JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)
Journal homepage: https://jurnal.stkippgritulungagung.ac.id/index.php/jipi
ISSN: 2540-8984
Vol. 10, No. 4, December 2025, Pp. 3054-3061

PREDIKSI KONSUMSI ENERGI LISTRIK BERBASIS METODE POHON KEPUTUSAN (STUDI KASUS: UNIVERSITAS WIDYA DHARMA PONTIANAK)

Paskalia Kartini*[1)], Jimmy Tjen[2)]
1. Sistem Informasi, Fakultas Teknologi Informasi, Universitas Widya Dharma Pontianak, Indonesia
2. Informatika, Fakultas Teknologi Informasi, Universitas Widya Dharma Pontianak, Indonesia

Article Info
Kata Kunci: Energi Listrik; Gradient boosting; Pohon Keputusan; Pohon Regresi; Random Forest

Keywords: Electrical Energy; Gradient Boosting; Decision Tree; Regression Tree; Random Forest

Article history:
Received 2 Oktober 2024
Revised 10 October 2024
Accepted 19 October 2024
Available online 1 December 2025

DOI :
https://doi.org/10.29100/jipi.v10i4.6751

* Corresponding author.
Corresponding Author
E-mail address:
paskalia@widyadharma.ac.id

ABSTRAK
Seiiring dengan berkurangnya ketersediaan bahan bakar fossil sebagai penghasil utama dari energi listrik, umat manusia modern dituntut untuk dapat mengoptimalkan penggunaan energi listrik secara optimal. Salah satu cara untuk mengoptimalkan penggunaan energi listrik adalah dengan memanfaatkan model berbasis data. Penelitian ini bertujuan untuk membangun algoritma prediksi konsumsi energi listrik dengan menggunakan metode pohon keputusan. Terdapat 6 variasi pohon keputusan yang digunakan dalam penelitian ini: *Gradient Boosting-Least Square* (GBLS) *Gradient Boosting-Bagging* (GBB), *Random Forest* (RF)-10, RF-50, RF-100 dan pohon regresi. Model pohon keputusan yang telah dibangun kemudian divalidasi akurasi model prediktifnya dengan menggunakan data konsumsi energi listrik dari gedung Padre Pio Universitas Widya Dharma Pontianak. Berdasarkan pada hasil percobaan yang dilakukan, metode GBLS merupakan metode yang paling akurat dalam memprediksikan konsumsi energi listrik, dengan akurasi sebesar 90,34%. Lebih lanjut, prediksi konsumsi energi listrik bulanan berbasis algoritma GBLS memiliki kesalahan maksimum sebesar 3 %, dengan kesalahan prediksi tahunan sebesar 0,04%. Hal ini menunjukan potensi dari metode GBLS dalam memprediksikan konsumsi energi listrik dari suatu gedung secara presisi.

ABSTRACT
Fossil oil, which has served as the main source for generating electric energy, has been rapidly declining over the past decades. Hence, modern mankind is expected to optimize energy consumption i.e., by utilizing data-driven models. This research aims to develop an algorithm for predicting electrical power consumption based on the decision tree learning method. Six variants of the decision tree were considered in this study: The Gradient Boosting-Least Square (GBLS) Gradient Boosting-Bagging *(GBB),* Random Forest (RF)-10, RF-50, RF-100, and the regression tree. The models were validated on real data taken from the Padre Pio building at Universitas Widya Dharma Pontianak, Indonesia. Based on the numerical simulations, it can be concluded that the GBLS method is the most accurate in predicting power consumption, with an accuracy of 90.34%. Furthermore, the GBLS-based model predicted the monthly power consumption with a maximum error of 3% and yearly prediction with an error of just 0.04%. These results demonstrated the potential of the GBLS method for accurately predicting the power consumption in buildings.

.

I. PENDAHULUAN

Bahan bakar fossil yang semakin langka telah mengakibatkan perubahan pola konsumsi energi listrik, dimana manusia pada saat ini cenderung menggunakan energi listrik secara boros dan sering kali tidak terkontrol. Oleh karena itu, para teknisi dan praktisi mendapat tuntutan untuk dapat menghasilkan ramalan konsumsi energi listrik yang akurat guna mengoptimalkan penggunaan energi listrik [1], [2]. Peramalan ini sebagai contoh dapat dilakukan dengan menggunakan model berbasis data (*data-driven model*) yang secara spesifik mempelajari dinamikan dari sebuah struktur bangunan [3], [4], [5]. Salah satu metode berbasis data yang sering digunakan adalah metode pohon keputusan atau *Decision Tree Learning* (DTL) dari algoritma *Classification and Regression Tree* (CART)[6], [7].

JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)
Journal homepage: https://jurnal.stkippgritulungagung.ac.id/index.php/jipi
ISSN: 2540-8984
Vol. 10, No. 4, December 2025, Pp. 3054-3061

Metode pohon keputusan merupakan sebauh metode yang menghasilkan struktur menyerupai pohon (*tree-like structure*) untuk mengklasifikasikan data berdasarkan pada kemiripan fiturnya. Dengan menggunakan metode ini, data akan dipecah menjadi bagian kecil yang terkumpul pada berbagai titik daun (*leaf node*) sesuai dengan kondisi pemisahan datanya (*splitting criterion*) [8]. Metode ini telah terbukti dapat memprediksi konsumsi energi listrik dengan baik seperti pada hasil yang ditunjukan pada: [9], [10], [11], [12].

Penelitian terkait. Pada [9], metode pohon regresi yang merupakan kelas dari pohon keputusan yang mengolah data kontinyu digunakan untuk memprediksikan konsumsi energi listrik dari gedung Fransiskus Assisi Universitas Widya Dharma Pontianak (FA-UWDP). Penelitian tersebut bertujuan untuk mengeksplorasi kemampuan dari metode pohon keputusan untuk menghasilkan peramalan konsumsi energi listrik dari data yang terbatas (*scarce dataset*). Berdasarkan pada percobaan yang telah dilakukan, dapat disimpulkan bahwa metode pohon keputusan dapat dengan baik memprediksi konsumsi energi dari gedung FA-UWDP meskipun dengan data yang terbatas dengan tingkat akurasi diatas 85%. Pada [10], metode pohon regresi digunakan untuk mengetahui pola konsumsi harian dari manusia yang berada di dalam sebuah gedung. Dalam kasus ini, metode pohon regresi digunakan untuk memperkirakan pola konsumsi energi listrik per jam guna mengidentifikasi pola kegiatan manusia di dalam sebuah gedung. Berdasarkan pada percobaan yang telah dilakukan, diketahui bahwa metode pohon regresi dapat memprediksi pola penggunaan energi listrik dengan tingkat kesalahan dibawah 10%.

Pada [11], metode *Random Forest* (RF) yang merupakan kumpulan dari pohon regresi digunakan untuk menentukan konsumsi energi listrik dari gedung Badan Perencanaan Pembangunan Daerah (Bappeda) Kalimantan Barat. Penelitian yang dilaksanakan pada tahun 2023 tersebut bertujuan untuk mengoptimasi penggunaan energi listrik gedung Bappeda Kalimantan Barat dengan memanfaatkan konsep *Internet of Things* (IoT). Berdasarkan pada penelitian yang telah dilakukan, terbukti bahwa metode RF dapat mengestimasi konsumsi energi listrik dengan baik. Terakhir, pada [12], telah dilakukan sebuah penelitian untuk menentukan efisiensi dari konsumsi energi listrik berdasarkan pada beberapa metode pohon pembelajaran. Berdasarkan pada percobaan yang telah dilakukan. Terlihat bahwa metode pohon keputusan tidak hanya memberikan akurasi yang baik dalam menentukan efisiensi konsumsi energi, namun dapat digunakan untuk menentukan parameter atau fitur data yang memiliki hubungan yang erat dengan efisiensi energi.

Kontribusi. Berdasarkan pada penelitian yang telah dibahas pada 2 paragraf sebelumnya, terlihat bahwa metode pohon keputusan memiliki potensi yang baik untuk meramalkan konsumsi energi listrik dari sebuah bangunan. Melihat potensi dari metode ini, maka penelitian ini disusun dengan menitik beratkan kontribusi sebagai berikut:

1. Penelitian ini bertujuan untuk menguji performa dari metode berbasis pohon keputusan diantaranya: *Gradient Boosting-Least Square* (GBLS) *Gradient Boosting-Bagging* (GBB), RF dan *Regression Tree* (RT) atau pohon regresi dalam memprediksi konsumsi energi listrik.
2. Penelitian ini berfokuskan untuk membangun algoritma peramalan konsumsi listrik berbasis metode pohon keputusan untuk gedung Padre Pio (PP) di UWDP Pontianak, Kalimantan Barat.

Penelitian ini menggunakan penelitian pada [9] dan [10] sebagai rujukan utama. Secara spesifik, penelitian ini memiliki tinjauan data yang mirip dengan data yang digunakan pada 2 penelitian yang telah disebutkan sebelumnya. Pada penelitian ini, data yang digunakan bersumber dari meteran pencatatan Perusahaan Listrik Negara (PLN) yang hanya memiliki informasi arus, tegangan dan konsumsi energi dalam sehari. Sehingga untuk memperoleh analisis yang lebih baik, maka data perlu di proses terlebih dahulu sesuai dengan metodologi yang dipaparkan pada [9] dan [10].

Penelitian ini tersusun dari 4 bagian utama dengan deskripsi sebagai berikut: Bagian pertama merupakan pendahuluan. Pada bagian kedua akan dibahas metodologi untuk menghasilkan ramalan konsumsi energi listrik untuk gedung PP-UWDP dengan berbagai metode berbasis pohon keputusan. lebih lanjut, pada bagian kedua akan dijelaskan terkait dengan himpunan data (*dataset*) yang digunakan dalam penelitian ini. Pada bagian ketiga akan ditunjukan akurasi model prediktif untuk metode yang telah disebutkan pada kontribusi pertama. Lebih lanjut, metode yang memberikan akurasi terbaik akan digunakan untuk meramalkan konsumsi energi listrik pada gedung PP-UWDP. Terakhir, bagian keempat akan menyimpulkan isi dari penelitian serta menunjukan arah penelitian selanjutnya dari penelitian ini.

II. METODOLOGI PENELITIAN

Pada bagian ini akan dibahas algoritma yang digunakan untuk memprediksi konsumsi energi listrik harian. Lebih lanjut, bahasan akan dilanjutkan dengan penjelasan terkait gedung PP-UWDP. Silahkan mengacu pada [13] terkait dengan informasi dasar dari metode pohon keputusan, dan [14] untuk informasi berhubungan dengan metode *gradient boosting*.

JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)
Journal homepage: https://jurnal.stkippgritulungagung.ac.id/index.php/jipi
ISSN: 2540-8984
Vol. 10, No. 4, December 2025, Pp. 3054-3061

A. *Prediksi Konsumsi Energi Listrik Berbasis Metode Pohon Keputusan*

Tinjau data konsumsi energi listrik harian dari gedung PP-UWDP. Misalkan $X \in \mathbb{R}^{m \times n}$ adalah sebuah himpunan data kelistrikan yang mengandung m buah sampel dan n buah parameter kelistrikan. Sebagai contoh, pada penelitian ini $n = 4$ karena terdapat 4 buah parameter yang digunakan yakni: 3 fasa arus dan tegangan. Sehingga dalam kasus ini, X dapat direpresentasikan sebagai $X = [\boldsymbol{I_1}\ \boldsymbol{I_2}\ \boldsymbol{I_3}\ \boldsymbol{V}]$, dengan $\boldsymbol{I_a}; a = 1,2,3$ menyatakan vektor arus fasa ke-k dan $\boldsymbol{V}$ menyatakan vektor tegangan listrik. Misalkan $\boldsymbol{e} = [e(1)\ e(2)\ \dots e(m)]^{\intercal}; \boldsymbol{e} \in \mathbb{R}^m$ adalah sebuah vektor konsumsi energi listrik, dengan $e(k); k = 1,2, \dots m$ menyatakan konsumsi energi listrik pada saat k. Lebih lanjut, misalkan $D = [\boldsymbol{h}\ \boldsymbol{t}\ \boldsymbol{b}\ \boldsymbol{t_a}]; D \in \mathbb{Z}^{m \times 4}$ adalah sebuah himpunan data terkait informasi waktu dari data, dimana: $\boldsymbol{h} \in [1,7]$ merupakan sebuah vektor berisikan nama hari (sebagai contoh: 1 untuk senin dan seterusnya), $\boldsymbol{t} \in [1,31]$ menyatakan vektor tanggal, $\boldsymbol{b} \in [1,12]$ menyatakan vektor bulan dan $\boldsymbol{t_a} \in \mathbb{Z}^+$ menyatakan vektor tahun. Berdasarkan definisi variabel di atas, maka tujuan dari metode ini adalah untuk menghasilkan sebuah vektor prediksi konsumsi energi listrik, $\hat{\boldsymbol{e}} = f(D, X);\ f: \mathbb{R}^{n_d} \to \mathbb{R}; n_d > n + 4$ dengan menggunakan metode pohon keputusan. Adapun proses peramalan konsumsi energi ini terdiri dari 2 tahap: mendefinisikan model arus dan mendefinisikan model konsumsi energi.

Tahap pertama: untuk menghasilkan model prediksi konsumsi energi yang akurat, maka pertama-tama perlu diturunkan model untuk memprediksi arus listrik. Dalam kasus ini, untuk setiap arus fasa, akan diturunkan sebuah model berbasis metode pohon regresi dengan masukkan berupa D dan $\bar{I}_{\boldsymbol{a},\boldsymbol{h}(\boldsymbol{k})} \in \mathbb{R}^m$ yang merupakan sebuah vektor yang berisikan rerata konsumsi arus listrik fasa ke-a pada hari $h(k)$:

$$\bar{I}_{a,h(k)}(k) = \frac{7}{k}\sum_{p=1}^{k} I_{a,p},$$
$$I_{a,p} = \begin{cases} I_a(p) \text{ jika } p = h(k) \\ 0 \text{ jika lainnya} \end{cases}. \quad (1)$$

Dalam kasus ini, prediksi untuk ketiga fasa arus dapat dinyatakan sebagai:

$$\hat{I}_1(k) = f_{RT1}\left(h(k), t(k), b(k), t_a(k), \bar{I}_{1,h(k)}(k)\right);$$
$$\hat{I}_2(k) = f_{RT2}\left(h(k), t(k), b(k), t_a(k), \bar{I}_{2,h(k)}(k)\right) \quad (2)$$
$$\hat{I}_3(k) = f_{RT3}\left(h(k), t(k), b(k), t_a(k), \bar{I}_{3,h(k)}(k)\right).$$

Dengan $[h(k)\ t(k)\ b(k)\ t_a(k)]$ menyatakan informasi waktu pada saat k, $f_{RT1}: \mathbb{R}^5 \to \mathbb{R}$, $f_{RT2}: \mathbb{R}^5 \to \mathbb{R}$ dan $f_{RT3}: \mathbb{R}^5 \to \mathbb{R}$ menyatakan fungsi pohon regresi untuk ketiga fasa arus.

Pada proses ini, model arus pada persamaan (2) kemudian akan digunakan untuk menurunkan model konsumsi energi listrik. Penurunan model arus listrik untuk ketiga fasa dibutuhkan karena tegangan listrik yang berasal dari PLN memiliki nilai yang stabil pada 235V dengan deviasi maksimum sebesar 3V. oleh karena itu, jika hanya mengandalkan informasi tegangan listrik, model konsumsi energi listrik yang dihasilkan tidak akan memberikan prediksi yang akurat.

Tahap kedua: berdasarkan pada persamaan (2), maka model konsumsi energi listrik dapat dinyatakan sebagai

$$\hat{e}(k) = f_{DT}\left(h(k), t(k), b(k), t_a(k), \hat{I}_1(k), \hat{I}_2(k), \hat{I}_3(k), e(k-1)\right), \quad (3)$$

Dengan $e(k-1)$ menyatakan informasi konsumsi energi listrik pada saat $k-1$ dan $f_{DT}: \mathbb{R}^8 \to \mathbb{R}$ menyatakan fungsi pohon keputusan atau *decision tree.* Dalam kasus ini, metode pohon keputusan yang digunakan dapat mengacu pada model yang dihasilkan dari metode pohon regresi, RF ataupun dari *gradient boosting*. Berbeda dari tahap pertama yang menggunakan tambahan rerata arus untuk membangun model, pada tahap kedua informasi tambahan yang digunakan adalah konsumsi energi 1 masa sebelumnya. Hal ini dikarenakan konsumsi energi bersifat berkelanjutan. Sehingga, lebih tepat untuk mengambil dinamika pada 1 saat sebelumnya ketimbang mengambil rerata dari parameter terikat. Gambar 1. Menjelaskan diagram alir dari algoritma prediksi konsumsi energi listrik berbasis metode pohon keputusan. Sedangkan Algoritma 1 menjelaskan pseudocode untuk metode tersebut.

B. *Studi Kasus: Gedung Padre Pio*

Data yang digunakan untuk memvalidasi metodologi penelitian ini bersumber dari gedung PP-UWDP. Data berasal dari meteran pencatatan konsumsi energi listrik milik PLN yang dihimpun selama 3 tahun, terhitung dari tanggal 1 Januari 2021 hingga 1 Januari 2023. Data terdiri dari 1095 sampel dengan 14 parameter: tanggal, energi (KWh) dan daya (KW) yang dikirimkan dari trafo PLN, energi (KWh) dan daya (KW) yang dikirimkan pengguna

JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)
Journal homepage: https://jurnal.stkippgritulungagung.ac.id/index.php/jipi
ISSN: 2540-8984
Vol. 10, No. 4, December 2025, Pp. 3054-3061

karena menggunakan panel surya (informasi ini kosong), 3 fasa arus (A), 3 fasa tegangan (V), faktor daya, energi (KWh) dan daya (KW) yang di konsumsi.

ALGORITMA 1: PREDIKSI KONSUMSI ENERGI LISTRIK BERBASIS METODE POHON KEPUTUSAN

Masukan : data kelistrikan X; data waktu D; sampel latih n_{latih};vektor konsumsi energi listrik $\boldsymbol{e}$
Keluaran : prediksi konsumsi energi listrik $\hat{\boldsymbol{e}}$
Proses :

untuk $a = 1:3$
  untuk $k = 1{:}\,n_{latih}$
    $\bar{I}_{a,k} = \text{rerata}\left(\text{I}_\text{a}\left(\text{temukan}\left(\text{k} == \text{h(k)}\right)\right)\right)$
  akhiri untuk k
akhiri untuk a
$\text{Pohon1} = \text{pohon_regresi}(h, t, b, t_a, \bar{I}_{1,h})$
$\text{Pohon2} = \text{pohon_regresi}(h, t, b, t_a, \bar{I}_{2,h})$
$\text{Pohon3} = \text{pohon_regresi}(h, t, b, t_a, \bar{I}_{3,h})$

tahap pertama
untuk $k = 1:$ n_latih
$\hat{I}_1(k) = \text{prediksi}\left(h(k), t(k), b(k), t_a(k), \bar{I}_{1,h(k)}(k)\right)$
$\hat{I}_2(k) = \text{prediksi}\left(h(k), t(k), b(k), t_a(k), \bar{I}_{2,h(k)}(k)\right)$
$\hat{I}_3(k) = \text{prediksi}\left(h(k), t(k), b(k), t_a(k), \bar{I}_{3,h(k)}(k)\right)$
akhiri untuk k

tahap kedua
$\text{e}_{t-1} = \text{lag(e, 1)}$
$\text{Pohon_energi} = \text{pohon_keputusan}(h, t, b, t_a, \hat{I}_1, \hat{I}_2, \hat{I}_3, \text{e}_{t-1})$
untuk $k = \text{n}_\text{latih}$: selesai
$\hat{e}(k) = \text{prediksi}(h(k), t(k), b(k), t_a(k), \hat{I}_1(k), \hat{I}_2(k), \hat{I}_3(k), e_{t-1}(k))$
akhiri untuk k

Penelitian ini hanya menggunakan parameter 3 fasa arus ($\boldsymbol{I_1, I_2}$ dan $\boldsymbol{I_3}$) dan tanggal (D) untuk memprediksi konsumsi energi listrik ($\boldsymbol{e}$). Hal ini didasarkan pada hasil penelitian [15] yang menjelaskan bahwa parameter arus memiliki pengaruh dominan dalam memprediksi konsumsi energi listrik. Terkait dengan informasi tanggal, parameter ini hanya mengandung informasi hari dalam 1 bulan, bulan dan tahun. Oleh karena itu, sebelum digunakan, data ini akan diekspansikan terlebih dahulu untuk memuat informasi hari dalam 1 minggu (*day of week*). Hal ini didasarkan pada asumsi bahwa konsumsi energi listrik harian (sebagai contoh: hari Senin atau Selasa) memiliki nilai yang berbeda, sesuai dengan hasil penelitian yang ditunjukan pada [10].

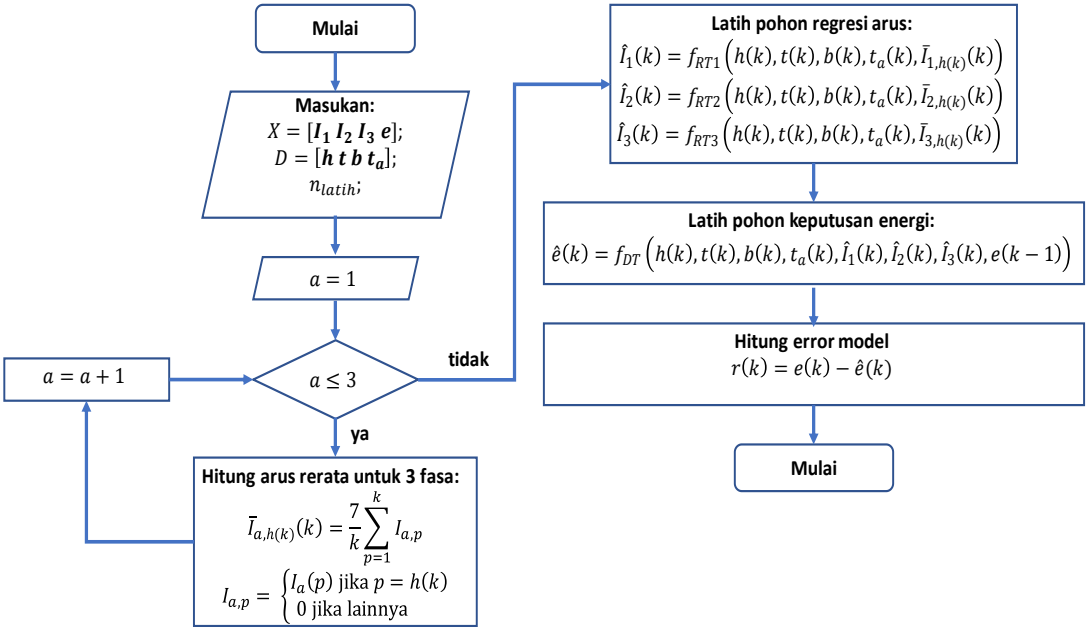

Gambar 1. Diagram Alir untuk metode prediksi konsumsi energi listrik berbasis pohon keputusan

Lebih lanjut, dipilih n_{latih} sebesar 730 sampel atau sekitar 2/3 atau 67% dari data yang ada. Selebihnya, data yang tersisa digunakan untuk memvalidasi akurasi model dalam memprediksi konsumsi energi listrik. Pemilihan data ini dilakukan untuk melatih model dengan data observasi selama 2 tahun (2021 dan 2022), dan kemudian diuji performanya untuk memprediksi konsumsi energi listrik selama 1 tahun (2023).

JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)
Journal homepage: https://jurnal.stkippgritulungagung.ac.id/index.php/jipi
ISSN: 2540-8984
Vol. 10, No. 4, December 2025, Pp. 3054-3061

III. HASIL DAN PEMBAHASAN

Pada bagian ini akan dibahas performa dari metode yang digagas meliput: akurasi model prediktif dan estimasi konsumsi energi listrik pada tahun 2023 untuk gedung PP-UWDP. Terkait dengan hal ini, ada 3 parameter pengujian kualitas model prediktif yang digunakan: *Root Mean Square Error* (RMSE), *Normalized Root Mean Square Error* (NRMSE), *Mean Absolute Percentage Error* (MAPE) dan akurasi.

Untuk dua buah vektor $y \in \mathbb{R}^n$ dan $\hat{y} \in \mathbb{R}^n$; dimana $\hat{y}$ merupakan estimasi dari y, RMSE atau galat rerata kuadrat merupakan sebuah besaran yang menyatakan rerata simpangan dari setiap sampel $\hat{y}$ dalam mengestimasi y. RMSE dinyatakan sebagai

$$RMSE(y, \hat{y}) = \sqrt{\frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)}{n}}. \quad (4)$$

Dengan n menyatakan banyaknya element dari vektor y. Sedangkan galat rerata kuadrat ternormalisasi atau NRMSE yang merupakan bentuk ternormalisasi dari RMSE dinyatakan sebagai

$$NRMSE(y, \hat{y}) = \frac{1}{\bar{y}} RMSE(y, \hat{y}). \quad (5)$$

Dengan $\bar{y}$ menyatakan rerata dari y. NRMSE merupakan besaran yang berguna untuk menunjukan tingkat kesalahan dari prediksi. Berdasarkan pada [16], akurasi model prediktif dapat diturunkan dari fungsi NRMSE sebagai:

$$\%A(y, \hat{y}) = \left(1 - NRMSE(y, \hat{y})\right) \times 100\% . \quad (6)$$

Dengan $\%A$ menyatakan proporsi dari y yang mampu diprediksi oleh $\hat{y}$. Terakhir, galat rerata absolute atau MAPE menyatakan rerata selisih mutlak dari dua buah vektor. MAPE didefinisikan sebagai

$$MAPE(y, \hat{y}) = \frac{1}{n}\sum_{i=1}^{n}\left|\frac{y_i - \hat{y}_i}{y_i}\right| \times 100\%. \quad (7)$$

Semua besaran ini akan digunakan untuk menguji kemampuan prediksi dari metode pohon keputusan. secara khusus, terdapat 6 variasi dari pohon keputusan yang akan diuji performanya: GBLS, GBB, RF-10, RF-50, RF-100 dan pohon regresi. Setelah ditentukan model terbaik untuk memprediksi konsumsi energi listrik, maka akan dilanjutkan dengan peramalan konsumsi energi listrik bulanan dan estimasi biaya yang dibutuhkan. Pada penelitian ini, Gedung PP-UWDP berada pada golongan S-2, sehingga dikenakan biaya sebesar Rp. 925 per KWh.

A. Akurasi Model Prediktif

Tabel 1 menunjukan hasil akurasi model prediktif untuk 7 variasi pohon keputusan yang digunakan. Terlihat dari Tabel 1 bahwa metode pohon regresi dan GBLS adalah 2 metode yang memiliki akurasi paling tinggi dalam memprediksikan konsumsi energi listrik dari gedung PP-UWDP. Sedangkan metode RF-10 merupakan metode dengan akurasi model prediktif paling rendah relatif terhadap 5 metode lainnya. Hasil ini telah menunjukan peningkatan dari akurasi model prediktif sebesar 2% dari [9], yang juga meneliti serupa terkait prediksi konsumsi energi listrik pada gedung Fransiskus Asisi UWDP. Hal ini menunjukan potensi dari GBLS dan pohon regresi untuk digunakan dalam mengestimasi konsumsi energi listrik dari suatu gedung.

TABEL 1.
AKURASI MODEL PREDIKTIF UNTUK 6 VARIASI POHON KEPUTUSAN

Model Pohon Keputusan	RMSE	NRMSE	MAPE	%A
Gradient Boosting - Least Square (GBLS)*	1,61	0,09	5,55 %	90,34 %
Gradient Boosting - Bagging (GBB)	2.49	0,15	13,03 %	85,01 %
Pohon Regresi*	1,71	0.10	4,42 %	89,71 %
Random Forest -10 Pohon (RF-10)	4,28	0,25	10,11 %	74,25 %
Random Forest - 50 Pohon (RF-50)	3,03	0,18	5,26 %	81,75 %
Random Forest - 100 Pohon (RF-100)	2,85	0,17	5,63 %	82,85 %

*Metode dengan akurasi terbaik

Jika memandang hanya pada angka saja, maka GBLS merupakan metode yang menghasilkan akurasi model prediktif terbaik dalam memprediksi konsumsi energi listrik. Namun, jika kompleksitas waktu juga dipertimbangkan, maka metode pohon regresi merupakan metode yang lebih baik. Pembuktian dari klaim ini ditunjukan dalam analisa berikut: Tinjau metode GBLS. Metode GBLS terdiri dari 2 proses utama: hasilkan pohon regresi dan perkuat model pohon. Pada proses pertama, untuk sebuah data dengan m sampel dan n fitur, maka model pohon regresi memiliki kompleksitas waktu sebesar $O(n \cdot log(n))$[16]. Sedangkan pada proses optimasi

JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)
Journal homepage: https://jurnal.stkippgritulungagung.ac.id/index.php/jipi
ISSN: 2540-8984
Vol. 10, No. 4, December 2025, Pp. 3054-3061

TABEL 2.
WAKTU PEMROSESAN DARI ALGORITMA GBRT DAN POHON REGRESI DALAM SATUAN DETIK PADA COMPUTER DENGAN RAM 16 GB DAN CPU CORE I7 7TH GEN

No	GBRT	RT
1	4,95	3,05
2	3,62	2,77
3	3,78	2,76
4	3,82	2,87
5	3,67	2,80
6	3,64	2.84
7	3,80	2,90
8	3,62	2,83
9	3,76	2,85
10	3,60	2,92
Rerata	3,83	2,86

kuadrat terkecil atau *least-square* yang melibatkan perhitungan residu pada nilai sebenarnya dan prediksi, proses ini dapat diselesaikan dalam $O(n)$. Jika proses optimasi ini diulang sebanyak p kali, maka dibutuhkan waktu sebesar $O(p \cdot n \cdot \log(n))$. Sehingga keseluruhan proses dari GBLS akan berada pada kompleksitas waktu $O(p \cdot n \cdot \log(n) + n \cdot \log(n))$ atau dapat disederhanakan menjadi $O\big((p+1) \cdot n + n \cdot \log(n)\big) \in O(p.n \cdot \log(n)) > n \cdot \log(n)$. Sehingga waktu yang dibutuhkan untuk menyelesaikan 1 kali algoritma GBLS akan lebih besar dari pada algorithma pohon regresi.

Untuk memvalidasi perhitungan teoritik yang telah dipaparkan di atas, maka dirasa perlu untuk melakukan percobaan untuk mengukur *runtime* dari metode GBRT dan pohon regresi. Tabel 2 menunjukan perhitungan *runtime* dari kedua metode pada mesin komputer dengan RAM 16 *GigaByte* (GB), dengan unit pemrosesan *Core i7 7th Gen* dalam satuan detik. Percobaan diulang sebanyak 10 kali untuk mendapatkan hasil yang lebih *valid*. Terlihat dari Tabel 2 bahwa kedua metode memiliki waktu perhitungan yang kurang lebih sama, dengan GBRT membutuhkan waktu 1 detik lebih lama daripada metode pohon regresi.

Menimbang hasil pada Tabel 1 dan 2, serta analisa kompleksitas waktu yang telah dipaparkan pada paragraf sebelumnya, maka idealnya metode yang digunakan adalah metode pohon regresi. Namun, penelitian ini tetap menggunakan metode GBLS untuk menghasilkan konsumsi energi listrik bulanan pada gedung PP-UWDP. Alasannya pada *robustness* atau kehandalan dari algoritma, dimana algoritma GBLS lebih handal jika dibandingkan dengan metode pohon regresi seperti yang ditunjukan pada penelitian serupa yang telah dilakukan pada [17], [18], [19]. Metode GBLS telah dioptimasi dengan metode *least-square* sehingga lebih stabil terhadap perubahan data, jika dibandingkan dengan metode pohon regresi yang belum di-*tuning*[18]. Sehingga metode GBLS lebih stabil untuk digunakan pada data yang memiliki fluktuasi tinggi seperti pada konsumsi energi listrik[17]. Pembahasan terkait dengan estimasi konsumsi energi listrik akan dibahas pada sub bagian 3-B.

B. Estimasi Konsumsi Energi Listrik Bulanan

Gambar 2 menunjukan grafik estimasi konsumsi listrik pada gedung PP-UWDP selama tahun 2023 dengan menggunakan metode GBLS. Tabel 3 menunjukan hasil prediksi konsumsi energi listrik bulanan untuk tahun 2023. Lebih lanjut pada Tabel 3, ditunjukan pula selisih antara prediksi dan nilai sebenarnya dari konsumsi energi listrik pada gedung PP-UWDP.

Terlihat dari Gambar 2 dan Tabel 3 bahwa estimasi dari konsumsi energi mirip dengan realitanya, dengan tingkat kesalahan prediksi harian sekitar 0,007 KWh atau jika disetarakan dalam rupiah, maka kesalahan prediksi berada pada kisaran Rp. 6,50 per harinya. Hasil ini menunjukan potensi dari algoritma untuk digunakan dalam mengestimasi konsumsi energi listrik tahunan pada suatu gedung. Informasi ini dapat digunakan sebagai contoh dalam merencanakan anggaran keuangan tahunan untuk pembayaran tagihan listrik. Dengan demikian dapat dihasilkan perencanan anggaran keuangan yang lebih baik, dan tidak mengakibatkan pembengkakan atau defisit anggaran karena kesalahan kalkulasi dan penganggaran biaya.

Lebih lanjut pada Tabel 3, terlihat bahwa konsumsi energi listrik tertinggi terjadi pada kisaran pertengahan (Mei-Juni) dan akhir tahun (November-Desember). Hal ini disebabkan karena gedung PP-UWDP tidak difungsikan secara utama untuk keperluan perkuliahan, namun sebagai kantor administrasi bagi staff dan tenaga kependidikan UWDP. Selain kantor administrasi, Lantai 4 dari gedung PP-UWDP difungsikan sebagai ruang sidang skripsi bagi mahasiswa di jurusan Fakultas Teknologi Informasi (FTI). Meskipun dapat dilaksanakan pada bulan apa saja sesuai

JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)
Journal homepage: https://jurnal.stkippgritulungagung.ac.id/index.php/jipi
ISSN: 2540-8984
Vol. 10, No. 4, December 2025, Pp. 3054-3061

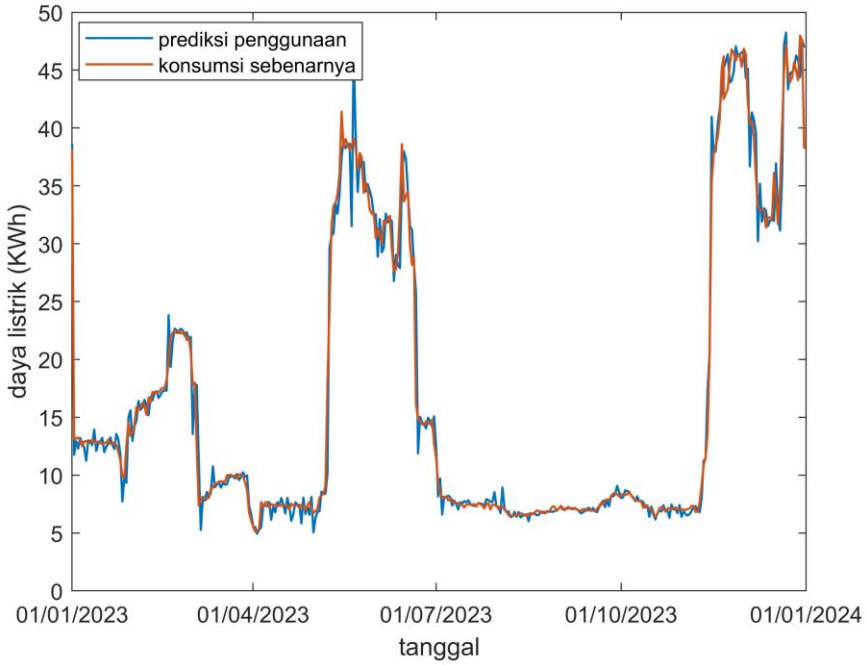

Gambar 2. Estimasi konsumsi energi listrik pada gedung Padre Pio Universitas Widya Dharma Pontianak pada tahun 2023

dengan jadwal yang disepakati oleh mahasiswa, kepala program studi dan dosen, namun kegiatan ujian sidang skripsi mahasiswa FTI UWDP lazimnya difokuskan pada 4 periode: Oktober, Desember, April dan Juni. Sehingga hal ini mempengaruhi konsumsi energi listrik pada gedung PP-UWDP pada periode tersebut.

Penggunaaan konsumsi energi listrik terendah untuk gedung PP-UWDP terjadi pada periode April, Agustus dan September. Dimana, pada bulan Agustus dan September merupakan masa libur semester genap, sehingga minim kegiatan pada gedung tersebut. Sedangkan pada bulan April 2023, terdapat banyak libur nasional dan keagamaan (paskah dan idul fitri) yang bersifat insidentil. Berdasarkan Tabel 3, dapat dilihat bahwa metode yang digagas tidak hanya mampu memprediksikan konsumsi energi bulanan dengan akurat, namun juga dapat memberikan gambaran terkait pola konsumsi energi dan prakiraan kepadatan aktivitas manusia dalam gedung tersebut.

Meskipun mampu memberikan prediksi yang akurat, prediksi konsumsi energi listrik yang dihasilkan belum dapat digunakan untuk memprediksi konsumsi energi listrik per jam. Hal ini karena metode GBRT merupakan metode berbasis data, sehingga jumlah data akan mempengaruhi performa dari algoritma tersebut [20]. Secara spesifik, semakin variatif dan banyak data yang digunakan, maka prediksi yang dihasilkan akan semakin akurat. Sehingga jika tidak tersedia data dalam satuan jam, maka tidak dimungkinkan untuk menghasilkan prediksi terkait konsumsi energi listrik per jam. Hal ini dirasa menarik untuk dilanjutkan pada penelitian terkait selanjutnya, sehingga dapat dihasilkan model yang lebih spesifik dan akurat.

TABEL 3.
PREDIKSI KONSUMSI ENERGI LISTRIK PADA GEDUNG PADRE PIO UNIVERSITAS WIDYA DHARMA PONTIANAK

Bulan	Konsumsi sebenarnya	Prediksi	Selisih	MAPE
Januari	418,27	412,81	5,45	1,31 %
Februari	523,12	521,18	1,93	0,37 %
Maret	310,76	316,32	-5,56	1,79 %
April	213,08	206,91	6,16	2,89 %
Mei	891,38	877,49	13,89	1,56 %
Juni	771,00	783,67	-12,66	1,64 %
Juli	240,60	244,11	-3,50	1,45 %
Agustus	211,20	210,42	0,77	0,36 %
September	221,50	220,60	0,89	0,40 %
Oktober	230,13	228,80	1,32	0,57 %
November	821,20	827,61	-6,41	0,78 %
Desember	1221,46	1226,21	-4,74	0,38 %
Tahunan	**6073,73**	**6076,17**	**-2,43**	**0,04 %**

IV. KESIMPULAN

Pada penelitian ini telah dibahas sebuah metode peramalan konsumsi energi listrik berbasis metode pohon keputusan. Metode yang digagas pada penelitian ini, melanjutkan hasil penelitian sebelumnya yang mengabungkan informasi pada masa lampau dan mengambil rerata dinamika untuk menghasilkan model yang lebih akurat. Berdasarkan pada percobaan yang telah dilakukan, dari 6 variasi pohon keputusan yang diuji, metode GBLS merupakan metode dengan akurasi dan kehandalan terbaik, disusul oleh metode pohon regresi biasa. Hal ini menunjukan bahwa optimasi dengan metode *least-square* mampu memperkuat pohon regresi dalam memprediksi konsumsi energi listrik dari sebuah gedung.

Lebih lanjut, metode GBLS mampu memprediksi konsumsi energi listrik dari gedung PP-UWDP dengan akurasi sebesar 90,34% dengan tingkat kesalahan prediksi bulanan 5 persen. Hal ini menunjukan potensi dari algoritma GBLS dalam membantu penyusunan anggaran pemakaian listrik pada suatu instansi. Secara khusus, arah penelitian lanjutan dari penelitian ini adalah untuk mengemas algoritma ini menjadi sebuah sistem penunjang keputusan atau *decision support system* dalam membantu perencanaan anggaran. Algoritma ini juga dapat diperluas konsepnya, tidak hanya memprediksikan konsumsi energi listrik, namun juga kebutuhan air bersih, sehingga dapat dihasilkan analisis yang lebih mendalam dan membantu perencanaan anggaran yang lebih luas.

Penelitian lanjutan pada hal teknis dapat mengacu pada mempelajari pola konsumsi energi listrik per satuan jam, sehingga dapat dipetakan penggunaan dari sebuah gedung per satuan jam. Hal ini akan mempermudah kontrol dari suatu ruangan sekaligus dapat membantu mempelajari pola penggunaan energi listrik dari suatu ruangan pada gedung. Lebih lanjut, penelitian lanjutan juga dapat berfokuskan untuk mengidentifikasi parameter lain selain arus yang berpotensi untuk menghasilkan model yang lebih akurat.

DAFTAR PUSTAKA

[1] W. Jiang, X. Wu, Y. Gong, W. Yu, and X. Zhong, "Holt–Winters smoothing enhanced by fruit fly optimization algorithm to forecast monthly electricity consumption," *Energy*, vol. 193, p. 116779, Feb. 2020, doi: 10.1016/j.energy.2019.116779.

[2] G. Memarzadeh and F. Keynia, "Short-term electricity load and price forecasting by a new optimal LSTM-NN based prediction algorithm," *Electric Power Systems Research*, vol. 192, p. 106995, Mar. 2021, doi: 10.1016/j.epsr.2020.106995.

[3] I. H. Sarker, "Smart City Data Science: Towards data-driven smart cities with open research issues," *Internet of Things*, vol. 19, p. 100528, Aug. 2022, doi: 10.1016/j.iot.2022.100528.

[4] P. Gupta and R. Singh, "PV power forecasting based on data-driven models: a review," *International Journal of Sustainable Engineering*, vol. 14, no. 6, pp. 1733–1755, Nov. 2021, doi: 10.1080/19397038.2021.1986590.

[5] J. Zhu, H. Dong, W. Zheng, S. Li, Y. Huang, and L. Xi, "Review and prospect of data-driven techniques for load forecasting in integrated energy systems," *Appl Energy*, vol. 321, p. 119269, Sep. 2022, doi: 10.1016/j.apenergy.2022.119269.

[6] Z. Dong, J. Liu, B. Liu, K. Li, and X. Li, "Hourly energy consumption prediction of an office building based on ensemble learning and energy consumption pattern classification," *Energy Build*, vol. 241, p. 110929, Jun. 2021, doi: 10.1016/j.enbuild.2021.110929.

[7] B. Charbuty and A. Abdulazeez, "Classification Based on Decision Tree Algorithm for Machine Learning," *Journal of Applied Science and Technology Trends*, vol. 2, no. 01, pp. 20–28, Mar. 2021, doi: 10.38094/jastt20165.

[8] N. A. Priyanka and D. Kumar, "Decision tree classifier: a detailed survey," *International Journal of Information and Decision Sciences*, vol. 12, no. 3, p. 246, 2020, doi: 10.1504/IJIDS.2020.108141.

[9] T. Darmanto, J. Tjen, and G. Hoendarto, "Monte Carlo Simulation-Based Regression Tree Algorithm for Predicting Energy Consumption from Scarce Dataset," *Journal of Data Science and Intelligent Systems*, 2024, doi: 10.47852/bonviewJDSIS42022395.

[10] T. Willay, J. Tjen, and P. Kartini, "Understanding Human Daily Activity Pattern Inside a Structure Via Power Consumption Modeling," in *2023 14th International Conference on Information & Communication Technology and System (ICTS)*, IEEE, Oct. 2023, pp. 211–216. doi: 10.1109/ICTS58770.2023.10330827.

[11] S. D. Panjaitan, J. Tjen, B. W. Sanjaya, F. T. P. Wigyarianto, and S. Khouw, "A Forecasting Approach for IoT-Based Energy and Power Quality Monitoring in Buildings," *IEEE Transactions on Automation Science and Engineering*, vol. 20, no. 2, pp. 892–900, Apr. 2023, doi: 10.1109/TASE.2022.3171561.

[12] M. Ferro, G. D. Silva, F. B. de Paula, V. Vieira, and B. Schulze, "Towards a sustainable artificial intelligence: A case study of energy efficiency in decision tree algorithms," *Concurr Comput*, vol. 35, no. 17, Aug. 2023, doi: 10.1002/cpe.6815.

[13] V. G. Costa and C. E. Pedreira, "Recent advances in decision trees: an updated survey," *Artif Intell Rev*, vol. 56, no. 5, pp. 4765–4800, May 2023, doi: 10.1007/s10462-022-10275-5.

[14] A. V. Konstantinov and L. V. Utkin, "Interpretable machine learning with an ensemble of gradient boosting machines," *Knowl Based Syst*, vol. 222, p. 106993, Jun. 2021, doi: 10.1016/j.knosys.2021.106993.

[15] G. Hoendarto, A. Saikhu, and R. V. H. Ginardi, "Daily Power Consumption Plan Derivation via the Monte Carlo-Based Regression Tree Algorithm," in *Proceedings of the 2024 10th International Conference on Computing and Artificial Intelligence*, New York, NY, USA: ACM, Apr. 2024, pp. 404–408. doi: 10.1145/3669754.3669816.

[16] F. Smarra, J. Tjen, and A. D'Innocenzo, "Learning methods for structural damage detection via entropy-based sensors selection," *International Journal of Robust and Nonlinear Control*, vol. 32, no. 10, pp. 6035–6067, Jul. 2022, doi: 10.1002/rnc.6124.

[17] U. Singh, M. Rizwan, M. Alaraj, and I. Alsaidan, "A Machine Learning-Based Gradient Boosting Regression Approach for Wind Power Production Forecasting: A Step towards Smart Grid Environments," *Energies (Basel)*, vol. 14, no. 16, p. 5196, Aug. 2021, doi: 10.3390/en14165196.

[18] M. Douiba, S. Benkirane, A. Guezzaz, and M. Azrour, "An improved anomaly detection model for IoT security using decision tree and gradient boosting," *J Supercomput*, vol. 79, no. 3, pp. 3392–3411, Feb. 2023, doi: 10.1007/s11227-022-04783-y.

[19] E. K. Sahin, "Comparative analysis of gradient boosting algorithms for landslide susceptibility mapping," *Geocarto Int*, vol. 37, no. 9, pp. 2441–2465, May 2022, doi: 10.1080/10106049.2020.1831623.

[20] J. Zhu, H. Dong, W. Zheng, S. Li, Y. Huang, and L. Xi, "Review and prospect of data-driven techniques for load forecasting in integrated energy systems," *Appl Energy*, vol. 321, p. 119269, Sep. 2022, doi: 10.1016/j.apenergy.2022.119269.