

# Model *Ensemble Gradient Boosting* untuk Peramalan Konsumsi Listrik Harian Berbasis Fitur Cuaca dan Waktu

Anwar Rohmadi<sup>1,\*</sup>, Ahmad Ruhayani Azis<sup>2</sup>, Aji Joko Pramono<sup>3</sup>

<sup>1,2,3</sup>Fakultas Ilmu Tarbiyah, Program Studi Sains Data, Universitas Islam Negeri Raden Mas Said Surakarta, Kabupaten Sukoharjo, Indonesia

Email : <sup>1,\*</sup>247411027@mhs.uinsaid.co.id, <sup>2</sup>247411018@mhs.uinsaid.co.id, <sup>3</sup>ajijoko@gmail.com

<sup>\*</sup>) Email Penulis Utama

**Abstrak**— Perkembangan sistem tenaga listrik global di era transisi energi saat ini ditandai oleh peningkatan permintaan listrik yang sangat pesat serta kompleksitas operasional yang belum pernah terjadi sebelumnya. Laporan International Energy Agency (IEA) pada tahun 2025 melaporkan bahwa konsumsi listrik dunia diproyeksikan tumbuh sekitar 3,3% pada tahun 2025 dan meningkat menjadi 3,7% pada tahun 2026, sebuah laju yang lebih dari dua kali lipat pertumbuhan permintaan energi total. Di Indonesia, data resmi Kementerian ESDM menunjukkan bahwa konsumsi listrik per kapita terus meningkat seiring dengan ekspansi program elektrifikasi dan integrasi sumber energi terbarukan seperti tenaga surya dan angin yang semakin masif. Namun, integrasi ini membawa tantangan tersendiri; sifat intermiten dari energi terbarukan menuntut presisi tinggi dalam perencanaan beban untuk menjaga keseimbangan supply-demand. Ketidakakuratan dalam peramalan beban listrik jangka pendek (Short-Term Load Forecasting, STLF) berpotensi menyebabkan inefisiensi biaya cadangan yang berlebihan atau risiko kekurangan pasokan yang berdampak fatal pada stabilitas frekuensi sistem. Penelitian ini bertujuan untuk mengembangkan model peramalan konsumsi listrik harian per kluster pelanggan menggunakan pendekatan ensemble machine learning yang menggabungkan kekuatan dua algoritma Gradient Boosting terkemuka, yaitu LightGBM dan XGBoost, yang dibandingkan dengan Regresi Linier sebagai baseline. Dataset yang digunakan berasal dari kompetisi peramalan beban listrik (Electric Energy Consumption Forecast) yang mencakup 15.088 baris data harian untuk periode 2014–2021, dengan variabel target konsumsi listrik serta 14 prediktor meteorologis lengkap, termasuk suhu, radiasi matahari, dan kecepatan angin. Metodologi penelitian mengikuti kerangka standar CRISP-DM, meliputi tahapan pembersihan data yang ketat, rekayasa fitur kalender, transformasi fitur siklis (sinus-kosinus) untuk menjaga kontinuitas temporal data waktu, fitur lag autoregresif untuk menangkap inersia beban, dan statistik bergulir. Hasil evaluasi menggunakan skema hold-out berbasis waktu menunjukkan bahwa model ensemble memberikan kinerja superior dengan RMSE 17,30 kWh, MAE 12,14 kWh, MAPE 2,03%, dan nilai R<sup>2</sup> mencapai 0,9960. Lebih lanjut, evaluasi menggunakan MASE sebesar 0,0383 membuktikan model ini jauh lebih akurat dibanding metode naif, memberikan nilai tambah informasi yang signifikan bagi operator. Analisis feature importance mengungkapkan bahwa konsumsi listrik masa lalu (lag\_1 dan lag\_7) adalah prediktor paling dominan, diikuti oleh fitur hari dalam minggu dan suhu maksimum. Temuan ini menegaskan bahwa penggabungan model Gradient Boosting dengan rekayasa fitur domain-spesifik mampu meningkatkan akurasi peramalan beban listrik secara signifikan dan siap diimplementasikan untuk mendukung efisiensi operasional utilitas listrik modern.

**Kata Kunci:** *Ensemble Learning, Gradient Boosting, Konsumsi Listrik, Peramalan Beban, Time Series.*

**Abstract**— The development of the global electric power system in the energy transition era is characterized by a rapid increase in electricity demand and unprecedented operational complexity. The International Energy Agency (IEA) report in 2025 states that world electricity consumption is projected to grow by around 3.3% in 2025 and increase to 3.7% in 2026, a rate more than double the growth of total energy demand. In Indonesia, official data from the Ministry of Energy and Mineral Resources (ESDM) shows that per capita electricity consumption continues to increase along with the expansion of electrification programs and the massive integration of renewable energy sources such as solar and wind. However, this integration brings its own challenges; the intermittent nature of renewables demands high precision in load planning to maintain supply-demand balance. Inaccuracies in Short-Term Load Forecasting (STLF) potentially cause excessive reserve cost inefficiencies or the risk of supply shortages that have a fatal impact on system frequency stability. This study aims to develop a daily electricity consumption forecasting model per customer cluster using an ensemble machine learning approach combining two leading Gradient Boosting algorithms, specifically LightGBM and XGBoost, compared against Linear Regression as a baseline. The dataset used is derived from the Electric Energy Consumption Forecast competition, covering 15,088 rows of daily data for the 2014–2021 period, with electricity consumption as the target variable and 14 complete meteorological predictors, including temperature, solar radiation, and wind speed. The research methodology follows the standard CRISP-DM framework, covering rigorous data cleaning stages, calendar feature engineering, cyclic feature transformation (sine-cosine) to maintain temporal continuity of time data, autoregressive lag features to capture load inertia, and rolling statistics. Evaluation results using a time-based hold-out scheme show that the ensemble model delivers superior performance with an RMSE of 17.30 kWh, MAE of 12.14 kWh, MAPE of 2.03%, and an R<sup>2</sup> value reaching 0.9960. Furthermore, evaluation

using MASE of 0.0383 proves this model is far more accurate than naive methods, providing significant information gain for operators. Feature importance analysis reveals that past electricity consumption (lag\_1 and lag\_7) are the most dominant predictors, followed by day-of-week features and maximum temperature. These findings confirm that combining Gradient Boosting models with domain-specific feature engineering can significantly improve load forecasting accuracy and is ready to be implemented to support the operational efficiency of modern electric utilities.

**Keywords:** Electricity Consumption, *Ensemble Learning*, *Gradient Boosting*, Load Forecasting, *Time Series*.

## 1. PENDAHULUAN

Permintaan listrik global terus tumbuh sejalan dengan elektrifikasi sektor transportasi, peningkatan pendapatan per kapita, dan digitalisasi industri yang semakin masif. Fenomena ini menempatkan listrik sebagai komoditas strategis yang tak tergantikan dalam menopang pertumbuhan ekonomi modern dan transisi menuju energi bersih. Menurut laporan terbaru dari *International Energy Agency* (IEA), permintaan listrik dunia meningkat sekitar 3,3% pada tahun 2025 dan diperkirakan akan kembali meningkat sebesar 3,7% pada tahun 2026 [1]. Pertumbuhan ini didorong oleh ekspansi pembangunan industri manufaktur serta peningkatan penggunaan perangkat elektrik di sektor residensial dan komersial yang semakin bergantung pada kenyamanan termal (sistem pendingin/pemanas). Pertumbuhan di kawasan Asia Pasifik tercatat lebih pesat dibandingkan kawasan lain karena adanya ekspansi ekonomi dan populasi yang signifikan, menjadikan akurasi pengelolaan energi semakin krusial untuk mencegah krisis pasokan di tengah lonjakan permintaan.

Indonesia menunjukkan tren yang serupa. Data dari *Handbook of Energy & Economic Statistics of Indonesia* yang dirilis oleh Kementerian ESDM menunjukkan bahwa konsumsi listrik per kapita meningkat secara konsisten dari tahun ke tahun, mencerminkan peningkatan taraf hidup dan aktivitas ekonomi masyarakat [2]. Program pemerintah seperti elektrifikasi desa, pertumbuhan kawasan industri baru, serta peningkatan penetrasi perangkat rumah tangga listrik menjadi faktor pendorong utama peningkatan beban puncak maupun beban dasar. Sejalan dengan pertumbuhan permintaan ini, sektor ketenagalistrikan juga menghadapi tantangan baru berupa integrasi pembangkit energi terbarukan, seperti tenaga surya (PLTS) dan angin (PLTB), yang bersifat intermiten. Transformasi ini bukan sekadar perubahan teknologi, melainkan pergeseran paradigma operasional dari *generation-following-load* menjadi sistem yang lebih fleksibel. Pembangkit terbarukan menyebabkan fluktuasi daya yang sangat bergantung pada kondisi cuaca yang stokastik, sehingga operator sistem tenaga listrik (System Operator) membutuhkan peramalan beban yang sangat presisi guna menyesuaikan *dispatch* unit pembangkit konvensional dan menjaga kestabilan frekuensi sistem agar tetap berada pada batas operasional yang aman, biasanya 50-60 Hz.

Permasalahan keakuratan dalam peramalan beban listrik jangka pendek (*Short-Term Load Forecasting*, STLF) memiliki implikasi teknis dan ekonomis yang serius bagi utilitas listrik. Kesalahan peramalan dapat memicu keputusan penjadwalan unit (*unit commitment*) dan alokasi cadangan putar (*spinning reserve*) yang tidak efisien. Kondisi *over-forecasting* (prediksi lebih tinggi dari aktual) menyebabkan operator menyalakan pembangkit Cadangan, sehingga memboroskan biaya bahan bakar dan meningkatkan emisi. Sebaliknya, *under-forecasting* (prediksi lebih rendah dari aktual) meningkatkan risiko ketidakstabilan jaringan yang dapat menyebabkan pemadaman beban (*load shedding*) demi mencegah kolaps sistem total (*blackout*). Oleh karena itu, pengembangan model peramalan yang akurat dan *robust* (tangguh) terhadap variabilitas cuaca menjadi prioritas utama dalam operasi sistem tenaga modern [3].

Peramalan beban listrik dilakukan dengan pendekatan statistik klasik seperti ARIMA (Auto-Regressive Integrated Moving Average) dan SARIMA. Model-model ini bermanfaat untuk data stasioner yang memiliki pola musiman yang teratur dan linear, serta efektif untuk horizon waktu yang sangat pendek [4]. Model statistik klasik memiliki keterbatasan mendasar; mereka rentan terhadap hubungan non-linier dan memerlukan pra-pemrosesan yang kompleks (seperti diferensiasi) ketika pola tren berubah. Selain itu, model linier sering kali gagal menangkap lonjakan beban ekstrem yang disebabkan oleh anomali cuaca mendadak, karena asumsi normalitas yang kaku. Penambahan variabel eksogen melalui ARIMAX dapat membantu, tetapi tetap terbatas dalam menangkap interaksi kompleks multidimensi antara variabel cuaca (suhu, kelembaban, angin) dan perilaku konsumsi manusia. Seiring dengan ketersediaan *big data* dan peningkatan daya komputasi, pendekatan *Machine learning* (ML) mulai mendominasi literatur *Short-Term Load Forecasting* (STLF). Model ML menawarkan kemampuan untuk menangkap pola non-linier, interaksi antar variabel yang kompleks, dan sensitivitas terhadap variabel eksogen tanpa perlu asumsi bentuk distribusi data yang kaku [5].

Algoritma ML yang umum digunakan untuk STLF meliputi *Support Vector Regression* (SVR), *Random Forest* (RF), *Gradient Boosting Decision Trees* (GBDT), hingga *Deep Learning* seperti LSTM. Studi komparatif dalam beberapa tahun terakhir menunjukkan bahwa keluarga algoritma GBDT, terutama XGBoost (*Extreme Gradient Boosting*) dan LightGBM (*Light Gradient Boosting Machine*), sering menjadi unggulan karena kombinasi akurasi

yang tinggi, efisiensi komputasi yang cepat, dan interpretabilitas yang lebih baik dibandingkan "kotak hitam" jaringan saraf tiruan. Chen dan Guestrin (2016) memperkenalkan XGBoost sebagai sistem *boosting* pohon yang skalabel, yang terbukti memenangkan banyak kompetisi data sains berkat mekanisme regularisasinya yang kuat dalam mencegah *overfitting* [6]. Sementara itu, Ke et al. (2017) mengembangkan LightGBM yang menggunakan teknik pengambilan sampel berbasis gradien (GOSS) untuk mempercepat pelatihan pada dataset besar tanpa mengorbankan akurasi, menjadikannya sangat efisien untuk data *time-series* berskala besar dengan dimensi tinggi [7]. Untuk menghasilkan satu prediksi akhir yang lebih baik. *Ensemble boosting*, seperti penggabungan LightGBM dan XGBoost, dilaporkan menghasilkan peningkatan akurasi karena masing-masing algoritma memiliki mekanisme optimasi yang sedikit berbeda sehingga kesalahannya tidak berkorelasi sempurna [8]. Dalam penelitian *nowcasting* beban residensial, integrasi algoritma *boosting* terbukti menghasilkan  $R^2$  mencapai 0,9745 [9]. Kombinasi model ini memanfaatkan keunggulan komplementer: kecepatan LightGBM dalam memproses data besar dan stabilitas XGBoost melalui regularisasi, sehingga mengurangi variansi prediksi dan meningkatkan ketahanan model terhadap *outlier*. Selain pemilihan algoritma, keberhasilan model STLF sangat bergantung pada rekayasa fitur (*feature engineering*). Literatur menunjukkan bahwa fitur kalender, transformasi siklus waktu, dan fitur lag (nilai beban masa lalu) adalah komponen vital. Kud (2020) menekankan pentingnya *encoding* fitur siklus (sinus-kosinus) untuk menghindari diskontinuitas ordinal pada data waktu, memastikan model memahami kontinuitas matematis antara akhir hari (jam 23:00) dan awal hari berikutnya (jam 00:00) atau antara bulan Desember dan Januari [10].

Berdasarkan penelitian terdahulu yang telah dikaji, masih terdapat celah penelitian (*research gap*) dalam penerapan *pipeline* STLF yang komprehensif untuk data multi-kluster dengan horizon harian yang memanfaatkan pustaka *tidymodels* di lingkungan R. Banyak studi sebelumnya berfokus pada horizon jam-jaman atau hanya menggunakan satu algoritma tunggal tanpa membandingkan efektivitas *ensemble* secara langsung pada data heterogen. Penelitian ini bertujuan untuk mengonstruksi *pipeline* peramalan konsumsi listrik harian yang memadukan rekayasa fitur waktu dan cuaca dengan model *ensemble Gradient Boosting*. Kontribusi utama dari artikel ini adalah: (1) membuktikan secara empiris superioritas model *ensemble* LightGBM-XGBoost yang mampu menurunkan tingkat kesalahan (RMSE) hingga 30-31% dibandingkan model regresi linier; (2) menerapkan evaluasi multi-metrik yang komprehensif, khususnya MASE (*Mean Absolute Scaled Error*), untuk memvalidasi nilai tambah informasi model terhadap metode *naif*; (3) menganalisis fitur meteorologis dan temporal yang paling determinan terhadap fluktuasi konsumsi listrik untuk memberikan wawasan perilaku beban; serta (4) menyediakan rancangan sistem peramalan otomatis yang terbukti efisien secara komputasi untuk mendukung keputusan operasional harian utilitas listrik.

## 2. METODE PENELITIAN

### 2.1. Kerangka Kerja CRISP-DM

Penelitian ini disusun dengan mengacu pada kerangka kerja *Cross Industry Standard Process for Data Mining* (CRISP-DM) sebagai landasan metodologis untuk menjamin bahwa seluruh tahapan analisis dan pemodelan dilakukan secara sistematis, terarah, dan dapat direplikasi. Kerangka kerja penelitian secara umum disajikan pada Gambar 1.

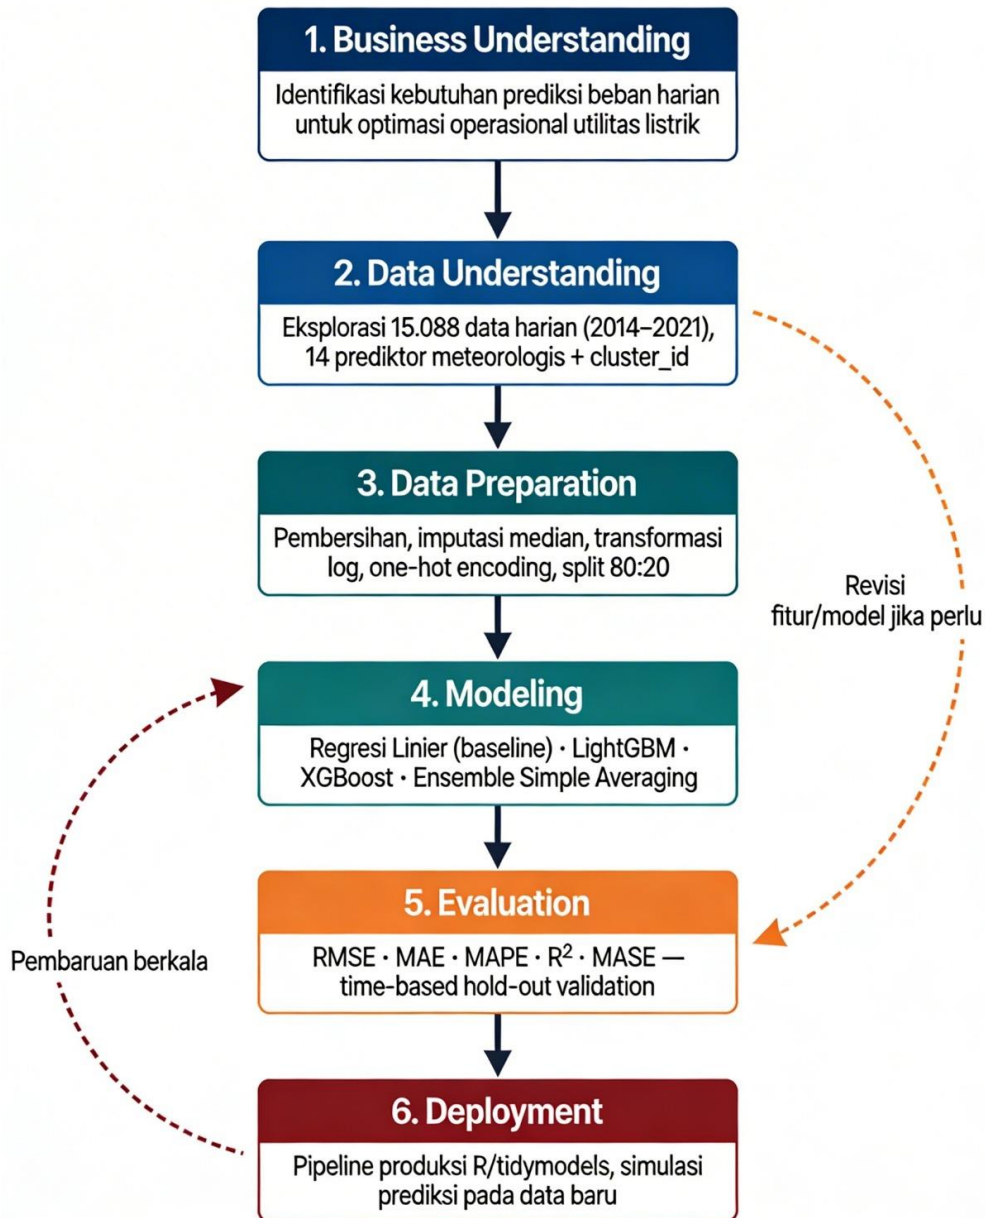
Sebagaimana ditunjukkan pada Gambar 1, penelitian ini mencakup enam tahapan utama, yaitu *business understanding*, *data understanding*, *data preparation*, *modeling*, *evaluation*, dan *deployment*. Penerapan kerangka kerja tersebut memungkinkan proses penelitian dilaksanakan secara terstruktur sekaligus iteratif, sehingga hasil evaluasi pada tahap akhir dapat dimanfaatkan untuk menyempurnakan fitur, pemilihan model, maupun strategi pemodelan yang digunakan.

Kerangka kerja ini dipilih karena strukturnya yang komprehensif dan siklus hidupnya yang iteratif, yang menjamin validitas, reliabilitas, dan reproduktibilitas penelitian data sains. Proses dimulai dari fase (1) *Business Understanding*, di mana fokus utama adalah mengidentifikasi kebutuhan mendesak utilitas listrik untuk memprediksi beban harian guna optimasi operasi pembangkitan dan meminimalkan biaya operasional akibat kesalahan prediksi. Dilanjutkan dengan (2) *Data Understanding* untuk mengeksplorasi karakteristik dataset, (3) *Data Preparation* yang meliputi pembersihan dan transformasi data yang ketat untuk mencegah kebocoran data (*data leakage*), serta (4) *Modeling* di mana berbagai algoritma diuji. Fase (5) *Evaluation* dilakukan untuk menilai kinerja model menggunakan metrik statistik yang relevan, dan diakhiri dengan (6) *Deployment* yang mensimulasikan penerapan model pada data baru. Seluruh proses implementasi teknis dilakukan menggunakan bahasa pemrograman R dengan ekosistem paket *tidymodels*, yang menyediakan struktur *pipeline* yang konsisten, modular, dan dapat direplikasi untuk pemodelan prediktif modern yang kompleks.

Penerapan CRISP-DM dalam penelitian ini tidak bersifat linier kaku, melainkan memungkinkan adanya umpan balik antar fase. Misalnya, temuan pada fase evaluasi model dapat memicu kembali fase persiapan data untuk melakukan rekayasa fitur tambahan guna meningkatkan akurasi. Pendekatan siklus ini sangat krusial dalam menangani

data beban listrik yang memiliki karakteristik dinamis dan dipengaruhi oleh banyak faktor eksternal. Dengan mengikuti standar ini, penelitian ini memastikan bahwa setiap keputusan pemodelan didasarkan pada pemahaman bisnis yang kuat dan divalidasi melalui proses evaluasi yang ketat, sehingga hasil akhirnya tidak hanya akurat secara matematis tetapi juga relevan dan dapat diterapkan dalam konteks operasional industri ketenagalistrikan yang sebenarnya.

### Kerangka Kerja CRISP-DM



Gambar 1. Kerangka Kerja CRISP-DM pada Penelitian Peramalan Konsumsi Listrik Harian

## 2.2. Dataset dan Eksplorasi Data

Dataset yang digunakan dalam penelitian ini bersumber dari kompetisi Electric Energy Consumption Forecast [11], yang merepresentasikan tantangan nyata dalam peramalan beban. Data terdiri dari dua berkas utama, yaitu *train.csv* dan *test.csv*. Berkas data latih mencakup 11.688 observasi harian untuk periode 1 Januari 2014 hingga 31 Desember 2021, memberikan rentang waktu yang cukup panjang untuk menangkap berbagai pola musiman, tren jangka panjang, dan anomali historis. Variabel target utama adalah *electricity\_consumption* (kWh). Selain target, dataset menyediakan 14 variabel prediktor meteorologis yang sangat kaya dan terperinci, antara lain: *temperature\_2m\_max* dan *temperature\_2m\_min* (suhu udara pada ketinggian 2 meter), *apparent\_temperature\_max* dan *apparent\_temperature\_min* (suhu yang dirasakan oleh tubuh manusia, memperhitungkan faktor kelembaban dan angin), *sunshine\_duration* (durasi penyinaran matahari), *daylight\_duration* (panjang siang hari), *wind\_speed\_10m\_max* (kecepatan angin maksimum), *shortwave\_radiation\_sum* (radiasi gelombang pendek), serta *et0\_fao\_evapotranspiration* (evapotranspirasi referensi).

Kekayaan fitur meteorologis ini memungkinkan model untuk mempelajari hubungan kompleks antara kondisi atmosfer dan perilaku konsumsi energi. Misalnya, variabel suhu nyata (*apparent temperature*) sering kali menjadi prediktor yang lebih baik daripada suhu udara biasa karena mencerminkan kenyamanan termal manusia yang memicu penggunaan alat pendingin atau pemanas. Selain data cuaca, terdapat pula variabel *cluster\_id* yang membagi data ke dalam 4 segmen pelanggan yang berbeda. Keberadaan variabel kluster ini sangat strategis karena memungkinkan analisis perilaku konsumsi yang spesifik per kelompok, mulai dari karakteristik beban residensial yang fluktuatif hingga beban industri kecil yang lebih stabil namun intensif energi. Eksplorasi awal terhadap distribusi data menunjukkan bahwa setiap kluster memiliki profil beban dasar (*base load*) dan pola puncak (*peak load*) yang unik, yang menuntut pendekatan pemodelan yang mampu mengadaptasi heterogenitas tersebut secara efektif.

## 2.3. Tahapan Pra-Pemrosesan Data

Tahap pra-pemrosesan dilakukan secara ketat untuk mencegah kebocoran data (*data leakage*) dan memastikan kualitas input model. Langkah-langkah yang dilakukan dalam *recipe* tidymodels meliputi:

- a. Pembersihan Nama Kolom: Normalisasi seluruh nama variabel ke format *snake\_case* (huruf kecil dengan garis bawah). Hal ini dilakukan untuk menjaga konsistensi penulisan kode R dan mencegah kesalahan sintaksis yang tidak perlu selama proses pemodelan.
- b. Konversi Tipe Data: Pengubahan kolom tanggal menjadi tipe *Date* untuk memfasilitasi manipulasi deret waktu dan *cluster\_id* menjadi faktor atau variabel kategorik untuk keperluan pengelompokan yang tepat dalam model.
- c. Imputasi Nilai Hilang: Nilai yang hilang (*missing values*) pada prediktor numerik diisi menggunakan metode median. Median dipilih karena lebih *robust* (tahan) terhadap *outlier* dibandingkan rata-rata (*mean*). Dalam data sensor cuaca, *outlier* sering terjadi akibat kesalahan pembacaan alat, sehingga penggunaan *mean* dapat mendistorsi nilai pengganti dan menggeser distribusi data, yang berpotensi menyesatkan model.
- d. Transformasi Distribusi: Variabel *wind\_speed\_10m\_max* yang memiliki distribusi miring kanan (*right-skewed*) ditransformasi menggunakan logaritma natural. Kecepatan angin sering kali mengikuti distribusi Weibull yang miring; transformasi log membantu data mendekati distribusi normal, yang meningkatkan stabilitas model regresi linier dan mempercepat konvergensi algoritma berbasis gradien dalam menemukan solusi optimal.
- e. Penyandian Variabel Kategorik: Variabel *cluster\_id* diubah menjadi variabel *dummy* (*one-hot encoding*) agar dapat diproses oleh algoritma regresi linier maupun XGBoost yang memerlukan input numerik murni, memungkinkan model membedakan karakteristik dasar setiap kluster pelanggan.

## 2.4. Rekayasa Fitur (*Feature engineering*)

Rekayasa fitur merupakan komponen paling kritis dalam penelitian ini untuk menangkap dinamika waktu yang kompleks. Fitur-fitur baru diturunkan untuk menangkap pola temporal dan kausalitas:

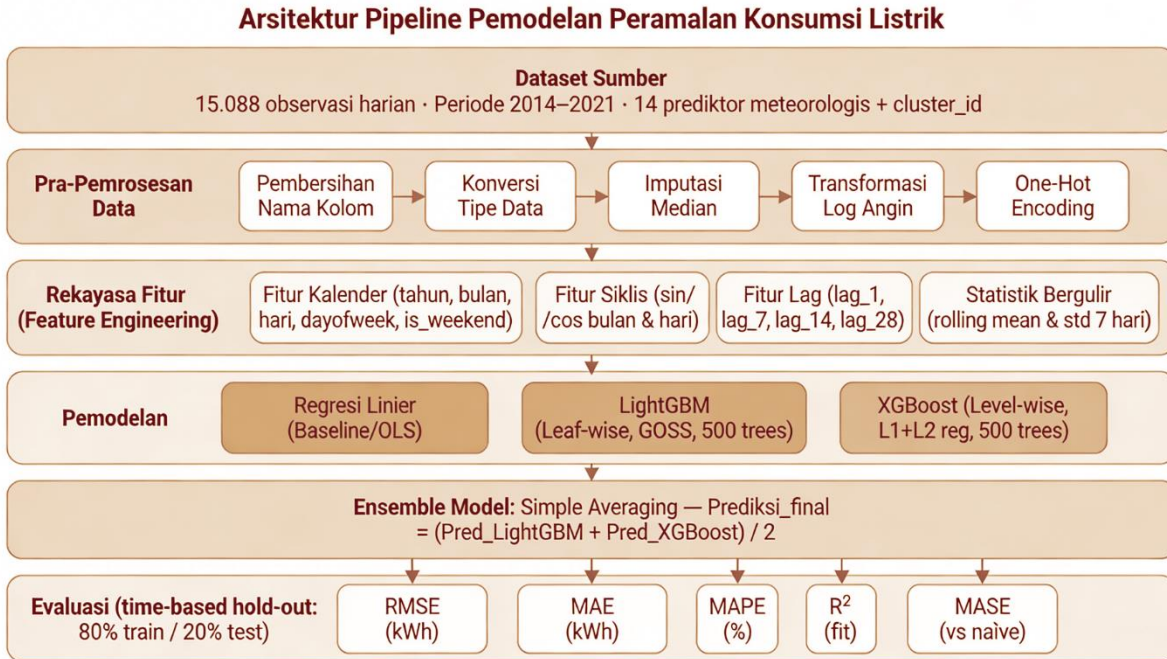
- a. Fitur Kalender: Mengekstrak komponen waktu seperti tahun, bulan, hari, hari dalam minggu (*dayofweek*), nomor minggu (*weekofyear*), serta indikator biner untuk akhir pekan (*is\_weekend*). Fitur ini penting untuk menangkap pola perilaku manusia, misalnya penurunan beban yang konsisten pada hari Minggu dibandingkan hari kerja akibat liburannya aktivitas perkantoran dan industri, yang merupakan pola dominan dalam data beban listrik.
- b. Fitur Siklis (*Cyclical features*): Waktu bersifat siklis (setelah bulan 12 kembali ke bulan 1), namun representasi angka biasa (1-12) bersifat ordinal dan terputus. Tanpa transformasi, model akan menganggap bulan 12 (Desember) dan bulan 1 (Januari) memiliki jarak terjauh (selisih 11), padahal secara temporal mereka berurutan. Oleh karena itu, fitur bulan dan hari ditransformasikan ke dalam bentuk sinus dan kosinus.

Contohnya, transformasi *month\_sin* dan *month\_cos* memastikan model memahami kedekatan matematis antara Desember dan Januari, mencegah lompatan nilai prediksi yang tidak realistis pada pergantian tahun dan menjaga kontinuitas pola musiman.

- c. Fitur Lag (Autoregresif): Dibuat fitur *lag\_1*, *lag\_7*, *lag\_14*, dan *lag\_28* yang merepresentasikan konsumsi listrik pada 1 hari, 1 minggu, 2 minggu, dan 4 minggu sebelumnya. Fitur ini menangkap sifat *autocorrelation* yang kuat pada data deret waktu, di mana beban hari ini sangat dipengaruhi oleh kebiasaan konsumsi masa lalu (inersia beban) [5]. Fitur ini berfungsi sebagai memori jangka pendek dan jangka panjang bagi model.
- d. Statistik Bergulir (*Rolling stats*): Dihitung rata-rata bergerak (*rolling mean*) dan standar deviasi suhu maksimum dalam jendela waktu 7 hari terakhir. Fitur ini memberikan konteks tren cuaca jangka pendek kepada model, membedakan antara hari panas yang tiba-tiba dengan gelombang panas yang berkepanjangan yang cenderung menyebabkan akumulasi panas pada bangunan, sehingga meningkatkan beban pendingin secara bertahap.

## 2.5. Arsitektur Pemodelan

Setelah kerangka metodologis ditetapkan, proses implementasi penelitian dirancang ke dalam suatu arsitektur *pipeline* pemodelan yang merepresentasikan alur pengolahan data secara menyeluruh, mulai dari data masukan hingga tahap evaluasi model. Rancangan *pipeline* tersebut disajikan pada Gambar 2.



Gambar 2. Arsitektur *Pipeline* Pemodelan Peramalan Konsumsi Listrik Harian

Gambar 2 menggambarkan arsitektur *pipeline* penelitian yang diawali dari dataset sumber, dilanjutkan dengan pra-pemrosesan data dan rekayasa fitur, kemudian tahap pemodelan menggunakan Regresi Linier, LightGBM, dan XGBoost. Ketiga skenario model tersebut dibangun untuk membandingkan performa prediksi dan menguji efektivitas pendekatan *ensemble*. Prediksi dari model *boosting* selanjutnya digabungkan melalui teknik *simple averaging*, lalu dievaluasi menggunakan skema *time-based hold-out* dengan metrik RMSE, MAE, MAPE, R<sup>2</sup>, dan MASE. Pemilihan model dilakukan dengan mempertimbangkan pola musiman yang kuat pada data beban listrik serta kebutuhan akan interpretabilitas dan akurasi prediksi.

### 2.5.1. Regresi Linier (*Baseline*)

Regresi linier (Ordinary Least Squares - OLS) digunakan sebagai model baseline atau acuan dasar. Model ini mengasumsikan adanya hubungan linier langsung antara variabel prediktor (fitur cuaca dan waktu) dengan variabel target (konsumsi listrik). Meskipun secara teoretis sederhana dan mungkin tidak mampu menangkap kompleksitas non-linier dari data beban listrik yang dinamis, keberadaan model baseline ini sangat krusial. Fungsinya adalah untuk

mengukur seberapa besar "keuntungan marjinal" atau uplift yang diperoleh dari penggunaan algoritma machine learning non-linier yang jauh lebih kompleks dan membutuhkan sumber daya komputasi lebih besar. Jika model kompleks hanya memberikan peningkatan akurasi yang tidak signifikan dibandingkan regresi linier, maka justifikasi untuk mengimplementasikan sistem yang berat secara komputasi menjadi lemah.

### 2.5.2. LightGBM (*Light Gradient Boosting Machine*)

LightGBM adalah implementasi Gradient Boosting Decision Tree (GBDT) yang dikembangkan oleh Microsoft, dipilih dalam penelitian ini karena efisiensinya pada dataset berskala besar dan kemampuannya menangkap pola non-linier yang kompleks. Strategi pertumbuhan leaf-wise yang dimilikinya memungkinkan konvergensi lebih cepat dibanding metode konvensional, menjadikannya sangat cocok untuk data time-series berdimensi tinggi seperti yang digunakan dalam penelitian ini. Dalam penelitian ini, model LightGBM dikonfigurasi dengan 500 pohon (trees), learning rate 0,05, dan kedalaman pohon (max depth) 6.

### 2.5.3. XGBoost (*Extreme Gradient Boosting*)

XGBoost merupakan algoritma *ensemble* berbasis pohon keputusan yang dipilih sebagai model kedua dalam penelitian ini karena kemampuan regularisasinya yang kuat (L1 dan L2) yang membuatnya tahan terhadap *overfitting* pada data beban listrik yang mengandung *noise* cuaca. Setiap pohon dibangun secara sekuensial untuk memperbaiki kesalahan pohon sebelumnya. Parameter XGBoost dalam penelitian ini disamakan dengan LightGBM — 500 pohon, *learning rate* 0,05, dan *max depth* 6 — untuk memastikan perbandingan yang adil (*apples-to-apples comparison*).

### 2.5.4. Ensemble Model

Model final yang diusulkan dalam penelitian ini adalah *Ensemble Model* yang dibentuk menggunakan teknik *simple averaging* — prediksi akhir diperoleh dengan merata-ratakan hasil prediksi LightGBM dan XGBoost untuk setiap observasi data uji. Pendekatan ini dipilih karena kedua algoritma memiliki mekanisme optimasi yang berbeda sehingga kesalahannya tidak berkorelasi sempurna, dan penggabungannya terbukti menghasilkan variansi prediksi yang lebih rendah dibanding model tunggal terbaik sekalipun, memberikan keandalan yang lebih tinggi untuk implementasi operasional.

Rangkaian proses pemodelan yang digunakan dalam penelitian ini secara lebih rinci disajikan pada Gambar 2.

## 2.6. Skema Evaluasi

Metode validasi yang digunakan adalah *time-based hold-out*, di mana 80% data awal digunakan untuk pelatihan (*training*) dan 20% data terakhir (secara kronologis) digunakan untuk pengujian (*testing*). Evaluasi kinerja dilakukan menggunakan lima metrik komprehensif:

- RMSE (*Root Mean Squared Error*): Mengukur akar rata-rata kuadrat kesalahan. Metrik ini memberikan penalti yang berat pada kesalahan prediksi yang besar (*outlier*), sehingga sangat berguna untuk mendeteksi kegagalan model dalam memprediksi beban puncak.
- MAE (*Mean Absolute Error*): Mengukur rata-rata selisih absolut antara prediksi dan nilai aktual. MAE lebih mudah diinterpretasi dalam konteks operasional bisnis (misalnya, rata-rata kesalahan dalam kWh).
- MAPE (*Mean Absolute Percentage Error*): Mengukur rata-rata persentase kesalahan absolut. Metrik ini memudahkan perbandingan kinerja model antar kluster yang memiliki skala konsumsi berbeda (misalnya industri vs residensial).
- $R^2$  (*Coefficient of Determination*): Menilai seberapa baik variasi dalam data target dapat dijelaskan oleh fitur-fitur dalam model. Nilai mendekati 1 menunjukkan *goodness-of-fit* yang sangat baik.
- Mean Absolute Scaled Error (MASE) digunakan sebagai metrik skala-bebas yang mengukur akurasi model relatif terhadap metode peramalan naif, sehingga hasil antar dataset dapat dibandingkan secara adil [12].

## 3. HASIL DAN PEMBAHASAN

### 3.1. Analisis Statistik Deskriptif dan Eksplorasi Data

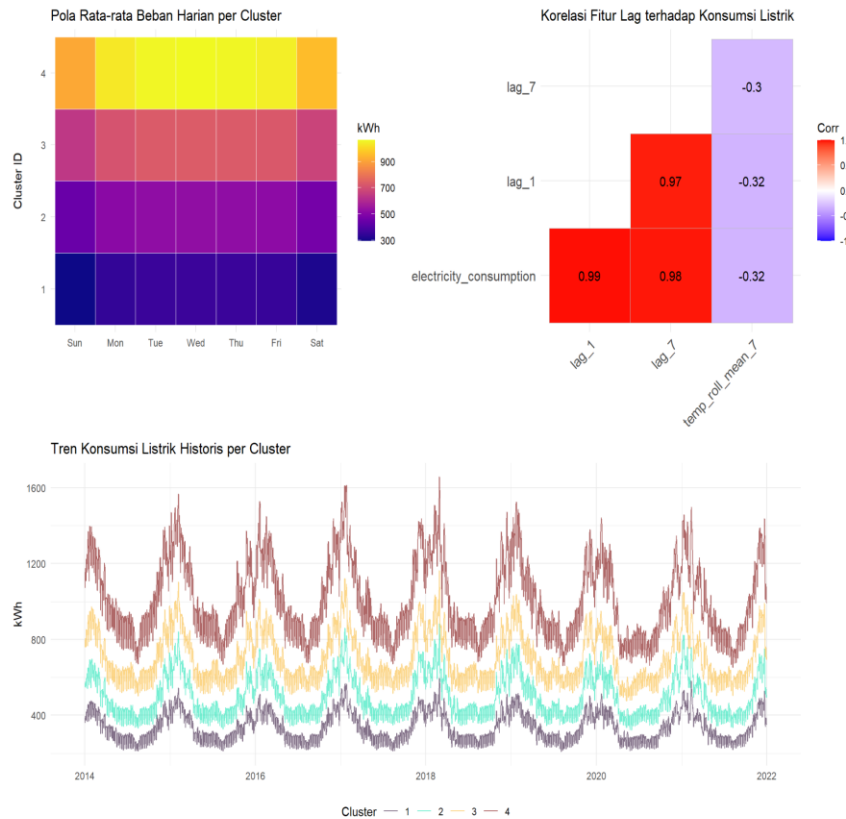
Sebelum memasuki evaluasi model, analisis statistik deskriptif pada tahap *Exploratory Data Analysis* (EDA) memberikan wawasan mendalam mengenai karakteristik data beban listrik yang menjadi landasan bagi perancangan model. Berdasarkan perhitungan awal pada data latih yang terdiri dari 11.688 observasi, terlihat adanya heterogenitas

konsumsi yang signifikan antar kluster pelanggan, yang mengindikasikan adanya perbedaan tipe pelanggan yang mendasar.

Kluster 4 mencatatkan rata-rata konsumsi harian tertinggi, yaitu sekitar 1.018 kWh per hari. Tingkat konsumsi setinggi ini mengindikasikan bahwa Kluster 4 kemungkinan besar merepresentasikan pelanggan industri kecil atau komersial (seperti pusat perbelanjaan atau pabrik kecil) yang memiliki operasional intensif energi dan cenderung stabil sepanjang minggu. Sebaliknya, Kluster 1 mencatat rata-rata terendah sebesar ~341 kWh per hari, yang lebih merepresentasikan profil pelanggan residensial (perumahan) atau bisnis kecil dengan fluktuasi yang lebih tinggi tergantung pada aktivitas penghuni. Sementara itu, Kluster 3 (~707 kWh) dan Kluster 2 (~503 kWh) berada di rentang menengah. Pemahaman mengenai perbedaan skala ini memvalidasi keputusan untuk menggunakan metrik MAPE (persentase *error*) dalam evaluasi, karena RMSE akan bias terhadap kluster dengan beban besar.

Selain analisis univariat, analisis korelasi antar variabel menunjukkan hubungan kausalitas yang menarik dan kuat yang menjadi dasar pemilihan fitur (*feature selection*). Konsumsi listrik memiliki korelasi Pearson yang sangat tinggi dengan fitur lag, yaitu sekitar 0.99 dengan *lag\_1* dan 0.98 dengan *lag\_7*. Tingginya autokorelasi ini menegaskan bahwa perilaku konsumsi listrik bersifat habitual atau berulang; beban hari ini sangat mirip dengan beban kemarin dan beban pada hari yang sama minggu lalu. Fakta statistik ini menjadi justifikasi kuat mengapa fitur autoregresif mendominasi performa model dibandingkan fitur cuaca semata.

Lebih lanjut, ditemukan korelasi negatif moderat (sekitar -0.3 hingga -0.4) antara konsumsi listrik dan suhu maksimum (*temperature\_2m\_max*). Korelasi negatif ini menyiratkan fenomena di mana ketika suhu udara menurun, konsumsi listrik justru meningkat. Fenomena ini khas untuk wilayah dengan iklim subtropis atau sedang di mana listrik dominan digunakan untuk sistem pemanas (*heating*) pada musim dingin. Hal ini berbeda dengan karakteristik beban di iklim tropis (seperti Indonesia pada umumnya) yang biasanya berkorelasi positif dengan suhu akibat penggunaan pendingin ruangan (AC). Namun, dalam dataset kompetisi global ini, pola “pemanas” terlihat lebih dominan. Pemahaman karakteristik ini krusial untuk menginterpretasikan mengapa fitur suhu menjadi prediktor penting dalam model dan mengapa pola musiman terbalik dengan pola suhu, serta membantu menjelaskan *error* model pada periode transisi musim.



Gambar 3. Pola Fluktuasi Konsumsi Listrik Harian pada Empat Kluster Pelanggan

Analisis korelasi antar variabel menunjukkan hubungan kausalitas yang menarik dan kuat. Konsumsi listrik memiliki korelasi Pearson yang sangat tinggi dengan fitur lag, yaitu sekitar 0,99 dengan *lag\_1* dan 0,98 dengan *lag\_7*. Tingginya autokorelasi ini menegaskan bahwa perilaku konsumsi listrik bersifat habitual atau berulang; beban hari ini sangat mirip dengan beban kemarin dan beban pada hari yang sama minggu lalu. Selain itu, ditemukan korelasi negatif moderat (sekitar -0,3) antara konsumsi listrik dan suhu maksimum (*temperature\_2m\_max*). Korelasi negatif ini menyiratkan fenomena di mana ketika suhu udara menurun, konsumsi listrik justru meningkat. Fenomena ini khas untuk wilayah dengan iklim subtropis atau sedang di mana listrik dominan digunakan untuk sistem pemanas (*heating*) pada musim dingin. Hal ini berbeda dengan karakteristik beban di iklim tropis yang biasanya berkorelasi positif dengan suhu akibat penggunaan pendingin ruangan (AC). Pemahaman karakteristik ini krusial untuk menginterpretasikan mengapa fitur suhu menjadi prediktor penting dalam model dan mengapa pola musiman terbalik dengan pola suhu.

### 3.2. Evaluasi Kinerja Model Prediksi

Tabel 1 menyajikan rangkuman hasil evaluasi kinerja model pada data uji (test set) yang mencakup 20% periode terakhir. Perbandingan dilakukan secara komprehensif antara model *baseline* Regresi Linier, model tunggal (LightGBM dan XGBoost), serta model *Ensemble*.

Tabel 1. Perbandingan Kinerja Model pada Data Uji

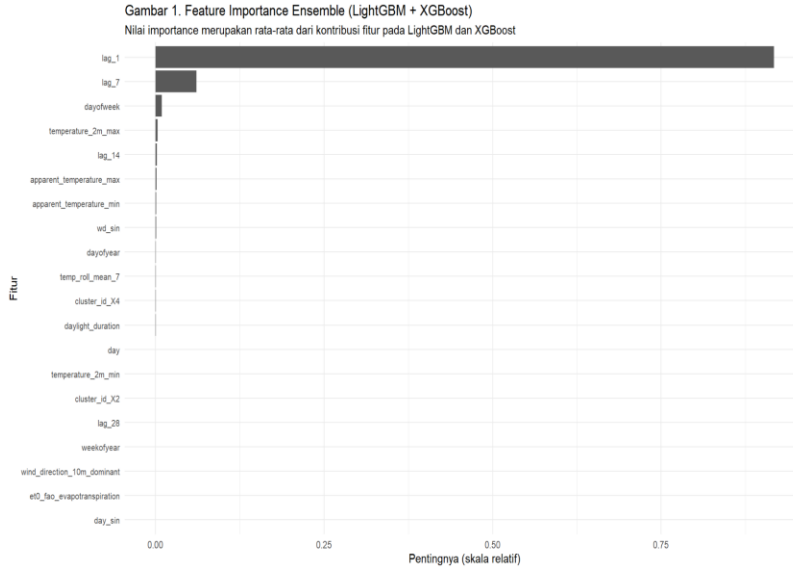
Model	RMSE (kWh)	MAE (kWh)	MASE	MAPE (%)	R <sup>2</sup>
Regresi Linier	25,194	18,699	0,0590	3,360	0,9914
LightGBM	17,406	12,303	0,0388	2,054	0,9960
XGBoost	17,971	12,643	0,0397	2,110	0,9957
<i>Ensemble</i> (LightGBM + XGBoost)	17,302	12,144	0,0383	2,032	0,9960

Analisis terhadap Tabel 1 menunjukkan bahwa model Regresi Linier memiliki kinerja terendah dengan nilai MAPE sebesar 3,36%. Hal ini disebabkan oleh keterbatasan mendasar model linier dalam menangkap interaksi non-linier yang kompleks, seperti hubungan suhu dan beban yang mungkin bersifat kuadratik atau eksponensial pada suhu ekstrem, serta interaksi antara hari libur dan konsumsi yang tidak selalu aditif. Sebaliknya, model berbasis pohon (tree-based models) menunjukkan peningkatan kinerja yang dramatis. LightGBM dan XGBoost masing-masing mampu menurunkan tingkat kesalahan RMSE sekitar 30-31% dibandingkan *baseline*. Secara spesifik, LightGBM sedikit lebih unggul dibanding XGBoost dengan MAPE 2,054% berbanding 2,110%, yang mungkin disebabkan oleh strategi *leaf-wise* yang lebih agresif dalam meminimalkan *loss* pada data yang heterogen. Namun, model *Ensemble* yang menggabungkan prediksi keduanya berhasil mencapai kinerja terbaik di seluruh metrik evaluasi: RMSE terendah (17,302 kWh), MAE terendah (12,144 kWh), dan MAPE terendah (2,032%).

Nilai R<sup>2</sup> sebesar 0,9960 pada model *Ensemble* menunjukkan bahwa model mampu menjelaskan 99,6% variasi data pada set pengujian, sebuah angka yang sangat tinggi yang mengindikasikan *goodness-of-fit* yang luar biasa. Namun, indikator yang paling krusial untuk validasi model deret waktu dalam penelitian ini adalah MASE. Nilai MASE sebesar 0,0383 (jauh di bawah ambang batas 1,0) memberikan bukti kuat bahwa model yang dikembangkan memberikan nilai tambah informasi yang signifikan dibandingkan metode *naif* (yang hanya memprediksi beban besok sama dengan beban hari ini). Rendahnya nilai MASE ini mengonfirmasi bahwa kompleksitas rekayasa fitur yang dilakukan—seperti transformasi siklis dan statistik bergulir—benar-benar berkontribusi terhadap akurasi prediksi, bukan sekadar *overfitting* terhadap data latih. Ini berarti model berhasil menangkap pola tren dan musiman yang tidak bisa dijelaskan hanya oleh inersia beban sederhana.

### 3.3. Analisis Kontribusi Fitur (*Feature importance*)

Untuk memahami "kotak hitam" dari model *Ensemble*, dilakukan analisis *Feature importance* dengan merata-ratakan skor kontribusi fitur (*gain*) dari LightGBM dan XGBoost untuk mengidentifikasi variabel yang paling mempengaruhi keputusan model.



**Gambar 4.** Peringkat 20 Variabel Prediktor Paling Berpengaruh terhadap Konsumsi Listrik

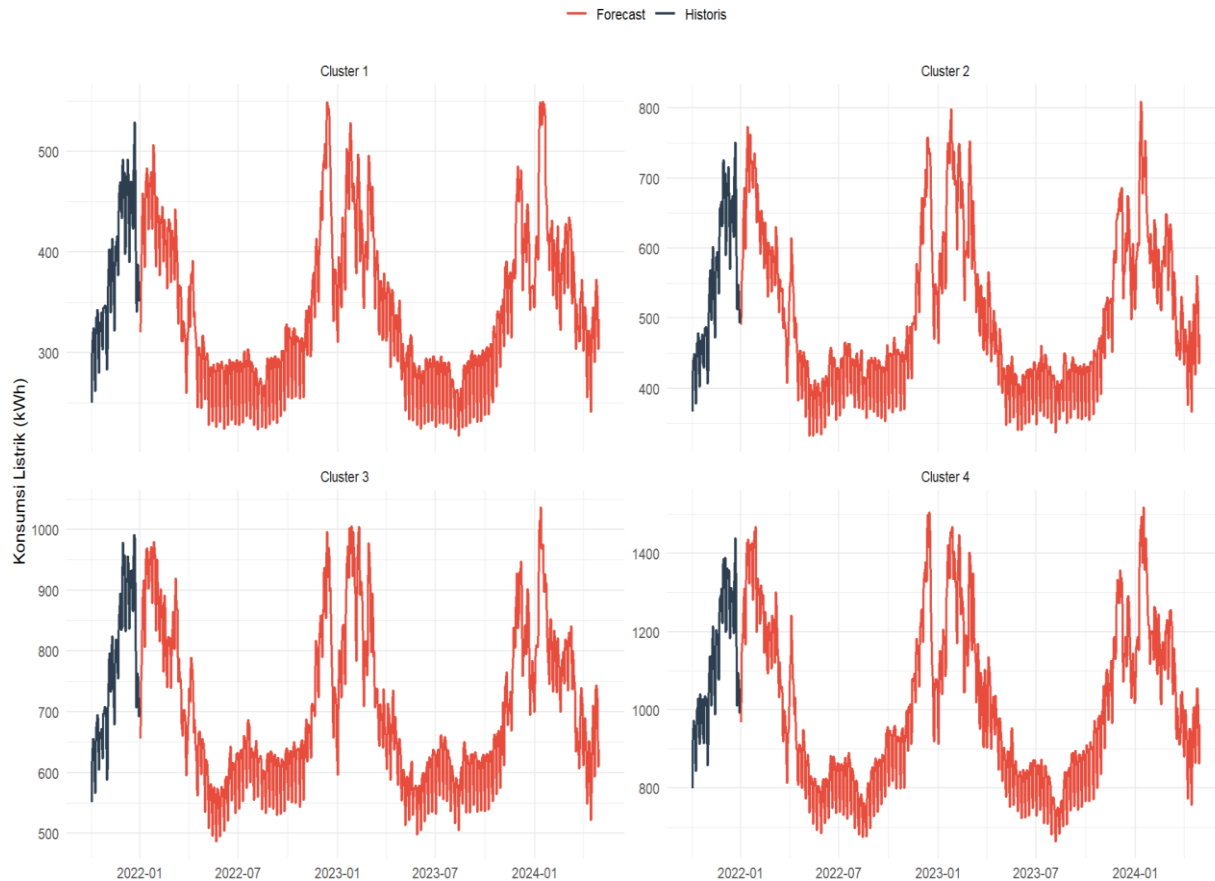
Hasil analisis (lihat Gambar 4) menunjukkan hierarki pengaruh variabel yang sangat jelas. Fitur *lag\_1* (beban satu hari sebelumnya) mendominasi secara absolut, memberikan kontribusi informasi terbesar bagi model. Posisi kedua ditempati oleh *lag\_7* (beban satu minggu sebelumnya), diikuti oleh fitur *dayofweek* (hari dalam minggu). Dominasi fitur-fitur autoregresif dan kalender ini mengonfirmasi sifat inersia sistem tenaga listrik: perilaku konsumsi masyarakat adalah rutinitas yang terpola secara harian dan mingguan. Pola mingguan (*dayofweek*) menjadi sangat penting karena membedakan antara hari kerja (*weekday*) dan akhir pekan (*weekend*), di mana aktivitas industri dan perkantoran menurun drastis pada hari Sabtu dan Minggu, menyebabkan profil beban yang sangat berbeda.

Di luar fitur waktu, variabel meteorologis yang paling berpengaruh adalah *temperature\_2m\_max* (suhu maksimum harian). Pengaruh suhu menempati urutan keempat terpenting, mengalahkan variabel cuaca lain seperti kecepatan angin atau durasi penyinaran matahari. Ini menegaskan hipotesis awal bahwa suhu adalah *driver* lingkungan utama untuk permintaan listrik, memicu penggunaan alat pemanas atau pendingin yang intensif energi. Fitur-fitur hasil rekayasa lanjutan, seperti *temp\_roll\_mean\_7* (rata-rata suhu 7 hari terakhir) dan fitur siklis (*wd\_sin*, *day\_sin*), memberikan kontribusi menengah yang membantu model melakukan penyesuaian prediksi pada periode transisi musim, memastikan model tidak "terkejut" oleh perubahan cuaca mendadak dan mampu beradaptasi dengan tren pemanasan atau pendinginan global.

### 3.4. Analisis Trajektori Prediksi dan Diskusi

Visualisasi hasil peramalan (*forecast trajectory*) pada data uji menunjukkan bahwa model *Ensemble* mampu mengikuti dinamika beban aktual dengan sangat presisi, bahkan pada periode volatilitas tinggi.

Gambar 2. Trajektori Konsumsi Listrik: Historis dan Hasil Forecast Ensemble  
Forecast dilakukan secara auto-regressive per hari untuk setiap cluster pelanggan



Gambar 5. Perbandingan Hasil Prediksi Model *Ensemble* terhadap Data Aktual pada Data Uji

Garis prediksi hampir berimpit sempurna dengan data historis pada sebagian besar periode waktu. Model berhasil menangkap pola musiman mingguan—penurunan beban di akhir pekan—serta tren musiman tahunan. Namun, inspeksi visual yang lebih detail mengungkapkan beberapa deviasi kecil yang menjadi bahan diskusi penting untuk pengembangan selanjutnya. Pada Kluster 1 dan 2, model cenderung melakukan *under-forecast* (prediksi lebih rendah dari aktual) pada saat beban puncak musim dingin yang ekstrem. Hal ini mungkin disebabkan oleh respon non-linier masyarakat terhadap suhu dingin yang ekstrem yang tidak sepenuhnya tertangkap oleh data latih, di mana penggunaan pemanas listrik mungkin melonjak secara eksponensial (bukan linier) ketika suhu melewati ambang batas tertentu (*threshold effect*).

Sebaliknya, pada Kluster 3 dan 4, terdapat kecenderungan *over-forecast* (prediksi lebih tinggi dari aktual) pada beberapa periode tertentu di musim panas. Deviasi positif ini kemungkinan besar disebabkan oleh adanya hari libur nasional atau cuti bersama yang bersifat spesifik dan tidak tertangkap oleh fitur kalender standar. Model mungkin mengira hari tersebut adalah hari kerja biasa karena jatuh pada hari Senin-Jumat, padahal aktivitas industri sedang libur, sehingga menyebabkan prediksi beban yang terlalu tinggi. Ini menyoroti pentingnya fitur kalender lokal yang spesifik dan integrasi data kejadian khusus untuk menangkap anomali beban.

### 3.5. Perbandingan dengan Penelitian Terkait

Hasil penelitian ini dapat diposisikan secara kompetitif di antara literatur terkini mengenai *Short-Term Load Forecasting* (STLF), khususnya dalam konteks perbandingan antara pendekatan *machine learning* klasik dan modern. Moon et al. (2024) melaporkan bahwa model Deep Learning untuk peramalan konsumsi listrik residensial mencapai  $R^2$  sebesar 0,93 dengan MAPE 2,9%, sedangkan model AdaBoost hanya mencapai MAPE 5,70% [8]. Jika dibandingkan, model *Ensemble* LightGBM-XGBoost dalam penelitian ini mencapai kinerja yang lebih baik dengan  $R^2$  0,996 dan MAPE 2,03%. Keunggulan ini mengindikasikan bahwa meskipun *Deep Learning* sering dianggap

sebagai *state-of-the-art*, pendekatan *Gradient Boosting* yang dioptimalkan dengan rekayasa fitur yang tepat (seperti fitur siklis dan lag) masih mampu memberikan akurasi yang superior pada data tabular, dengan kompleksitas komputasi yang jauh lebih rendah.

Lebih lanjut, temuan ini sejalan dengan studi Zhao et al. (2022) yang mengembangkan model TPE-XGBoost untuk peramalan beban regional. Mereka menemukan bahwa algoritma berbasis pohon keputusan sangat efektif dalam menangani data dengan karakteristik non-linier dan *missing values*, sebuah keunggulan yang juga terkonfirmasi dalam penelitian ini [13]. Zhao mencatat peningkatan akurasi sekitar 14% dibanding model dasar, sementara penelitian ini mencatat penurunan RMSE sebesar 31% dibanding regresi linier. Hal ini memperkuat argumen bahwa untuk data beban listrik yang memiliki pola musiman kuat dan *noise* dari variabel cuaca, algoritma *Gradient Boosting* menawarkan keseimbangan terbaik antara bias dan varians, serta lebih tahan (*robust*) terhadap pencilaan data dibandingkan model statistik konvensional atau jaringan saraf tiruan yang membutuhkan data sangat besar untuk konvergensi optimal.

Selain itu, penelitian ini juga memberikan kontribusi unik melalui penerapan metrik MASE (*Mean Absolute Scaled Error*) yang jarang digunakan dalam studi sejenis. Banyak penelitian sebelumnya, seperti yang dilakukan oleh Moon et al. (2024) [8], berfokus pada metrik absolut seperti RMSE dan MAE. Meskipun metrik tersebut penting, mereka tidak memberikan gambaran apakah model tersebut benar-benar memberikan nilai tambah informasi dibandingkan metode *naif* sederhana. Dengan melaporkan nilai MASE sebesar 0,0383, penelitian ini memberikan bukti empiris yang kuat bahwa model *ensemble* yang dibangun bukan hanya akurat secara statistik, tetapi juga memberikan peningkatan efisiensi prediksi yang signifikan secara praktis dibandingkan sekadar memproyeksikan beban hari kemarin ke hari esok, sebuah wawasan yang krusial bagi praktisi di industri utilitas.

### 3.6. Implikasi Manajerial dan Operasional

Dari perspektif operasional utilitas listrik, akurasi peramalan yang tinggi memiliki nilai ekonomi yang nyata dan terukur. Penurunan MAPE dari 3,36% (Regresi Linier) menjadi 2,03% (*Ensemble*) berarti pengurangan ketidakpastian beban sebesar lebih dari 1,3%. Dalam sistem tenaga skala gigawatt, deviasi beban sebesar 1% setara dengan ratusan megawatt daya yang harus dicadangkan. Dengan peramalan yang lebih akurat, operator sistem (System Operator) dapat mengurangi *spinning reserve* atau cadangan putar yang harus disiagakan "hanya untuk berjaga-jaga". Hal ini berdampak langsung pada penghematan biaya bahan bakar pembangkit *peaker* (biasanya berbahan bakar gas atau diesel) yang mahal dan kurang efisien, serta mengurangi frekuensi start-stop unit pembangkit yang dapat memperpendek umur mesin dan meningkatkan biaya pemeliharaan jangka panjang.

Selain efisiensi biaya, akurasi model ini mendukung integrasi energi terbarukan yang lebih agresif sesuai rekomendasi NREL [3]. Pembangkit energi terbarukan seperti tenaga surya dan angin memiliki sifat intermiten yang tinggi, sehingga membutuhkan perencanaan beban yang presisi untuk menjaga kestabilan frekuensi grid. Prediksi beban yang akurat membantu operator menyeimbangkan variabilitas pasokan dari PLTS dan PLTB dengan lebih percaya diri, mengurangi risiko pemadaman (*blackout*) akibat ketidakseimbangan pasokan-permintaan, dan meminimalkan kebutuhan akan pemadaman beban (*load shedding*) yang merugikan konsumen. Dengan demikian, model ini tidak hanya berfungsi sebagai alat prediksi, tetapi juga sebagai *enabler* strategis bagi transisi energi yang lebih bersih dan andal.

Terakhir, implementasi *pipeline* otomatis berbasis R tidymodels yang didemonstrasikan dalam penelitian ini menawarkan solusi *low-cost* namun *high-performance* bagi utilitas daerah atau pengelola gedung komersial. Berbeda dengan perangkat lunak komersial yang mahal dan tertutup (*proprietary*), pendekatan *open-source* ini memungkinkan kustomisasi penuh sesuai karakteristik lokal dan integrasi data baru secara fleksibel. Hal ini memberdayakan manajemen untuk mengambil keputusan berbasis data (*data-driven decision making*) dalam perencanaan operasional harian, manajemen aset trafo distribusi, hingga strategi penentuan tarif listrik dinamis (*dynamic pricing*) di masa depan, yang pada akhirnya akan meningkatkan daya saing dan keberlanjutan operasional perusahaan listrik di era digital.

## 4. KESIMPULAN

Penelitian ini berhasil merancang, mengimplementasikan, dan mengevaluasi sebuah sistem peramalan konsumsi listrik harian yang komprehensif menggunakan pendekatan *Ensemble Gradient Boosting*. Melalui penerapan kerangka kerja CRISP-DM yang sistematis, penelitian ini membuktikan bahwa integrasi algoritma LightGBM dan XGBoost dengan rekayasa fitur waktu dan cuaca yang mendalam mampu menghasilkan model prediksi yang sangat akurat dan *robust*.

Kesimpulan utama dari aspek kinerja model adalah superioritas metode *ensemble*. Model gabungan ini berhasil mencapai nilai MAPE terendah sebesar 2,03% dan  $R^2$  sebesar 0,996, mengungguli model Regresi Linier *baseline* secara signifikan dengan penurunan tingkat kesalahan (RMSE) mencapai 31%. Nilai MASE yang sangat rendah (0,038) menjadi validasi statistik yang kuat bahwa model ini memberikan peningkatan informasi yang nyata dibandingkan metode prediksi *naif*. Hal ini menunjukkan bahwa algoritma *machine learning* modern mampu mengekstrak pola kompleks dari data historis yang tidak dapat ditangkap oleh metode konvensional.

Dari sisi karakteristik data, penelitian ini menyimpulkan bahwa konsumsi listrik memiliki sifat autoregresif yang sangat kuat. Fitur lag (beban masa lalu) dan fitur kalender (*dayofweek*) teridentifikasi sebagai determinan utama fluktuasi beban. Variabel cuaca, khususnya suhu maksimum, terbukti memiliki korelasi negatif dengan beban, mengindikasikan karakteristik sistem beban yang didominasi oleh kebutuhan pemanas. Temuan ini memberikan wawasan bagi pembuat kebijakan energi bahwa sensitivitas beban terhadap perubahan iklim (suhu) perlu dimitigasi melalui standar efisiensi bangunan yang lebih baik.

Penelitian ini memiliki implikasi praktis yang luas. Bagi utilitas listrik, *pipeline* yang dihasilkan dapat langsung digunakan untuk mengoptimalkan perencanaan operasi harian, mengurangi biaya pembangkitan cadangan, dan meningkatkan keandalan sistem. Bagi akademisi dan praktisi data sains, penelitian ini menyediakan blueprint implementasi STLF menggunakan ekosistem R modern yang dapat direplikasi dan dikembangkan lebih lanjut.

Namun, penelitian ini tidak lepas dari keterbatasan. Evaluasi saat ini hanya menggunakan satu skema pembagian data latih-uji (*single split hold-out*). Penelitian selanjutnya disarankan untuk menerapkan validasi silang berbasis waktu (*time-series cross-validation*) untuk menguji stabilitas model di berbagai kondisi musim. Selain itu, deviasi prediksi pada hari-hari libur tertentu menunjukkan perlunya integrasi data eksternal tambahan, seperti kalender hari libur nasional dan tarif listrik dinamis, untuk meningkatkan akurasi pada periode anomali. Eksplorasi model hibrida yang menggabungkan *Gradient Boosting* untuk pola reguler dan *Deep Learning* (seperti LSTM) untuk menangkap dependensi jangka panjang juga menjadi arah pengembangan yang menjanjikan di masa depan.

## DAFTAR PUSTAKA

- [1] International Energy Agency, "Electricity 2025 – Analysis," IEA, Paris, 2025.
- [2] Ministry of Energy and Mineral Resources (ESDM), "*Handbook of Energy & Economic Statistics of Indonesia 2023*," Jakarta, 2023.
- [3] National Renewable Energy Laboratory (NREL), "*Short-Term Load Forecasting Error Distributions and Implications for Renewable Integration Studies*," Golden, CO, Tech. Rep., 2013.
- [4] R. Weron, *Electricity Price Forecasting: A Statistical Approach*. Chichester, UK: Wiley, 2014.
- [5] B. Ibrahim, L. Rabelo, E. Gutierrez-Franco, and N. Clavijo-Buritica, "*Machine learning for Short-Term Load Forecasting in Smart Grids*," *Energies*, vol. 15, no. 21, p. 8079, 2022.
- [6] T. Chen and C. Guestrin, "XGBoost: A scalable tree *boosting* system," in *Proc. 22nd ACM SIGKDD Int. Conf. Knowl. Discov. Data Min.*, San Francisco, CA, USA, 2016, pp. 785–794.
- [7] G. Ke et al., "LightGBM: A highly efficient *Gradient Boosting* decision tree," in *Advances in Neural Information Processing Systems*, vol. 30, Long Beach, CA, USA, 2017.
- [8] J. Moon, M. Maqsood, D. So, S. W. Baik, and Y. Nam, "Advancing *Ensemble Learning* techniques for residential building electricity consumption forecasting: Insight from explainable artificial intelligence," *PLOS ONE*, vol. 19, no. 11, p. e0307654, 2024.
- [9] A. dkk, "Nowcasting the next hour of residential load using *boosting ensemble* machines," *PMC*, 2024.
- [10] A. Kud, "Why We Need *Encoding Cyclical features*," *Medium*, 2020. [Online]. Available: <https://Medium.com>.
- [11] R. Salim and Vincent, "Seleksi Data Science Academy COMPFEST 17," Kaggle, 2025. [Online]. Available: <https://kaggle.com/competitions/seleksi-dsa-compfest-17>.
- [12] R. J. Hyndman and A. B. Koehler, "Another look at measures of forecast accuracy," *Int. J. Forecast.*, vol. 22, no. 4, pp. 679–688, 2006.
- [13] Q. Zhao et al., "Optimised *Extreme Gradient Boosting* model for short term electric load demand forecasting," *Sci. Rep.*, vol. 12, 2022.