LAMPIRAN

Lampiran A. Dataset	50
Lampiran B. Link Produk	50
Lampiran C. Dokumen Pengujian.....	50
Lampiran D. Video Demo Aplikasi	50

ABSTRAK

Konsumsi listrik rumah tangga di Indonesia menyumbang lebih dari 40% total konsumsi nasional, namun sebagian besar pengguna tidak dapat memperkirakan konsumsi dan tagihan sebelum periode penagihan berakhir. Proyek akhir ini membangun model prediksi konsumsi energi listrik harian sekaligus estimasi tagihan bulanan tanpa memerlukan perangkat IoT. Data yang digunakan adalah *Individual Household Electric Power Consumption* dari UCI Machine Learning Repository, berisi 2.075.259 catatan per menit yang diagregasi menjadi 1.390 hari setelah penyaringan kelengkapan. Dari data tersebut dibentuk 20 fitur yang mencakup sub-metering perangkat, *cyclical encoding* pola temporal, fitur lag, dan statistik rolling. Tiga algoritma dibandingkan, yaitu *Linear Regression* sebagai *baseline*, *Random Forest*, dan XGBoost, dengan validasi *TimeSeriesSplit* lima lipatan serta ablation study empat konfigurasi fitur. XGBoost dengan penyetelan hiperparameter memberikan performa terbaik pada data uji *hold-out* 20% terakhir, dengan RMSE 0,826 kWh, MAE 0,558 kWh, MAPE 2,69%, dan R^2 0,9873. Analisis SHAP menempatkan beban puncak harian, rasio beban puncak terhadap rata-rata, dan sub-metering pendingin serta pemanas air sebagai kontributor dominan. Model diintegrasikan dengan modul tarif PLN delapan golongan daya berbasis aturan untuk mengonversi prediksi kWh menjadi estimasi tagihan, kemudian dibungkus dalam aplikasi web berbasis *FastAPI* dan *React*. Hasil ini menunjukkan model ensemble dapat memprediksi konsumsi energi harian secara akurat hanya dari input perangkat dan pola waktu. Akurasi tersebut diperoleh pada satu rumah tangga beriklim kontinental, sehingga belum dapat digeneralisasi ke rumah tangga Indonesia tanpa kalibrasi ulang menggunakan data lokal.

Kata Kunci: prediksi konsumsi energi, *ensemble learning*, XGBoost, estimasi tagihan listrik, SHAP

BAB I PENDAHULUAN

1.1. Latar Belakang

Listrik menjadi kebutuhan dasar bagi hampir seluruh rumah tangga di Indonesia. Pemakaiannya melekat pada aktivitas harian, dari penerangan dan pendingin ruangan sampai peralatan dapur dan hiburan. Seiring bertambahnya jumlah penduduk dan meningkatnya kepemilikan perangkat elektronik, konsumsi listrik rumah tangga terus naik dari tahun ke tahun. Kementerian Energi dan Sumber Daya Mineral mencatat konsumsi listrik per kapita nasional meningkat dari 1.173 kWh pada tahun 2022 menjadi 1.285 kWh pada tahun 2023 (Kementerian ESDM, 2024). Kenaikan ini memperlihatkan ketergantungan masyarakat terhadap listrik yang semakin besar.

Rumah tangga adalah kelompok pelanggan listrik terbesar. Data Badan Pusat Statistik menunjukkan pangsa konsumsi rumah tangga terhadap seluruh pelanggan tetap di atas 40% setiap tahun, lebih besar dari kelompok sosial, bisnis, industri, maupun publik. Jumlah listrik yang didistribusikan kepada pelanggan rumah tangga juga terus bertambah, dari 111.413,28 GWh pada 2020 menjadi 130.433,10 GWh pada 2024, atau tumbuh rata-rata sekitar 4% per tahun, seperti terlihat pada Gambar 1.1. Besaran ini menegaskan bahwa apa yang terjadi di tingkat rumah berdampak langsung pada beban sistem kelistrikan nasional.



Gambar 1. 1 Listrik yang Didistribusikan Kepada Pelanggan Rumah Tangga
Periode 2020–2024

Persoalannya, sebagian besar pengguna tidak dapat memperkirakan berapa konsumsi dan tagihan listriknya sebelum periode penagihan berakhir. Tagihan baru diketahui setelah angka meteran tercatat pada akhir bulan, sehingga tidak ada ruang untuk menyesuaikan pemakaian lebih awal. Tagihan tersebut mengikuti struktur tarif berdasarkan golongan daya, mulai dari 450 VA hingga 6.600 VA, sebagaimana diatur dalam Peraturan Menteri ESDM No. 3 Tahun 2020 dan Keputusan Menteri ESDM No. 3 K/20/MEM/2021. Setiap golongan memiliki tarif per kWh yang berbeda, dan banyak pengguna belum memahami bagaimana pemakaian perangkat sehari-hari diterjemahkan menjadi rupiah pada tagihan.

Pendekatan *machine learning* membuka peluang untuk memperkirakan konsumsi listrik dari data historis tanpa memerlukan perangkat sensor tambahan. Salah satu kelompok metode yang banyak dipakai adalah *ensemble learning*, yaitu teknik yang menggabungkan banyak model sederhana menjadi satu prediktor yang lebih kuat, seperti *Random Forest* dan *Extreme Gradient Boosting* (XGBoost). Model ensemble *gradient boosting* yang dipadukan dengan fitur waktu dan kalender terbukti mampu meramalkan konsumsi listrik harian dengan tingkat kesalahan yang rendah (Rohmadi et al., 2026). Pemilihan fitur turut menentukan akurasi. Fitur temporal seperti hari, bulan, dan musim, serta fitur autoregresif berupa konsumsi pada hari-hari sebelumnya, lazim digunakan untuk menangkap pola berulang pada data deret waktu. Kualitas prediksi diukur dengan metrik RMSE, MAE, MAPE, dan R-squared yang umum dipakai pada penelitian konsumsi energi. Selain akurasi, kemampuan model untuk dijelaskan juga penting. Metode SHAP memungkinkan kontribusi tiap fitur terhadap hasil prediksi diukur dan ditampilkan, sehingga model tidak lagi bersifat kotak hitam (Moon et al., 2024).

Urgensi penelitian ini terletak pada jarak antara besarnya konsumsi rumah tangga dan minimnya alat bantu yang bisa dipakai pengguna awam. Banyak penelitian prediksi konsumsi di Indonesia berhenti pada perbandingan akurasi model dan belum menghubungkan hasilnya dengan struktur tarif PLN untuk menghasilkan estimasi tagihan yang langsung berguna (Saragih & Suryani, 2026). Sebagian pendekatan lain bergantung pada sensor per perangkat atau *smart meter* yang mahal dan belum tersebar luas di rumah tangga Indonesia. Kebutuhan akan

estimasi dini yang murah, mudah diakses, dan bebas perangkat keras tambahan menjadi alasan utama penelitian ini dikerjakan.

Berdasarkan uraian tersebut, proyek akhir ini membangun model *ensemble learning* untuk memprediksi konsumsi energi listrik harian rumah tangga berdasarkan karakteristik penggunaan perangkat dan pola temporal, kemudian mengintegrasikannya dengan struktur tarif PLN untuk menghasilkan estimasi tagihan bulanan per golongan daya. Model dibungkus dalam sebuah aplikasi web sehingga dapat digunakan tanpa perangkat IoT maupun *smart meter*. Dengan cara ini, pengguna rumah tangga memperoleh gambaran konsumsi dan perkiraan tagihan lebih awal sebagai dasar untuk menyesuaikan pemakaian.

1.2. Rumusan Masalah

Berdasarkan latar belakang di atas, permasalahan yang dikaji dalam proyek akhir ini dirumuskan sebagai berikut:

1. Seberapa akurat model *ensemble learning* dalam memprediksi konsumsi energi listrik harian rumah tangga berdasarkan fitur penggunaan perangkat dan pola temporal?
2. Algoritma mana di antara *Linear Regression* sebagai *baseline*, *Random Forest*, dan *XGBoost* yang menghasilkan performa prediksi terbaik berdasarkan metrik RMSE, MAE, MAPE, dan R^2 ?
3. Kelompok fitur mana yang memberikan kontribusi terbesar terhadap akurasi prediksi, apakah fitur sub-metering perangkat, temporal, atau autoregresif?
4. Bagaimana hasil prediksi konsumsi diintegrasikan dengan struktur tarif PLN untuk menghasilkan estimasi tagihan listrik bulanan per golongan daya?

1.3. Tujuan

Mengacu pada rumusan masalah tersebut, proyek akhir ini bertujuan untuk:

1. Mengukur akurasi model *ensemble learning* dalam memprediksi konsumsi energi listrik harian rumah tangga.

2. Membandingkan performa *Linear Regression*, *Random Forest*, dan XGBoost untuk menentukan algoritma dengan prediksi terbaik berdasarkan RMSE, MAE, MAPE, dan R^2 .
3. Mengidentifikasi kelompok fitur yang paling berkontribusi terhadap akurasi prediksi menggunakan analisis SHAP.
4. Mengembangkan modul estimasi tagihan yang mengintegrasikan hasil prediksi dengan struktur tarif PLN per golongan daya dalam sebuah aplikasi web.

1.4. Batasan Masalah

Agar pembahasan tetap terarah, proyek akhir ini dibatasi pada hal-hal berikut:

1. Data yang digunakan adalah dataset *Individual Household Electric Power Consumption* dari UCI yang berasal dari satu rumah tangga di Prancis, sehingga hasil tidak dapat langsung digeneralisasi ke rumah tangga di Indonesia tanpa kalibrasi ulang menggunakan data lokal.
2. Prediksi dilakukan pada tingkat konsumsi harian dalam satuan kWh per hari, bukan pada tingkat perangkat individu.
3. Estimasi tagihan dihitung berdasarkan delapan golongan tarif rumah tangga PLN dengan pendekatan berbasis aturan, dan bukan merupakan tagihan resmi.
4. Model tidak menggunakan data cuaca *real-time* melainkan variasi musiman didekati melalui fitur temporal.
5. Sistem tidak melibatkan perangkat IoT maupun *smart meter*, dan tidak mencakup pemantauan konsumsi secara *real-time*.

1.5. Manfaat

Proyek akhir ini diharapkan memberikan manfaat baik secara teoretis maupun praktis bagi berbagai pihak sebagai berikut:

1. Bagi Penulis

- a. Menerapkan ilmu *data science* dan *machine learning* pada permasalahan nyata melalui proses pengolahan data, pembangunan model, dan evaluasi hasil prediksi.
 - b. Mengembangkan kemampuan dalam mengimplementasikan metode *ensemble learning* dan interpretabilitas model menggunakan SHAP.
 - c. Memperoleh pengalaman dalam membangun aplikasi web yang mengintegrasikan model *machine learning* ke dalam sistem yang dapat digunakan oleh pengguna.
2. Bagi Rumah Tangga sebagai Pengguna
- a. Memperoleh estimasi konsumsi listrik dan perkiraan tagihan tanpa memerlukan perangkat pengukuran tambahan.
 - b. Membantu perencanaan penggunaan listrik secara lebih hemat dan efisien berdasarkan hasil prediksi yang diberikan.
 - c. Meningkatkan pemahaman terhadap pola penggunaan energi sehingga dapat mendukung pengambilan keputusan yang lebih terencana.
3. Bagi Pencapaian Tujuan Pembangunan Berkelanjutan (SDGs)
- a. Mendukung SDGs Tujuan ke-7, yaitu Energi Bersih dan Terjangkau, khususnya Target 7.3 mengenai peningkatan efisiensi energi (United Nations, 2024).
 - b. Membantu rumah tangga memahami pola konsumsi listrik sehingga dapat mendorong penggunaan energi yang lebih efisien.
 - c. Berkontribusi pada upaya pemanfaatan energi yang lebih berkelanjutan melalui pengambilan keputusan berbasis data terkait konsumsi listrik rumah tangga.

1.6. Kolaborasi dan Sinergi dalam Pelaksanaan

Proyek akhir ini dilaksanakan dengan pembagian peran dan tanggung jawab berbasis modul, sehingga setiap bagian dikerjakan secara menyeluruh mulai dari analisis kebutuhan, perancangan, implementasi, pengujian, hingga dokumentasi. Rincian pembagian peran dan tanggung jawab disajikan pada Tabel 1.1 berikut.

Tabel 1. 1 Pembagian Peran dan Tanggung Jawab

Nama Mahasiswa	Peran/ Kontribusi	Ruang Lingkup Tanggung Jawab
Muhammad Zaini Ridha	Implementasi Antarmuka Pengguna	Berkontribusi dalam perancangan dan implementasi antarmuka aplikasi, termasuk penyusunan tampilan halaman, komponen UI, serta pengalaman pengguna untuk mendukung proses demonstrasi dan validasi produk pada kompetisi.
Yulia Pipka Ziliwu	Pitching dan Presentasi Produk	Berkontribusi dalam penyusunan materi presentasi, penyampaian pitching produk kepada dewan juri, serta komunikasi nilai dan manfaat solusi yang dikembangkan selama kompetisi berlangsung.

Selain pembagian peran teknis, pelaksanaan proyek tetap melibatkan kolaborasi dengan pihak pendukung untuk menjaga kualitas dan relevansi hasil. Konsultasi rutin dengan dosen pembimbing dilakukan untuk memastikan kesesuaian metodologi dan kelengkapan dokumentasi dengan standar akademik.

BAB II TINJAUAN PUSTAKA

2.1. Tinjauan Solusi dan Sistem Terkait

Prediksi konsumsi energi listrik berbasis *machine learning* sudah banyak dikerjakan, baik di Indonesia maupun di luar negeri, dengan ragam algoritma dan dataset yang berbeda. Bagian ini meninjau beberapa penelitian terdahulu yang relevan untuk menempatkan posisi proyek ini di antara solusi yang sudah ada.

Meskipun demikian, sebagian besar penelitian masih berfokus pada aspek prediksi konsumsi energi saja. Integrasi antara prediksi konsumsi, estimasi tagihan listrik berdasarkan struktur tarif, dan interpretasi hasil model masih relatif terbatas. Oleh karena itu, tinjauan terhadap penelitian terdahulu diperlukan untuk mengidentifikasi pendekatan yang telah digunakan, hasil yang diperoleh, serta celah penelitian yang menjadi dasar pengembangan proyek ini. Ringkasan penelitian terdahulu yang relevan disajikan pada Tabel 2.1.

Tabel 2. 1 Kajian Penelitian Terdahulu

Peneliti/ Tahun	Masalah	Algoritma	Dataset	Performa	Kelebihan	Keterbatasan
Rohmadi et al. (2026)	Peramalan konsumsi listrik harian	Ensemble LightGBM + XGBoost	Kompetisi (harian, 2014–2021)	MAPE 2,03%; R^2 0,9960	Akurasi tinggi, fitur waktu dan lag	Tidak ada estimasi tagihan
Wardana et al. (2024)	Prediksi daya jangka pendek	CNN, LSTM, BDLSTM, CNN- LSTM	UCI IHEPC (per menit)	BDLSTM MAE 0,174	Memakai dataset publik tervalidasi	Tidak membahas tagihan
Saragih & Suryani (2026)	Prediksi per golongan tarif	Hybrid BPNN-PSO	Penjualan listrik PLN (bulanan)	MAPE 46,38%; R^2 0,1831	Mengaitkan golongan tarif	Akurasi masih rendah
Moon et al. (2024)	Peramalan listrik residensial	Ensemble decision tree + SHAP	University Residential & Appliances	Ensemble unggul; SHAP interpretatif	Interpretasi model dengan SHAP	Bukan konteks Indonesia

Berdasarkan tinjauan tersebut, terlihat bahwa sebagian besar penelitian berfokus pada satu aspek saja, yaitu akurasi prediksi konsumsi, tanpa

menghubungkannya dengan estimasi tagihan maupun interpretasi model. Penelitian yang memakai *ensemble* umumnya tidak menyertakan modul tarif, sedangkan penelitian yang mengaitkan golongan tarif masih memiliki akurasi yang rendah. Proyek ini mengintegrasikan proses prediksi konsumsi listrik, interpretasi model menggunakan SHAP, dan perhitungan estimasi tagihan berdasarkan tarif PLN ke dalam sebuah aplikasi web. Penekanannya bukan pada kebaruan ilmiah, melainkan pada keterpakaian solusi bagi pengguna rumah tangga.

2.2. Landasan Konsep dan Teknologi

2.2.1. Prediksi Konsumsi Energi Listrik Rumah Tangga

Prediksi konsumsi energi listrik adalah upaya memperkirakan pemakaian listrik pada periode mendatang dari data historis dan faktor yang memengaruhinya. Pada tingkat rumah tangga, prediksi ini berguna untuk memperkirakan tagihan dan mendorong pemakaian yang lebih hemat. Penelitian di Indonesia menunjukkan bahwa pendekatan berbasis data mampu memprediksi konsumsi listrik dengan tingkat kesalahan yang rendah, baik pada skala nasional maupun pada tingkat rumah (Wardana et al., 2024).

2.2.2. Konsep Dasar Energi Listrik dan Konsumsi

Energi listrik yang dikonsumsi sebuah perangkat dihitung dari daya dikalikan lama pemakaian. Hubungan dasarnya dinyatakan pada Persamaan (2.1).

$$E = P \times t \quad (2.1)$$

Keterangan:

E = energi listrik (Wh atau kWh)

P = daya perangkat (W atau kW)


t = lama pemakaian (jam)

Satuan baku konsumsi listrik pada meteran PLN adalah kilowatt-hour (kWh). Karena daya perangkat umumnya dinyatakan dalam watt, konversi ke kWh dilakukan dengan membagi hasil perkalian dengan 1.000, sebagaimana Persamaan (2.2).

$$kWh = E/1000 \quad (2.2)$$

Pada proyek ini, data mentah berisi daya aktif dalam kilowatt dengan resolusi satu menit, sehingga energi per menit dihitung sebagai P (kW) dikalikan $1/60$ jam. Nilai sub-metering yang tercatat dalam watt-hour per menit dikonversi ke kWh dengan membagi 1.000. Seluruh nilai per menit kemudian dijumlahkan menjadi konsumsi harian dalam kWh.


2.2.3. Machine Learning, Supervised Learning, dan Regresi



Gambar 2. 1 Taksonomi *Machine Learning* dan Posisi Regresi

Machine learning adalah cabang kecerdasan buatan yang memungkinkan komputer mempelajari pola dari data tanpa diprogram secara eksplisit untuk tiap kasus (Rayadin et al., 2024). Pada skema *supervised learning*, model dilatih memakai data yang sudah memiliki nilai target. Ketika targetnya berupa nilai kontinu, masalahnya disebut regresi. Prediksi konsumsi listrik harian dalam satuan kWh termasuk masalah regresi, sehingga model dilatih untuk memetakan fitur masukan ke nilai konsumsi (Fauzi et al., 2025).


2.2.4. Ensemble Learning



Gambar 2. 2 Perbandingan *Bagging* dan *Boosting*

Ensemble learning menggabungkan beberapa model dasar untuk menghasilkan prediksi yang lebih baik daripada satu model tunggal. Dua pendekatan utamanya adalah *bagging* dan *boosting* (Churniansyah & Wahyu Utomo, 2024). *Bagging* melatih banyak model secara paralel pada subset data hasil pengambilan sampel acak dengan pengembalian, lalu menggabungkan hasilnya untuk menurunkan varians. *Boosting* melatih model secara bertahap, dengan tiap model baru memperbaiki kesalahan model sebelumnya, sehingga menurunkan bias dan biasanya meningkatkan akurasi.

2.2.5. Linear Regression



Gambar 2. 3 Ilustrasi *Linear Regression*

Linear Regression memodelkan target sebagai fungsi linear dari fitur masukan, dengan bentuk umumnya seperti pada persamaan 2.3.

$$\hat{y} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_n x_n \quad (2.3)$$

Keterangan:

$\hat{y}$ = nilai prediksi

β_0 = intersep (konstanta)


β_i = koefisien regresi fitur ke-i

x_i = nilai fitur ke-i

n = jumlah fitur

Model ini sederhana, cepat, dan mudah ditafsirkan, sehingga dipakai sebagai *baseline* pembanding. Pada kasus dengan hubungan antar variabel yang relatif sederhana, *Linear Regression* dapat menyaingi model yang lebih kompleks (Setiyorini & Frieyadie, 2024).

2.2.6. *Random Forest*




Gambar 2. 4 Ilustrasi *Random Forest* untuk Regresi

Random Forest adalah algoritma ensemble berbasis *bagging* yang membangun banyak pohon keputusan dari subset data dan fitur yang berbeda. Untuk masalah regresi, prediksi akhir diperoleh dari rata-rata prediksi seluruh

pohon. Algoritma ini tahan terhadap *overfitting* dan mampu menangani hubungan *non-linear* (Aditya Pratama et al., 2024).


2.2.7. *Extreme Gradient Boosting (XGBoost)*



Gambar 2. 5 Ilustrasi XGBoost untuk Regresi

XGBoost adalah implementasi *gradient boosting* yang dioptimalkan dari sisi kecepatan dan akurasi, serta dilengkapi regularisasi untuk menekan *overfitting*. Model membangun pohon secara berurutan, dengan tiap pohon baru memperbaiki residu pohon sebelumnya, lalu menjumlahkan kontribusi seluruh pohon menjadi prediksi akhir. XGBoost terbukti memberikan performa kuat pada masalah regresi maupun peramalan konsumsi energi (Rohmadi et al., 2026).

2.2.8. *Feature Engineering*



Gambar 2. 6 Ilustrasi *Feature Engineering* pada tahap *Preprocessing*

Feature engineering adalah proses membentuk fitur informatif dari data mentah agar model menangkap pola dengan lebih baik. Pada data deret waktu,

teknik yang dipakai pada proyek ini mencakup *lag*, *rolling statistics*, *cyclical encoding*, dan fitur rasio turunan (Rohmadi et al., 2026).

Lag features memasukkan nilai konsumsi pada waktu sebelumnya, misalnya satu hari, tujuh hari, dan tiga puluh hari lalu, sebagai prediktor ketergantungan antar waktu.

Rolling statistics menghitung ringkasan bergerak pada jendela waktu selebar w . Rata-rata bergerak dan simpangan baku bergerak dirumuskan pada Persamaan (2.4) dan (2.5).

$$rolling_mean = \frac{1}{w} \sum_{i=1}^w x_i \quad (2.4)$$

$$rolling_std = \sqrt{\frac{1}{w} \sum_{i=1}^w (x_i - \bar{x})^2} \quad (2.5)$$

Keterangan:

x_i = nilai konsumsi pada hari ke- i dalam jendela

$\bar{x}$ = rata-rata nilai dalam jendela

w = lebar jendela (misalnya 7 atau 30 hari)

Cyclical encoding mengubah fitur waktu yang bersifat siklis, seperti bulan dan hari, menjadi pasangan sinus dan kosinus agar nilai yang berdekatan dalam siklus tetap berdekatan secara numerik, sebagaimana Persamaan (2.6) dan (2.7).

$$x_{sin} = \sin\left(\frac{2\pi v}{T}\right) \quad (2.6)$$

$$x_{cos} = \cos\left(\frac{2\pi v}{T}\right) \quad (2.7)$$

Keterangan:

v = nilai waktu (misalnya bulan 1 sampai 12)

T = panjang siklus (12 untuk bulan, 7 untuk hari dalam pekan, 365 untuk hari dalam tahun)

Fitur rasio turunan dibentuk untuk merangkum karakteristik beban. Rasio konsumsi tercatat dan rasio beban puncak dirumuskan pada Persamaan (2.8) dan (2.9).

$$metered_ratio = \frac{sm_1 + sm_2 + sm_3}{total_kwh} \quad (2.8)$$

$$peak_to_avg_ratio = \frac{daya_{puncak}}{daya_{rata-rata}} \quad (2.9)$$


Keterangan:

sm_1, sm_2, sm_3 = konsumsi tiga kanal sub-metering

$total_kwh$ = total konsumsi harian

$daya_puncak$ = daya tertinggi dalam sehari; $daya_rata-rata$ = daya rata-rata harian


2.2.9. Cross Validation



Gambar 2. 7 Cross Validation dengan TimeSeriesSplit

Cross-validation menilai kemampuan generalisasi model dengan membagi data menjadi beberapa lipatan latih dan uji. Pada data deret waktu, *k-fold* acak tidak tepat karena melanggar urutan waktu dan berisiko membocorkan informasi masa depan ke masa lalu. Karena itu dipakai *TimeSeriesSplit*, ketika data latih selalu mendahului data uji pada tiap lipatan (Aprihartha & Idham, 2024).


2.2.10. Hyperparameter Tuning



Gambar 2. 8 *Hyperparameter Tuning* pada Model *Machine Learning*

Hyperparameter adalah parameter yang ditetapkan sebelum pelatihan, seperti jumlah pohon, kedalaman maksimum, dan *learning rate*, yang nilainya tidak dipelajari dari data. Pemilihannya berpengaruh besar terhadap performa, sehingga diperlukan pencarian yang sistematis (Putri et al., 2025). *RandomizedSearchCV* menerapkan pencarian acak yang dipadukan dengan *cross-validation*, mencoba sejumlah kombinasi parameter secara acak dengan iterasi terbatas. Pendekatan ini lebih hemat komputasi dibanding pencarian menyeluruh dan cocok untuk algoritma dengan banyak parameter seperti *boosting* (Rizky et al., 2024).

2.2.11. Metrik Evaluasi Regresi



Gambar 2. 9 Ilustrasi Evaluasi Model Regresi

Evaluasi performa model regresi dapat dilakukan menggunakan beberapa metrik statistik, antara lain *Mean Absolute Error* (MAE), *Mean Absolute*

Percentage Error (MAPE), *Root Mean Square Error* (RMSE), dan koefisien determinasi (R^2) (Nurani et al., 2023).

RMSE mengukur akar rata-rata kuadrat galat dan peka terhadap galat besar, sebagaimana Persamaan (2.10).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.10)$$

MAE mengukur rata-rata galat absolut dalam satuan asli, sebagaimana Persamaan (2.11).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2.11)$$

MAPE menyatakan galat dalam persen sehingga mudah ditafsirkan lintas skala, sebagaimana Persamaan (2.12).

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (2.12)$$

R^2 menunjukkan proporsi variasi target yang dapat dijelaskan model, sebagaimana Persamaan (2.13).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2.13)$$

Keterangan:

y_i = nilai aktual

$\hat{y}_i$ = nilai prediksi

$\bar{y}$ = rata-rata nilai aktual

n = jumlah data

2.2.12. *Explainable AI* dan SHAP

Explainable AI adalah pendekatan untuk membuat keputusan model yang kompleks dapat dipahami manusia. SHAP adalah metode interpretasi berbasis teori permainan yang menghitung kontribusi tiap fitur terhadap suatu prediksi, baik

secara menyeluruh maupun pada kasus tunggal. Nilai kontribusi tiap fitur dihitung dengan menimbang selisih prediksi ketika fitur disertakan dan ketika tidak, dirata-ratakan atas berbagai kombinasi fitur. SHAP banyak dipakai untuk menjelaskan model *ensemble*, termasuk pada peramalan konsumsi listrik (Hadi et al., 2023).

2.2.13. Struktur Tarif Tenaga Listrik PLN dan Estimasi Tagihan

Tarif listrik rumah tangga di Indonesia disusun berjenjang menurut golongan daya, dari 450 VA hingga 6.600 VA, dengan tarif per kWh dan ketentuan biaya yang berbeda antar golongan, sebagaimana diatur dalam Peraturan Menteri ESDM No. 3 Tahun 2020 dan Keputusan Menteri ESDM No. 3 K/20/MEM/2021. Estimasi tagihan dihitung dari konsumsi dikalikan tarif golongan, ditambah biaya tetap bila berlaku, sebagaimana Persamaan (2.14).

$$\text{Tagihan} = (kWh \times \text{tarif}_{\text{per kWh}}) + \text{abonemen} \quad (2.14)$$

Bila hasil perhitungan lebih rendah dari tagihan minimum golongan tertentu, yang berlaku adalah tagihan minimum tersebut. Perancangan prediksi berbasis golongan tarif ini sejalan dengan penelitian terdahulu pada konsumsi rumah tangga (Saragih & Suryani, 2026).


2.2.14. Dataset individual Household Electric Power Consumption

Dataset Individual Household Electric Power Consumption dari UCI Machine Learning Repository memuat 2.075.259 pengukuran konsumsi listrik satu rumah tangga di Suresnes, Prancis, pada periode Desember 2006 hingga November 2010 dengan resolusi satu menit (Hebrail & Berard, 2012). Dataset mencakup daya aktif total dan tiga kanal sub-metering yang mewakili kelompok perangkat berbeda.

2.3. Metode Pengembangan Produk

Pengembangan model pada proyek ini mengikuti kerangka CRISP-DM (*Cross-Industry Standard Process for Data Mining*). Kerangka ini dipilih karena menyediakan tahapan yang baku dan terstruktur untuk *data mining*, mulai dari

pemahaman masalah hingga penerapan, sehingga banyak dipakai pada penelitian prediksi berbasis *machine learning* di Indonesia (Hasanah et al., 2021). CRISP-DM terdiri atas enam tahap yang berurutan, namun bersifat iteratif, ketika temuan pada tahap lanjut dapat mendorong perbaikan pada tahap sebelumnya. Keenam tahap beserta kegiatan yang dilakukan pada proyek ini diuraikan sebagai berikut.



Gambar 2. 10 Kerangka Kerja Metode CRISP-DM

2.3.1. Pemahaman Bisnis (*Business Understanding*)

Tahap ini menetapkan tujuan dan kriteria keberhasilan dari sudut pandang masalah yang diselesaikan. Masalah yang diangkat adalah ketidakmampuan pengguna rumah tangga memperkirakan konsumsi dan tagihan listrik sebelum periode penagihan berakhir. Dari masalah ini dirumuskan dua tujuan, yaitu memprediksi konsumsi energi listrik harian dalam satuan kWh dan mengestimasi tagihan bulanan berdasarkan golongan tarif PLN. Kriteria keberhasilan model ditetapkan pada galat yang rendah, dengan target MAPE di bawah 15%.

2.3.2. Pemahaman Data (*Data Understanding*)

Tahap ini mengenali sumber, karakteristik, dan kualitas data yang tersedia. Data utama adalah *Individual Household Electric Power Consumption* dari UCI Machine Learning Repository. Pada tahap ini dilakukan eksplorasi awal untuk memeriksa kelengkapan data, sebaran nilai konsumsi, keberadaan outlier, serta pola

musiman dan pola akhir pekan. Pemahaman ini menjadi dasar untuk menentukan langkah penyiapan data pada tahap berikutnya.

2.3.3. Persiapan Data (*Data Preparation*)

Tahap ini menyiapkan data mentah menjadi bentuk yang siap dimodelkan. Kegiatannya mencakup pembersihan data, konversi satuan ke kWh, agregasi dari resolusi per menit menjadi konsumsi harian, dan penyaringan hari dengan kelengkapan data di bawah ambang yang ditetapkan. Pada tahap ini juga dilakukan *feature engineering* untuk membentuk fitur yang informatif, meliputi fitur *sub-metering*, fitur temporal, fitur *lag*, dan *rolling statistics*. Tahap persiapan data umumnya menjadi bagian yang paling menyita waktu karena menentukan kualitas masukan model (Hasanah et al., 2021).

2.3.4. Pemodelan (*Modeling*)

Tahap ini melatih dan membandingkan beberapa algoritma. Tiga model dilatih, yaitu *Linear Regression* sebagai *baseline*, *Random Forest*, dan XGBoost. Validasi memakai *TimeSeriesSplit* agar urutan waktu tetap terjaga, dan hiperparameter *Random Forest* serta XGBoost disetel untuk meningkatkan performa. Pada tahap ini juga dilakukan *ablation study* untuk menilai kontribusi tiap kelompok fitur.

2.3.5. Evaluasi (*Evaluation*)

Tahap ini menilai performa model terhadap tujuan yang ditetapkan pada tahap pemahaman bisnis. Model diuji menggunakan metrik RMSE, MAE, MAPE, dan R^2 pada data uji. Model terbaik dipilih berdasarkan metrik tersebut, lalu diinterpretasikan menggunakan SHAP untuk mengetahui fitur yang paling berkontribusi terhadap prediksi. Hasil evaluasi dibandingkan dengan kriteria keberhasilan untuk menentukan apakah model layak diterapkan.

2.3.6. Penerapan (*Deployment*)

Tahap ini menerapkan model ke dalam aplikasi nyata. Model terbaik disimpan dalam bentuk file, lalu dimuat oleh layanan *backend* berbasis *FastAPI*. Hasil prediksi konsumsi dikonversi menjadi estimasi tagihan melalui modul tarif PLN yang mengikuti golongan daya. Antarmuka pengguna dibangun dengan *React*, sehingga pengguna dapat memasukkan data perangkat dan memperoleh estimasi konsumsi serta tagihan tanpa memerlukan perangkat IoT.

BAB III ANALISIS DAN PERANCANGAN

3.1. Pengumpulan Data

Pengumpulan data merupakan tahap penyediaan bahan pelatihan model. Karena penelitian ini berskema *supervised regression* berbasis deret waktu, data yang dibutuhkan adalah riwayat konsumsi energi listrik rumah tangga beresolusi tinggi yang tervalidasi secara ilmiah.

Individual Household Electric Power Consumption		
Donated on 8/29/2012		
Measurements of electric power consumption in one household with a one-minute sampling rate over a period of almost 4 years. Different electrical quantities and some sub-metering values are available.		
Dataset Characteristics	Subject Area	Associated Tasks
Multivariate, Time-Series	Physics and Chemistry	Regression, Clustering
Feature Type	# Instances	# Features
Real	2075259	9

Gambar 3. 1 Profil Dataset *Individual Household Electric Power Consumption*

Dataset primer adalah *Individual Household Electric Power Consumption (IHEPC)* dari UCI Machine Learning Repository. Dataset ini merekam konsumsi daya satu rumah tangga di Sceaux, Prancis, periode 16 Desember 2006 hingga 26 November 2010, resolusi per menit (2.075.259 baris). Dataset dipilih karena tersedia publik dan dapat direproduksi, memuat lebih dari tiga tahun sehingga variasi musiman tertangkap, dan meliputi tujuh variabel daya yang diuraikan pada tabel 3.1.

Tabel 3. 1 Variabel Mentah Dataset UCI IHEPC

Variabel	Satuan	Deskripsi
Global_active_power	kW	Daya aktif total rumah tangga
Global_reactive_power	kW	Daya reaktif
Voltage	V	Tegangan jaringan
Global_intensity	A	Arus total
Sub_metering_1	Wh/menit	Dapur (dishwasher, oven, microwave)
Sub_metering_2	Wh/menit	Laundry (mesin cuci, pengering, kulkas)
Sub_metering_3	Wh/menit	Pemanas air dan pendingin udara

 Appliances Energy Prediction Donated on 2/14/2017		
Experimental data used to create regression models of appliances energy use in a low energy building.		
Dataset Characteristics	Subject Area	Associated Tasks
Multivariate, Time-Series	Computer Science	Regression
Feature Type	# Instances	# Features
Real	19735	28

Gambar 3. 2 Profil Dataset *Appliances Energy Prediction*

Dataset pendukung *Appliances Energy Prediction* (Stambruges, Belgia, periode Januari–Mei 2016) digunakan secara terbatas pada tahap eksplorasi data untuk menguji hipotesis korelasi cuaca–konsumsi, bukan sebagai data pelatihan. Data dikumpulkan dengan mengunduh berkas mentah (127 MB) dari repositori UCI.

Penelitian ini tidak menggunakan data primer yang dikumpulkan langsung dari rumah tangga di Indonesia sehingga kemampuan generalisasi hasil menjadi salah satu keterbatasan penelitian. Data regulasi tarif untuk modul estimasi tagihan bersumber dari Peraturan Menteri ESDM No. 3 Tahun 2020 dan Keputusan Menteri ESDM No. 3 K/20/MEM/2021.

3.2. *Preprocessing Data*

Preprocessing mengubah data mentah beresolusi menit menjadi himpunan data harian siap-model yang bersih, konsisten satuan, dan bebas kebocoran data (*data leakage*). Prosedur terdiri atas langkah-langkah berikut.

1. Penggabungan dan penguraian waktu. Kolom `Date` dan `Time` digabung menjadi indeks datetime tunggal sebagai dasar agregasi temporal.
2. Konversi satuan. `Global_active_power` (kW) dikalikan 1/60 menjadi kWh per menit; nilai `Sub\_metering` (Wh/menit) dibagi 1000 menjadi kWh per menit, sehingga seluruh variabel daya berada pada satuan energi yang konsisten.
3. Agregasi harian. Data di-resample ke resolusi harian (`resample("D")`), menghasilkan variabel target `total\_kwh` sebagai akumulasi konsumsi per hari.

4. Penyaringan kelengkapan. Hari dengan kurang dari 80% data menit yang valid dibuang untuk mencegah hari dengan nilai hilang masif dihitung sebagai konsumsi rendah palsu.
5. Penanganan nilai hilang dan pencilan. Pencilan dideteksi menggunakan *Interquartile Range* dan dipertahankan, karena merepresentasikan konsumsi ekstrem yang sah seperti beban puncak musim dingin, bukan kesalahan pengukuran.

Setelah pembersihan, dilakukan rekayasa fitur untuk memperkaya representasi data. Keluaran tahap ini adalah himpunan data harian siap-model dengan 20 fitur dan 1 variabel target, disimpan sebagai `model\_ready\_dataset.csv`.

3.3. Penerapan Metode AI

Penelitian ini menerapkan *supervised learning* untuk tugas regresi, yaitu memetakan vektor fitur ke nilai kontinu `total\_kwh`. Metode yang dibandingkan mencakup satu model linear sebagai *baseline* dan dua model *ensemble*.

3.3.1. Rekayasa Fitur

Dua puluh fitur dibentuk dalam empat kelompok sebagaimana disajikan pada Tabel 3.2. Fitur temporal menggunakan transformasi siklis berbasis fungsi sinus dan kosinus untuk merepresentasikan pola periodik waktu sehingga periode yang berdekatan dalam satu siklus direpresentasikan sebagai nilai yang berdekatan. Sementara itu fitur baru digunakan untuk merepresentasikan pola musiman tanpa memasukkan variabel cuaca secara langsung.

Tabel 3. 2 Rancangan Fitur Model

Kategori	Fitur	Peran
Sub-metering (4)	sm1_kwh_day, sm2_kwh_day, sm3_kwh_day, metered_ratio	Proksi konsumsi kelompok perangkat
Temporal & cyclical (8)	month_sin/cos, dow_sin/cos, doy_sin/cos, is_weekend, season	Penanda pola harian, mingguan, dan musiman
Autoregresif (6)	lag_1_kwh, lag_7_kwh, lag_30_kwh, rolling_7d_mean, rolling_7d_std, rolling_30d_mean	Riwayat dan tren konsumsi
Metrik daya (2)	peak_power_kw, peak_to_avg_ratio	Karakteristik beban puncak

3.3.2. Model dan Justifikasi

1. *Linear Regression* sebagai *baseline* untuk menetapkan batas bawah kinerja yang harus dilampaui model kompleks.
2. *Random Forest*, model *ensemble* berbasis *bagging* yang menangkap hubungan non-linear dan relatif tidak sensitif terhadap *overfitting*.
3. *Extreme Gradient Boosting* (XGBoost), model *ensemble* berbasis boosting yang membangun pohon secara berurutan untuk mengoreksi galat residual.

3.3.3. Studi Ablasi

Untuk mengukur kontribusi tiap kelompok fitur, dirancang studi ablasi empat konfigurasi yang dievaluasi menggunakan Random Forest dengan skema validasi identik (Tabel 3.3).

Tabel 3. 3 Rancangan Konfigurasi Studi Ablasi

Konfigurasi	Komposisi Fitur	Jumlah Fitur
A	Hanya fitur perangkat	4
B	A + fitur temporal	12
C	B + fitur autoregresif	18
D	Seluruh fitur	20

Studi ablasi mengisolasi sumbangan tiap kelompok fitur terhadap penurunan galat. Konfigurasi dengan kinerja terbaik ditetapkan sebagai konfigurasi tetap pada tahap perbandingan antarmodel.

3.3.4. Penyetelan Hiperparameter


Penyetelan dilakukan terhadap *Random Forest* dan XGBoost menggunakan *RandomizedSearchCV* ($n_iter=30$). Pencarian acak dipilih karena secara komputasi lebih efisien dibanding pencarian *grid* penuh yang mengharuskan perhitungan di setiap kombinasi parameter.

3.3.5. Interpretabilitas

SHapley Additive exPlanations (SHAP) diterapkan untuk mengukur kontribusi tiap fitur terhadap prediksi, baik secara global maupun per kasus. SHAP dipilih karena menghasilkan atribusi yang konsisten secara teoretis dan dapat diuraikan per prediksi tunggal, sesuai kebutuhan komunikasi hasil kepada pengguna non-teknis.

3.4. Integrasi ke Aplikasi

Model yang telah dilatih diintegrasikan ke dalam aplikasi web *full-stack*. Arsitektur memisahkan *backend* (*FastAPI*, *Python*) dan *frontend* (*React*, *TypeScript*) yang berkomunikasi melalui REST API.



Gambar 3. 3 Arsitektur Sistem Aplikasi

Alur data prediksi dirancang sebagai berikut.

1. Pengguna memasukkan daftar perangkat (daya watt, jumlah unit, jam pemakaian per hari) dan golongan daya PLN melalui formulir.
2. Daya dan durasi tiap perangkat dikonversi ke kWh dan dipetakan ke kanal sub-metering melalui tabel pemetaan perangkat. Fitur temporal dibangun dari tanggal permintaan. Fitur autoregresif diisi menggunakan nilai default cold-start, yaitu rata-rata populasi dataset (25,86 kWh), karena pengguna baru tidak memiliki riwayat konsumsi.
3. Vektor 20 fitur disusun dalam urutan tetap sesuai Konfigurasi D, lalu diumpankan ke model XGBoost terlatih (*best_model.pkl*) untuk menghasilkan prediksi kWh harian dan proyeksi bulanan.

4. Prediksi bulanan diteruskan ke modul tarif berbasis aturan yang menghitung biaya pemakaian, abonemen, tagihan minimum, Pajak Penerangan Jalan, dan biaya administrasi sesuai golongan daya. Modul ini memuat delapan golongan tarif PLN.
5. Hasil ditampilkan sebagai rincian kWh dan tagihan; pengguna terotentikasi dapat menyimpan riwayat prediksi ke basis data.

Dua batas validitas integrasi dinyatakan secara eksplisit. Pertama, fitur autoregresif yang digunakan model tidak tersedia bagi pengguna baru sehingga digantikan dengan nilai *cold-start*, dan keterbatasan ini dijelaskan pada antarmuka aplikasi. Kedua, model dilatih menggunakan data rumah tangga dari luar Indonesia, sedangkan estimasi tagihan menggunakan struktur tarif PLN. Oleh karena itu, hasil prediksi bersifat estimasi dan tidak sepenuhnya merepresentasikan kondisi rumah tangga di Indonesia.

3.5. Evaluasi Hasil

3.5.1. Metrik Evaluasi

Untuk menilai performa model, digunakan empat metrik evaluasi regresi yang dirangkum pada Tabel 3.4.

Tabel 3. 4 Metrik Evaluasi

Metrik	Satuan/Bentuk	Alasan Pemilihan
RMSE	kWh	Sensitif terhadap galat besar; relevan karena kesalahan pada konsumsi tinggi bermakna secara biaya
MAE	kWh	Galat rata-rata absolut, terbaca langsung dalam satuan kWh
MAPE	persen	Galat relatif, standar pelaporan pada domain energi
R^2	rasio (0–1)	Proporsi variansi target yang dijelaskan model

3.5.2. Strategi Validasi

Validasi model dilakukan menggunakan *TimeSeriesSplit* dengan lima lipatan untuk menjaga urutan temporal data. Pendekatan *k-fold* konvensional tidak digunakan karena berpotensi menyebabkan kebocoran informasi dari data masa depan ke data pelatihan.

3.5.3. Prosedur Pengujian Bertahap

Evaluasi dirancang berjenjang agar setiap simpulan dapat ditelusuri:

1. Validasi deret waktu menggunakan *TimeSeriesSplit* untuk menilai konsistensi kinerja model pada periode yang berbeda.
2. Studi ablasi untuk mengevaluasi kontribusi masing-masing kelompok fitur terhadap performa model.
3. Perbandingan performa beberapa model menggunakan konfigurasi fitur yang sama.
4. Pengujian pada *hold-out* test set yang terdiri atas 20% data terakhir secara kronologis untuk mengukur kemampuan generalisasi model pada data yang belum pernah dilihat.
5. Analisis residual dan SHAP untuk mengidentifikasi pola kesalahan prediksi serta memahami pengaruh fitur terhadap hasil prediksi.

Kriteria keberhasilan yang ditetapkan di muka: MAPE di bawah 15% pada data uji, dan model ensemble terbaik harus melampaui *baseline* linear pada RMSE dan R^2 .

BAB IV HASIL DAN PEMBAHASAN

4.1. Pengumpulan Data

Pengumpulan data primer menghasilkan berkas mentah *Individual Household Electric Power Consumption* berukuran 127 MB yang memuat 2.075.259 baris pengukuran beresolusi per menit, mencakup periode 16 Desember 2006 hingga 26 November 2010 (lebih dari 47 bulan). Seluruh tujuh variabel daya tersedia lengkap sesuai deskripsi pada Tabel 3.1, sehingga dataset memenuhi syarat sebagai sumber pelatihan model regresi deret waktu.

Dataset pendukung *Appliances Energy Prediction* terhimpun sebanyak 19.735 baris (resolusi 10 menit, 137 hari). Verifikasi awal menunjukkan dataset ini mengecualikan beban HVAC (*Heating, Ventilation, and Air Conditioning*) dan tidak mencakup musim panas, yang menyebabkan pengaruh cuaca terhadap konsumsi energi tampak relatif rendah. Oleh karena itu, dataset ini digunakan hanya untuk menguji hipotesis korelasi cuaca–konsumsi pada tahap eksplorasi, bukan sebagai data pelatihan. Keputusan ini dibuat untuk menyesuaikan dengan batasan penelitian. Ringkasan kedua dataset disajikan pada Tabel 4.1.

Tabel 4. 1 Ringkasan Dataset yang Terkumpul

Aspek	UCI IHEPC (Primer)	UCI Appliances (Pendukung)
Jumlah baris	2.075.259	19.735
Resolusi	Per menit	Per 10 menit
Periode	16 Des 2006 - 26 Nov 2010	11 Jan - 27 Mei 2016
Cakupan hari	1.442 hari	138 hari
Jumlah kolom	9	29
Peran dalam proyek	Pelatihan dan evaluasi model	Validasi hipotesis cuaca pada EDA

Durasi pengamatan lebih dari tiga tahun memadai untuk menangkap variasi musiman penuh, yang menjadi prasyarat pembentukan fitur musiman. Keterbatasan utama yang melekat sejak tahap ini adalah sifat data yang berasal dari satu rumah tangga di iklim kontinental, sehingga seluruh kesimpulan kinerja model berlaku pada konteks tersebut dan tidak dapat digeneralisasi ke populasi rumah tangga Indonesia.

4.2. Preprocessing Data

Tahapan *preprocessing* menghasilkan dataset siap model berukuran 1.390 baris dan 21 kolom (20 fitur dan satu target). Transformasi dilakukan dalam lima langkah berurutan:

1. Kolom `Date` dan `Time` digabung menjadi indeks `datetime`.
2. Satuan dikonversi agar konsisten dalam kWh: `Global\_active\_power` (kW) dikalikan 1/60 menjadi kWh per menit, dan ketiga kanal `Sub\_metering` (Wh per menit) dibagi 1.000 menjadi kWh per menit.
3. Data diagregasi ke resolusi harian melalui *resample("D")*, menghasilkan total konsumsi per hari sebagai variabel target.
4. Hari dengan kelengkapan data di bawah 80% dibuang untuk mencegah hari dengan nilai hilang masif dihitung sebagai konsumsi rendah palsu. Jumlah hari berkurang dari 1.442 menjadi 1.420; rata-rata kelengkapan hari tersisa 99,96% dengan nilai minimum 87,64%.
5. Dua puluh fitur direkayasa mencakup fitur sub-metering, fitur *encoding cyclical* (sin/cos transformasi pada bulan, hari dalam minggu, dan hari dalam tahun untuk menangkap pola periodik), fitur *lag* (nilai konsumsi periode sebelumnya dihasilkan melalui operasi `shift(1)`, `shift(7)`, `shift(30)` untuk memperoleh `lag\_1\_kwh`, `lag\_7\_kwh`, `lag\_30\_kwh`), *rolling statistics* (rata-rata dan simpangan baku bergerak), dan metrik daya (beban puncak harian dan rasio puncak terhadap rata-rata). Inisialisasi fitur `lag\_30\_kwh` dan `rolling\_30d\_mean` menghasilkan nilai kosong pada 30 hari pertama sehingga baris tersebut dibuang, menghasilkan dataset final 1.390 baris.

Dataset final berisi 1.390 baris pada rentang 16 Januari 2007 sampai 26 November 2010 tanpa nilai hilang. Reduksi data per tahap dirangkum pada Tabel 4.2.

Tabel 4. 2 Hasil Reduksi Data per Tahap *Preprocessing*

Tahap	Jumlah Baris/Hari	Keterangan
Data mentah (per menit)	2.075.259 baris	1.442 hari kalender

Tahap	Jumlah Baris/Hari	Keterangan
Agregasi harian	1.442 hari	-
Filter kelengkapan $\geq 80\%$	1.420 hari	22 hari dibuang
Drop NaN inisialisasi lag/rolling 30 hari	1.390 hari	Dataset final, missing values = 0


Statistik target `total_kwh` pada dataset final disajikan pada Tabel 4.3. Konsumsi harian rata-rata 25,86 kWh dengan simpangan baku 9,65 kWh, rentang 4,17 sampai 67,16 kWh, dan skewness 0,426 yang menandakan distribusi sedikit miring ke kanan. Deteksi outlier berbasis IQR (batas bawah 1,56 kWh; batas atas 49,24 kWh) menemukan 26 hari konsumsi ekstrem, setara 1,9% data. Sesuai keputusan rancangan, outlier tidak dibuang karena merepresentasikan kejadian konsumsi nyata yang harus dapat diprediksi model.

Tabel 4. 3 Statistik Deskriptif Target `total\_kwh`

Statistik	Nilai (kWh/hari)
Mean	25,86
Standar deviasi	9,65
Minimum	4,17
Kuartil 1 / Median / Kuartil 3	19,44 / 25,61 / 31,36
Maksimum	67,16
Outlier IQR	26 hari (1,9%), tidak dibuang

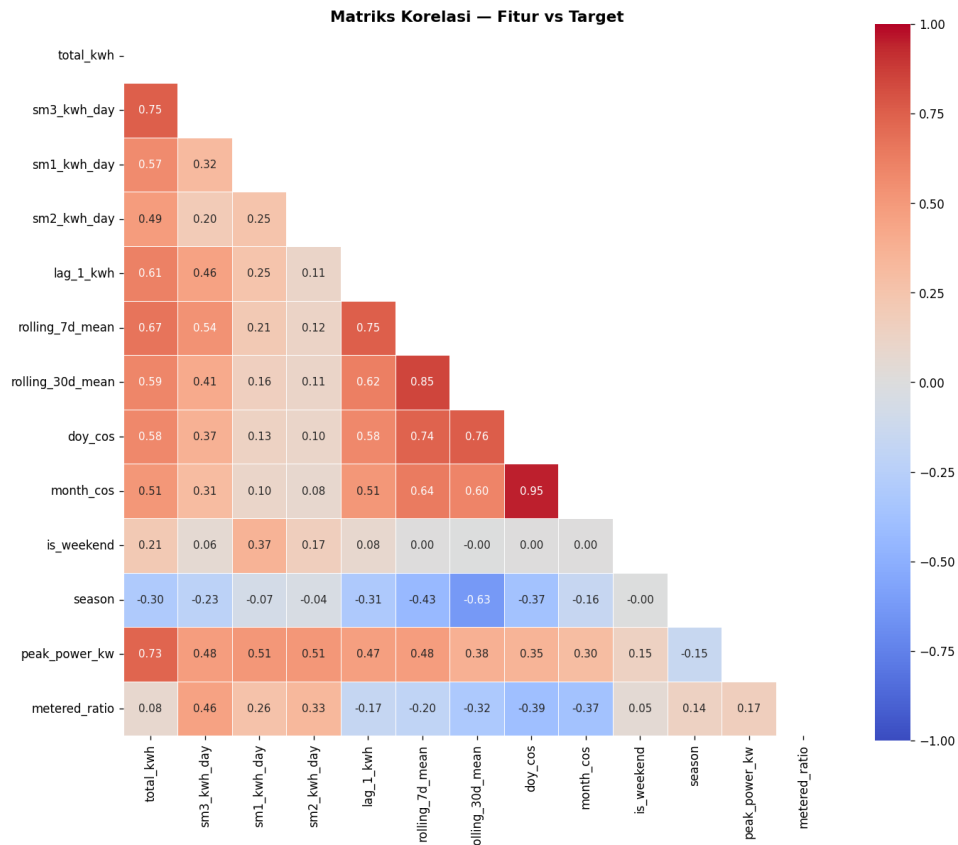


Gambar 4. 1 Pola Deret Waktu Konsumsi Energi Harian Hasil Agregasi (2007-2010)




Gambar 4. 2 Distribusi Konsumsi Energi Harian dan Perbandingan Musiman

Eksplorasi pola temporal memperlihatkan dua pola yang konsisten. Pertama, pola musiman terlihat pada Gambar 4.1: rata-rata konsumsi musim dingin 33,29 kWh/hari, musim panas 17,42 kWh/hari, sedangkan musim semi dan gugur berada di antaranya (26,48 dan 27,22 kWh/hari). Kedua, efek akhir pekan menunjukkan konsumsi rata-rata Sabtu sampai Minggu 29,12 kWh/hari, lebih tinggi 4,54 kWh (+18,5%) dibanding hari kerja (24,58 kWh/hari) sebagaimana terlihat pada Gambar 4.2. Kedua pola ini menjadi dasar dimasukkannya fitur siklikal dan `is\_weekend` ke dalam himpunan fitur.



Gambar 4. 3 Heatmap Korelasi Antar Fitur



Gambar 4. 4 Korelasi Fitur terhadap Target `total\_kwh`

Analisis korelasi pada Gambar 4.3 dan Gambar 4.4 menempatkan `sm3\_kwh\_day` ($r = 0,753$) dan `peak\_power\_kw` ($r = 0,729$) sebagai prediktor terkuat, diikuti `rolling\_7d\_mean` ($r = 0,669$) dan `lag\_1\_kwh` ($r = 0,614$). Di antara fitur siklikal, `doy\_cos` ($r = 0,584$) merupakan *proxy* musiman terkuat, menunjukkan bahwa informasi musiman dapat ditangkap dari posisi tanggal dalam tahun tanpa memerlukan data cuaca eksplisit.

4.3. Pengolahan Data

4.3.1. Hasil *Baseline*


Linear Regression dengan 20 fitur penuh dijalankan sebagai *baseline*. Hasil validasi silang adalah RMSE $1,666 \pm 0,331$ kWh, MAE $1,253 \pm 0,265$ kWh, MAPE $6,36\% \pm 2,09\%$, dan R^2 $0,9623 \pm 0,0110$. Nilai ini menjadi ambang pembanding. Model yang lebih kompleks hanya dapat dibenarkan apabila melampaui angka tersebut.

4.3.2. Hasil Studi Ablasi

Studi ablasi dijalankan menggunakan Random Forest pada empat konfigurasi fitur. Hasil lengkap disajikan pada Tabel 4.4 dan divisualisasikan pada Gambar 4.5.

Tabel 4. 4 Tabel Hasil Studi Ablasi (*Random Forest, TimeSeriesSplit* 5-fold)

Konfigurasi	Jumlah Fitur	RMSE (kWh)	MAE (kWh)	MAPE
A (Device Only)	4	$2,484 \pm 0,916$	$1,760 \pm 0,678$	$8,23\% \pm 4,82\%$
B (+ Temporal)	12	$2,881 \pm 0,760$	$2,137 \pm 0,546$	$9,78\% \pm 3,89\%$
C (+ Autoregressive)	18	$3,093 \pm 0,752$	$2,305 \pm 0,543$	$10,56\% \pm 4,02\%$
D (Full)	20	$1,949 \pm 0,825$	$1,345 \pm 0,637$	$6,73\% \pm 4,09\%$



Gambar 4. 5 Hasil Studi Ablasi Empat Konfigurasi Fitur

Hasil ablasi tidak monoton. Penambahan fitur temporal saja (A ke B) menaikkan RMSE 0,396 kWh, dan penambahan fitur autoregressive tanpa metrik daya (B ke C) menaikannya lagi 0,213 kWh. Konfigurasi penuh (D) yang menggabungkan seluruh kelompok fitur termasuk metrik daya (*peak_power_kw*, *peak_to_avg_ratio*) menghasilkan RMSE terendah, dengan perbaikan total A ke D sebesar 0,535 kWh dan kenaikan R^2 0,0307. Hal ini dapat diartikan bahwa tidak ada satu kelompok fitur yang dominan secara terpisah; kontribusi terbesar muncul ketika seluruh kelompok digabungkan.

4.3.3. Hasil Perbandingan Model

Tiga algoritma dibandingkan pada konfigurasi fitur identik (Config D). Hasilnya disajikan pada Tabel 4.5.

Tabel 4. 5 Perbandingan Model Sebelum dan Sesudah *Tuning* (Config D, *TimeSeriesSplit* 5-fold)

Model	RMSE (kWh)	MAE (kWh)	MAPE
Linear Regression (baseline)	1,666 ± 0,331	1,253 ± 0,265	6,36% ± 2,09%
Random Forest	1,925 ± 0,813	1,320 ± 0,624	6,64% ± 4,15%
XGBoost	1,751 ± 0,714	1,219 ± 0,490	6,27% ± 4,17%
Random Forest (tuned)	1,993 ± 0,654	1,411 ± 0,475	7,18% ± 4,24%
XGBoost (tuned)	1,351 ± 0,479	0,907 ± 0,345	4,56% ± 2,48%

Pada konfigurasi bawaan, Linear Regression mengungguli Random Forest maupun XGBoost pada RMSE dan R^2 . Penyebabnya dapat ditelusuri ke sifat data: komponen sub-metering merupakan bagian aditif dari total konsumsi, sehingga


hubungan target dengan beberapa fitur kunci mendekati linear dan model linear sudah kompetitif tanpa penyetelan apa pun. Keunggulan model ensemble baru terlihat setelah hiperparameternya disetel.

4.3.4. Hasil Penyetelan Hiperparameter

Penyetelan memakai *RandomizedSearchCV* dengan 30 kombinasi acak dan validasi *TimeSeriesSplit* lima lipatan, menghasilkan 150 *fit* per model terhadap ruang pencarian 576 kombinasi untuk *Random Forest* dan 82.944 kombinasi untuk XGBoost. Penyetelan *Random Forest* tidak memperbaiki performa dengan RMSE validasi silang 1,993 kWh, lebih buruk dari konfigurasi bawaan. Penyetelan XGBoost memberikan hasil sebaliknya: RMSE turun dari 1,751 menjadi 1,351 kWh, MAPE turun dari 6,27% menjadi 4,56%, dan R^2 naik menjadi 0,9742. Kombinasi hiperparameter terbaik XGBoost disajikan pada Tabel 4.6.

Tabel 4. 6 Hiperparameter Terbaik XGBoost Hasil Tuning

Hiperparameter	Nilai
n_estimators	300
learning_rate	0,05
max_depth	6
min_child_weight	3
subsample	0,6
colsample_bytree	1,0
gamma	0,1
reg_alpha	0
reg_lambda	1,5



Gambar 4. 6 Perbandingan Performa Model Sebelum dan Sesudah Penyetelan

XGBoost (tuned) terpilih sebagai model final dan menjadi satu-satunya model yang melampaui *baseline* linear pada seluruh metrik.


4.4. Integrasi ke Aplikasi

Model final XGBoost (*tuned*) dilatih ulang pada seluruh 1.390 sampel sebelum disimpan, agar model produksi memanfaatkan semua data yang tersedia. Model diserialisasi sebagai `best_model.pkl` (723,6 KB) bersama berkas `model_metadata.json` yang menyimpan nama model, tanggal pelatihan, jumlah sampel, dan daftar 20 nama fitur dengan urutan tetap yang wajib dipertahankan saat inferensi.

Modul tarif PLN diimplementasikan sebagai modul berbasis aturan yang mengonversi prediksi kWh menjadi estimasi tagihan untuk delapan golongan daya. Perhitungan mencakup biaya pemakaian (dengan skema blok khusus untuk R1/450VA), tagihan minimum, Pajak Penerangan Jalan 3%, dan biaya administrasi. Modul diverifikasi dengan kasus uji konsumsi 120 kWh/bulan; hasilnya pada Tabel 4.7 sesuai dengan struktur tarif yang berlaku. Golongan bersubsidi menghasilkan tagihan lebih rendah, sedangkan golongan non-subsidi 1.300 VA ke atas konvergen pada nilai yang sama karena tarif per kWh-nya identik (Rp 1.444). Perbandingan tagihan antar golongan divisualisasikan pada Gambar 4.7.

Tabel 4. 7 Hasil Verifikasi Modul Tarif PLN (Konsumsi 120 kWh/Bulan)

Golongan	Estimasi Tagihan
R1/450VA	Rp 64.874
R1/900VA-RTM	Rp 97.628
R1/900VA	Rp 169.357
R1/1300VA	Rp 180.728
R1/2200VA	Rp 180.728
R2/3500VA	Rp 180.728
R2/5500VA	Rp 180.728
R3/6600VA	Rp 180.728



Gambar 4. 7 Perbandingan Estimasi Tagihan Antar Golongan Tarif PLN

Rangkaian model dan tarif diuji *end-to-end* pada tanggal pertama data uji, 11 Februari 2010. Model memprediksi konsumsi 23,03 kWh terhadap nilai aktual 22,83 kWh, selisih 0,20 kWh. Prediksi diproyeksikan menjadi 690,8 kWh untuk 30 hari, lalu dikonversi menjadi estimasi tagihan per golongan, misalnya Rp 453.301 untuk R1/900VA-RTM dan Rp 1.029.640 untuk R1/1300VA. Demonstrasi ini menunjukkan komponen prediksi dan tarif bekerja dalam satu rangkaian.

Aplikasi web dibangun dengan backend FastAPI dan frontend React. *Backend* memuat model melalui pola singleton saat aplikasi dimulai dan membangun 20 fitur dari masukan perangkat pengguna: jenis perangkat dipetakan ke grup `sub-metering`, `peak\_power\_kw` dihitung dari beban terbesar, fitur temporal diturunkan dari tanggal berjalan, dan fitur *lag/rolling* diisi nilai *cold-start* dari statistik populasi dataset. Sembilan *endpoint* yang diekspos dirangkum pada Tabel 4.8.

Tabel 4. 8 Daftar Endpoint API Hasil Implementasi

Method	Path	Fungsi
POST	/api/v1/auth/register	Pendaftaran akun
POST	/api/v1/auth/login	Masuk dan penerbitan token
POST	/api/v1/auth/refresh	Rotasi refresh token
POST	/api/v1/predict	Prediksi tanpa penyimpanan
POST	/api/v1/predictions	Prediksi dan simpan ke basis data
GET	/api/v1/predictions	Daftar histori (paginasi)
GET	/api/v1/predictions/{id}	Detail satu prediksi

Method	Path	Fungsi
DELETE	/api/v1/predictions/{id}	Hapus prediksi
GET	/health	Status API dan model

Frontend menyediakan lima halaman, yaitu Login, Register, Prediksi, Histori, dan Detail Prediksi, dengan tabel perangkat dinamis, pemilihan golongan daya, serta rincian hasil prediksi dan tagihan. Tangkapan layar antarmuka dan alur penggunaan dari pengisian formulir hingga penyimpanan histori ditampilkan pada Gambar 4.8 sampai Gambar 4.12.

Gambar 4. 8 Halaman Login Aplikasi

Gambar 4. 9 Halaman Registrasi Aplikasi

WATTCAST
Prediction
History
Fathu Sign out

Prediction

Input your household devices to estimate electricity consumption and PLN bill.

WattCast membantu memperkirakan konsumsi listrik rumah tangga dan kisaran tagihan PLN berdasarkan jenis perangkat, jumlah pemakaian, daya, dan lama penggunaan per hari.

1 - DEVICES

DEVICE	QTY	WATT	HOURS/DAY	kWh/DAY
Televisi / TV	1	100 W	5 h	0.500
Komputer Desktop	1	200 W	6 h	1.200
Kipas Angin	2	50 W	8 h	0.800

+ Add Device

Total Input: **2.500 kWh/day** Peak device: **0.200 kW**

2 - ESTIMATION PARAMETERS

PLN TARIF CLASS (GOLONGAN)

R1 / 900VA – Subsidi RTM

PROJECTION (DAYS)

30

CALCULATE PREDICTION RESET

3 - RESULT

PREDICTION RESULT

kWh / Day	kWh / 30 Days	Estimated Bill
16.059 kWh	481.78 kWh	Rp 323.070

TARIFF BREAKDOWN – R1/900VA-RTM

Usage charge	Rp 291.476
Monthly subscription	Rp 28.000
PPJ (3%)	Rp 9.344
Admin fee	Rp 2.250
TOTAL	Rp 323.070

Subsidized tariff – actual bill may differ based on household eligibility.

DEVICE GROUPS

Kitchen (SM1) 0.000 kWh 0.0%	Laundry + Fridge (SM2) 0.000 kWh 0.0%	AC + Water Heater (SM3) 0.000 kWh 0.0%	Lighting & Others 2.500 kWh 100.0%
------------------------------------	---	--	--

DEVICE CONTRIBUTIONS

Device	Qty	Watt	Hours	kWh/Day	Group
Televisi / TV	1	100W	5h	0.500	Lighting & Others
Komputer Desktop	1	200W	6h	1.200	Lighting & Others
Kipas Angin	2	50W	8h	0.800	Lighting & Others

Autoregressive features (lag, rolling) use dataset population defaults (25.86 kWh). Predictions improve as history accumulates.

SAVE TO HISTORY CALCULATE AGAIN

© 2026 WATTCAST

Gambar 4. 10 Halaman Formulir Prediksi dengan Hasil Prediksi dan Tarif Tagihan

WATTCAST
Prediction
History
Fathu Sign out

Prediction History

3 saved predictions

+ New Prediction

Date	Golongan	kWh/Day	kWh/Month	Total Bill	
13 Jun 2026, 22.11	R1/900VA-RTM	16.06 kWh	481.8 kWh	Rp 323.070	View →
13 Jun 2026, 12.38	R1/900VA-RTM	7.58 kWh	227.4 kWh	Rp 164.559	View →
13 Jun 2026, 12.17	R1/900VA-RTM	14.70 kWh	441.1 kWh	Rp 297.736	View →

© 2026 WATTCAST

Gambar 4. 11 Halaman Histori Prediksi Tersimpan

WATTCAST

Prediction

History

Fathu Sign out

- History

Delete

Prediction Detail

Sab, 13 Jun 2020, 22:11

RESULTS

kWh / Day	kWh / 30 Days	Estimated Bill
16.059 kWh	481.78 kWh	Rp 323.070

INPUT DEVICES

Device	Qty	Watt	Hours/Day	kWh/Day
Televisi / TV	1	100W	5h	0.500
Komputer Desktop	1	200W	6h	1.200
Kipas Angin	2	50W	8h	0.800

TARIFF BREAKDOWN - R1/900VA-RTH (900 VA)

Consumption	481.78 kWh
Usage charge	Rp 291.476
Monthly subscription	Rp 20.000
PPJ (3%)	Rp 9.344
Admin fee	Rp 2.250
TOTAL	Rp 323.070

ID: 7e4dce72-1a64-4e94-9726-0f119a6a14c8

© 2020 WATTCAST

Gambar 4. 12 Halaman Detail Historis Prediksi

Dua batas validitas integrasi yang dinyatakan pada Bab III tetap berlaku pada hasil implementasi. Pertama, prediksi untuk pengguna baru memakai nilai *cold-start* pada fitur *autoregressive*, dan keterangan ini ditampilkan pada antarmuka hasil. Kedua, model dilatih pada data rumah tangga Prancis sementara tagihan dihitung dengan tarif PLN, sehingga hasil bersifat estimasi.

Setelah implementasi selesai, aplikasi dievaluasi melalui User Acceptance Testing (UAT) sebagai bagian dari fase Operate. Pengujian dilakukan oleh 2 rekan tim yang berperan sebagai pengguna untuk memvalidasi bahwa seluruh fungsi aplikasi dapat dijalankan sesuai kebutuhan dan alur penggunaan yang telah dirancang.

Setiap responden menjalankan lima skenario utama, yaitu registrasi dan login, pengisian formulir perangkat beserta pemilihan golongan daya, prediksi konsumsi dan estimasi tagihan, penyimpanan serta peninjauan histori prediksi, dan penghapusan prediksi yang tersimpan. Hasil pengujian menunjukkan bahwa seluruh skenario berhasil dijalankan tanpa kesalahan sistem dan menghasilkan keluaran yang sesuai. Temuan ini menunjukkan bahwa fitur-fitur utama aplikasi dapat digunakan dengan baik oleh pengguna dan berjalan sesuai dengan alur yang dirancang. Rincian skenario dan hasil pengujian disajikan pada Lampiran C.

4.5. Hasil Evaluasi


Evaluasi akhir dilakukan pada hold-out test set berupa 20% data terakhir secara kronologis. Model dilatih pada 1.112 hari (16 Januari 2007 sampai 10 Februari 2010) dan diuji pada 278 hari (11 Februari sampai 26 November 2010) yang tidak pernah dilihat selama pelatihan maupun penyetelan. Hasilnya disajikan pada Tabel 4.9.

Tabel 4. 9 Hasil Evaluasi Model Final pada *Hold-out Test Set*

Metrik	Nilai	Kriteria Keberhasilan	Status
RMSE	0,826 kWh	-	-
MAE	0,558 kWh	-	-
MAPE	2,69%	< 15%	Tercapai
R ²	0,9873	Melampaui baseline	Tercapai

MAPE 2,69% berada di bawah ambang 15% yang ditetapkan pada tahap pemahaman bisnis. Performa hold-out lebih baik daripada rata-rata validasi silang (RMSE 0,826 berbanding 1,351 kWh). Dua faktor menjelaskan selisih ini: model hold-out dilatih pada porsi data yang lebih besar dibanding lipatan-lipatan awal validasi silang, dan periode uji 2010 didominasi musim dengan konsumsi menengah yang relatif lebih mudah diprediksi. Rentang performa yang wajar untuk dilaporkan karena itu mencakup keduanya: hasil validasi silang sebagai estimasi konservatif, hasil hold-out sebagai estimasi pada kondisi data terkini.

Analisis residual pada Gambar 4.13 memperlihatkan sebaran galat di sekitar nol tanpa pola sistematis terhadap waktu maupun nilai prediksi, sehingga tidak ada indikasi bias musiman pada periode uji. Galat terbesar terkonsentrasi pada hari konsumsi ekstrem, konsisten dengan keputusan mempertahankan outlier dalam data pelatihan.




Gambar 4. 13 Hasil Evaluasi Prediksi vs Aktual dan Analisis Residual pada *Hold-out Test Set*


Interpretasi model dilakukan dengan SHAP TreeExplainer pada 278 observasi data uji. Peringkat sepuluh fitur teratas berdasarkan rata-rata SHAP disajikan pada Tabel 4.10, dengan visualisasi global importance pada Gambar 4.14 dan beeswarm plot pada Gambar 4.15.

Tabel 4. 10 Sepuluh Fitur Teratas Berdasarkan Rata-rata SHAP


Peringkat	Fitur	Rata-rata SHAP (kWh)
1	peak_power_kw	5057
2	peak_to_avg_ratio	2985
3	sm3_kwh_day	2885
4	sm1_kwh_day	0,371
5	sm2_kwh_day	0,333
6	doy_cos	0,325
7	rolling_7d_mean	0,315
8	metered_ratio	0,301
9	lag_1_kwh	0,145
10	rolling_30d_mean	0,053



Gambar 4. 14 SHAP Kepentingan Fitur pada Final Model



Gambar 4. 15 Arah dan Besaran Pengaruh Fitur dalam SHAP Beeswarm Plot



Gambar 4. 16 SHAP Waterfall pada Tiga Representative Case

Seluruh kriteria keberhasilan yang ditetapkan di muka tercapai: MAPE pada data uji di bawah 15%, dan model ensemble terbaik melampaui baseline linear pada RMSE dan R^2 . Hasil ini berlaku dalam batas yang dinyatakan pada Bab III. Data berasal dari satu rumah tangga beriklim kontinental, proyeksi bulanan merupakan aproksimasi linear dari prediksi harian, dan fitur autoregressive pada inferensi pengguna baru diisi nilai cold-start.

BAB V KESIMPULAN

5.1 Kesimpulan

Proyek akhir ini membangun model *ensemble learning* untuk memprediksi konsumsi energi listrik harian rumah tangga dan mengestimasi tagihan bulanan per golongan tarif PLN, dan mengintegrasikannya ke dalam aplikasi web.

Model *ensemble learning* mampu memprediksi konsumsi harian secara akurat. Model final XGBoost yang telah disetel mencapai MAPE 2,69% pada hold-out test set, dengan RMSE 0,826 kWh dan R^2 0,9873. Nilai MAPE ini berada di bawah ambang keberhasilan 15%, sehingga fitur penggunaan perangkat dan pola temporal sudah memadai untuk memprediksi konsumsi harian tanpa sensor per perangkat.

Performa terbaik dicapai XGBoost setelah penyetelan hiperparameter, dengan RMSE 1,351 kWh, MAE 0,907 kWh, MAPE 4,56%, dan R^2 0,9742 pada validasi silang. Ada catatan di sini. Pada konfigurasi bawaan, Linear Regression mengungguli kedua model ensemble karena sebagian fitur kunci berhubungan mendekati linear dengan target. Keunggulan model ensemble baru tampak setelah penyetelan, dan hanya XGBoost yang melampaui baseline linear pada semua metrik.

Kontribusi kelompok fitur tidak terpusat pada satu kelompok. Studi ablasi menunjukkan konfigurasi fitur penuh memberi RMSE terendah, sedangkan penambahan kelompok temporal atau autoregresif secara parsial justru menurunkan performa. Analisis SHAP menempatkan beban puncak harian `'peak_power_kw'` sebagai fitur paling berpengaruh dengan rata-rata SHAP 5,057 kWh, diikuti rasio puncak terhadap rata-rata dan konsumsi grup pemanas air dan AC. Akurasi tertinggi berasal dari gabungan seluruh kelompok fitur, bukan dari fitur autoregresif saja seperti dugaan awal.

Prediksi konsumsi diintegrasikan dengan struktur tarif PLN lewat modul berbasis aturan untuk delapan golongan daya. Modul ini mengubah prediksi kWh harian menjadi proyeksi bulanan dan estimasi tagihan dengan menghitung biaya pemakaian, tagihan minimum, Pajak Penerangan Jalan, dan biaya administrasi.

Seluruh rangkaian dari masukan perangkat pengguna sampai estimasi tagihan berjalan dalam satu aplikasi web berbasis *FastAPI* dan *React*, dan dapat dipakai tanpa perangkat IoT maupun smart meter.

Keempat tujuan proyek akhir tercapai. Model prediksi akurat sudah dibangun, algoritma terbaik sudah ditentukan, kontribusi fitur sudah diidentifikasi lewat SHAP, dan modul estimasi tagihan sudah terintegrasi dalam aplikasi. Hasil ini berlaku dalam batas yang ditetapkan: data dari satu rumah tangga beriklim kontinental di Prancis, prediksi pada tingkat konsumsi harian, dan estimasi tagihan yang bersifat perkiraan.

5.2 Saran

Saran utama menyangkut asal data. Model dilatih pada data satu rumah tangga di Prancis yang beriklim kontinental, sehingga pola musiman dan perilaku konsumsi yang dipelajarinya tidak dapat langsung digeneralisasi ke rumah tangga Indonesia. Penelitian lanjutan sebaiknya mengumpulkan data konsumsi langsung memakai sensor IoT yang dipasang secara real-time pada perumahan lokal di Batam. Data primer seperti ini menangkap pola iklim tropis dan kebiasaan konsumsi masyarakat setempat, sehingga model yang dihasilkan lebih valid untuk konteks Indonesia dan tidak bergantung pada asumsi dari iklim yang berbeda.

Beberapa arah lain dapat melengkapinya. Prediksi untuk pengguna baru kini memakai nilai cold-start karena riwayat konsumsi belum ada; menyimpan input pengguna dari waktu ke waktu akan mengisi fitur lag dan rolling dengan nilai aktual dan memperbaiki akurasi pada pemakaian berikutnya. Proyeksi bulanan yang sekarang dihitung dari prediksi harian dikali jumlah hari dapat diganti pendekatan peramalan deret waktu agar variasi antar hari ikut terbaca. Struktur tarif PLN sebaiknya dibuat agar nilainya bisa diperbarui dari sumber resmi tanpa mengubah kode, karena tarif dapat berubah. Pada sisi pemanfaatan, hasil prediksi paling tepat dibaca sebagai estimasi untuk perencanaan, bukan tagihan resmi, sejalan dengan upaya efisiensi energi pada SDGs Tujuan ke-7.

DAFTAR PUSTAKA

- Aditya Pratama, M., Munawaroh, M., & Joko Pranoto, W. (2024). Perbandingan Performa Algoritma Linear Regresi dan Random Forest untuk Prediksi Harga Bawang Merah di Kota Samarinda. *Jurnal Ilmu Teknik*, 1(2), 172–182. <https://doi.org/https://doi.org/10.62017/tekonik.v1i2.468>
- Aprihartha, Moch. A., & Idham, I. (2024). Optimization of Classification Algorithms Performance with k-Fold Cross Validation. *EIGEN MATHEMATICS JOURNAL*, 7(2), 61–66. <https://doi.org/10.29303/emj.v7i2.212>
- Churniansyah, F., & Wahyu Utomo, D. (2024). Teknik Bagging pada Ensemble Learning untuk Kategorisasi Produk E-Commerce. *Pendrikan Kidul, Kec. Semarang Tengah*, 50131(207). <https://doi.org/10.25077/TEKNOSI.v10i1.2024.92-80>
- Fauzi, M. R., Handika, M., Awinanto, A., Wahidin, A. J., Rahmatullah, B., & Kurniawati, I. (2025). Analisis Perbandingan Kinerja Algoritma Linear Regression, Random Forest, dan XGBoost dalam Prediksi Harga Rumah. *RIGGS: Journal of Artificial Intelligence and Digital Business*, 4(4), 1541–1548. <https://doi.org/10.31004/riggs.v4i4.3620>
- Hadi, A. F., Zulva, A. F., Hakim, M. L., Saputra, M. D., & Sadiyah, H. (2023). *Implementasi Explainable Machine Learning: Visualisasi Global Explainability and Local Interpretability pada Analisis Sentimen dengan SHAP dan LIME*. <https://doi.org/10.1234/bias.v17i1.219>
- Hasanah, M. A., Soim, S., & Handayani, A. S. (2021). Implementasi CRISP-DM Model Menggunakan Metode Decision Tree dengan Algoritma CART untuk Prediksi Curah Hujan Berpotensi Banjir. *Journal of Applied Informatics and Computing*, 5(2), 103–108. <https://doi.org/10.30871/jaic.v5i2.3200>
- Hebrail, G., & Berard, A. (2012). *Individual Household Electric Power Consumption*. UCI Machine Learning Repository. <https://doi.org/https://doi.org/10.24432/C58K54>
- Kementerian ESDM. (2024, January 15). *Konsumsi Listrik Masyarakat Meningkat, Tahun 2023 Capai 1.285 kWh/Kapita*. <https://www.esdm.go.id/Id/Media->

Center/Arsip-Berita/Konsumsi-Listrik-Masyarakat-Meningkat-Tahun-2023-Capai-1285-Kwh-Kapita.

- Moon, J., Maqsood, M., So, D., Baik, S. W., Rho, S., & Nam, Y. (2024). Advancing ensemble learning techniques for residential building electricity consumption forecasting: Insight from explainable artificial intelligence. *PLoS ONE*, 19(11 November). <https://doi.org/10.1371/journal.pone.0307654>
- Nurani, A. T., Setiawan, A., & Susanto, B. (2023). Perbandingan Kinerja Regresi Decision Tree dan Regresi Linear Berganda untuk Prediksi BMI pada Dataset Asthma. *Jurnal Sains Dan Edukasi Sains*, 6(1), 34–43. <https://doi.org/10.24246/juses.v6i1p34-43>
- Putri, S. K. N. A., Jumiatin, I., Sulistia, I., Saputra, N. A. B., & Wiranda, N. (2025). Penerapan Hyperparameter Tuning pada Model Klasifikasi untuk Prediksi Risiko Penyakit Jantung. 5, 1181–1189. <https://doi.org/10.57152/malcom.v5i4.2138>
- Rayadin, M. A., Musaruddin, M., Saputra, R. A., & Isnawaty, I. (2024). Implementasi Ensemble Learning Metode XGBoost dan Random Forest untuk Prediksi Waktu Penggantian Baterai Aki. *BIOS : Jurnal Teknologi Informasi Dan Rekayasa Komputer*, 5(2), 111–119. <https://doi.org/10.37148/bios.v5i2.128>
- Rizky, M. H., Faisal, M. R., Budiman, I., Kartini, D., & Abadi, F. (2024). Effect of Hyperparameter Tuning Using Random Search on Tree-Based Classification Algorithm for Software Defect Prediction. *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, 18(1), 95. <https://doi.org/10.22146/ijccs.90437>
- Rohmadi, A., Ruhayani Azis, A., & Joko Pramono, A. (2026). Model Ensemble Gradient Boosting untuk Peramalan Konsumsi Listrik Harian Berbasis Fitur Cuaca dan Waktu. 20(2). <https://publikasi.teknokrat.ac.id/index.php/teknokompak/article/view/1358>
- Saragih, Y. A. C., & Suryani, E. (2026). Implementasi Metode Hybrid Backpropagation Neural Network dan Particle Swarm Optimization untuk

- Prediksi Konsumsi Listrik Rumah Tangga Berdasarkan Golongan Tarif*. 6(2), 663–673. <https://doi.org/10.57152/malcom.v6i2.2519>
- Setiyorini, T., & Frieyadie. (2024). Comparison of the Application of Linear Regression with Sliding Window Validation and K-Fold Cross-Validation for Forecasting Covid-19 Recovered Cases. *Jurnal Riset Informatika*, 6(3), 159–166. <https://doi.org/10.34288/jri.v6i3.288>
- United Nations. (2024). *Goal 7: Ensure access to affordable, reliable, sustainable and modern energy for all*. <https://Sdgs.Un.Org/Goals/Goal7>.
- Wardana, P., Daratha, N., & Amri Rosa, M. K. (2024). Perbandingan Metode-
Metode Deep Learning Dalam Prediksi Konsumsi Daya Listrik Rumah Jangka
Pendek. *JURNAL AMPLIFIER : JURNAL ILMIAH BIDANG TEKNIK
ELEKTRO DAN KOMPUTER*, 14(1), 61–69.
<https://doi.org/10.33369/jamplifier.v14i1.34367>

DAFTAR LAMPIRAN

Lampiran A. Dataset

https://github.com/fathualr/final-project-diploma3_wattcast/tree/main/ML/script/energy_project/data

Lampiran B. Link Produk

https://github.com/fathualr/final-project-diploma3_wattcast

Lampiran C. Dokumen Pengujian

https://github.com/fathualr/final-project-diploma3_wattcast/tree/main/_REPORT/UAT

Lampiran D. Video Demo Aplikasi

<https://youtu.be/j-huOVbnMQM>