

## PERBANDINGAN KINERJA JARINGAN SARAF TIRUAN DAN SEASONAL NAÏVE DALAM PERAMALAN KONSUMSI LISTRIK BULANAN RUMAH TANGGA: STUDI WALK-FORWARD VALIDATION

Budi Antoro<sup>1</sup>, Nurhayati<sup>2</sup>, Andika Prayoga<sup>3</sup>, Zafnia Febby<sup>4</sup>, Clara Chyntia Haris Putri Lubis<sup>5</sup>

<sup>12345</sup>Fakultas Ekonomi dan Bisnis, Universitas Dharmawangsa

<sup>1</sup>email: [budiantoro@dharmawangsa.ac.id](mailto:budiantoro@dharmawangsa.ac.id)

<sup>2</sup>email: [nurhayati37488@gmail.com](mailto:nurhayati37488@gmail.com)

<sup>3</sup>email: [prayogaandika823@gmail.com](mailto:prayogaandika823@gmail.com)

<sup>4</sup>email: [zafniaf@gmail.com](mailto:zafniaf@gmail.com)

<sup>5</sup>email: [clarachyn23@gmail.com](mailto:clarachyn23@gmail.com)

### ABSTRACT

*This study aims to compare the performance of Artificial Neural Networks (ANN) and Naïve methods in forecasting monthly household electricity consumption. The dataset consists of monthly time series data from January 2020 to December 2024, comprising 60 observations. The ANN model is developed using a Multi-Layer Perceptron with lag-based features up to 12 months, while the benchmark methods include Naïve-1 and Seasonal Naïve-12. Model evaluation is conducted using both conventional test set and multi-horizon walk-forward validation (1, 3, 6, and 12 months), with MAE, RMSE, MAPE, and  $R^2$  as performance metrics. The results on the test set indicate that ANN outperforms the baseline methods, achieving MAE of 2.30 kWh, RMSE of 2.64 kWh, MAPE of 0.43%, and  $R^2$  of 0.9838. However, under walk-forward validation, the Seasonal Naïve-12 method consistently demonstrates superior performance across all forecasting horizons, particularly in long-term predictions. These findings suggest that although ANN performs well in short-term forecasting, simple seasonal-based methods remain more robust for multi-step forecasting in strongly seasonal data. This study highlights the importance of robust evaluation frameworks and baseline comparisons in time series forecasting research.*

**Keywords:** *Electricity Forecasting, Artificial Neural Network, Seasonal Naïve, Walk-Forward Validation, Time Series*

### ABSTRAK

Penelitian ini bertujuan untuk membandingkan kinerja Jaringan Saraf Tiruan (Artificial Neural Network/ANN) dan metode Naïve dalam peramalan konsumsi listrik bulanan rumah tangga. Data yang digunakan merupakan deret waktu bulanan periode Januari 2020 hingga Desember 2024 sebanyak 60 observasi. Model ANN dibangun menggunakan pendekatan Multi-Layer Perceptron dengan fitur berbasis lag hingga 12 bulan, sedangkan metode pembandingan meliputi Naïve-1 dan Seasonal Naïve-12. Evaluasi dilakukan menggunakan dua pendekatan, yaitu test set konvensional dan walk-forward validation multi-horizon (1, 3, 6, dan 12 bulan), dengan metrik MAE, RMSE, MAPE, dan  $R^2$ . Hasil pengujian pada test set menunjukkan bahwa ANN memiliki performa terbaik dengan MAE 2,30 kWh, RMSE 2,64 kWh, MAPE 0,43%, dan  $R^2$  sebesar 0,9838, mengungguli kedua metode baseline. Namun, pada evaluasi walk-forward validation, Seasonal Naïve-12 secara konsisten memberikan performa terbaik pada seluruh horizon, dengan error yang lebih rendah dibandingkan ANN, terutama pada horizon panjang. Temuan ini menunjukkan bahwa meskipun ANN efektif dalam prediksi jangka pendek, metode sederhana berbasis musiman tetap lebih robust untuk peramalan multi-step pada data dengan pola musiman yang kuat. Penelitian ini menegaskan

pentingnya penggunaan baseline sederhana dan metode evaluasi yang lebih realistis dalam studi peramalan deret waktu.

**Kata Kunci:** *Peramalan Listrik, Jaringan Saraf Tiruan, Seasonal Naïve, Walk-Forward Validation, Time Series*

## I. PENDAHULUAN

Konsumsi energi listrik rumah tangga merupakan salah satu komponen penting dalam sistem permintaan energi, karena merepresentasikan kebutuhan riil masyarakat pada tingkat pengguna akhir. Ketepatan dalam memprediksi konsumsi listrik rumah tangga menjadi penting tidak hanya untuk kebutuhan perencanaan beban dan efisiensi energi, tetapi juga untuk membantu pengambilan keputusan pada tingkat operasional rumah tangga, termasuk pengendalian konsumsi dan estimasi biaya listrik. Dalam konteks ini, peramalan konsumsi listrik berbasis data historis menjadi salah satu pendekatan yang banyak digunakan dalam penelitian maupun praktik manajemen energi (Nti et al., 2020).

Perkembangan metode peramalan konsumsi listrik menunjukkan pergeseran dari pendekatan statistik klasik menuju pendekatan machine learning dan deep learning. Tinjauan sistematis tentang electricity load forecasting menunjukkan bahwa model berbasis machine learning, termasuk artificial neural networks, semakin banyak digunakan karena kemampuannya dalam menangkap pola nonlinier dan kompleksitas data beban listrik. Dalam konteks konsumsi listrik, jaringan saraf tiruan menjadi salah satu metode yang sering dikaji karena fleksibilitasnya dalam memodelkan hubungan temporal yang tidak selalu dapat ditangkap dengan baik oleh model linear tradisional (Ahmad et al., 2022).

Pada level rumah tangga, penggunaan jaringan saraf tiruan untuk peramalan konsumsi listrik telah dilaporkan dalam berbagai studi. Penelitian oleh Marvuglia dan Messineo mengkaji penggunaan recurrent artificial neural networks untuk memprediksi konsumsi listrik rumah tangga, sedangkan Rodrigues, Cardeira, dan Calado menunjukkan penerapan ANN untuk peramalan konsumsi energi pada data rumah tangga harian dan per jam. Selain itu, Berriel dkk. juga meneliti peramalan konsumsi energi bulanan menggunakan pendekatan deep learning, yang menegaskan bahwa model jaringan saraf dapat diterapkan pada horizon temporal yang lebih panjang, termasuk data bulanan (Berriel et al., 2017; Marvuglia & Messineo, 2012; Rodrigues et al., 2014).

Meskipun demikian, penggunaan model yang lebih kompleks tidak selalu menjamin keunggulan dibandingkan metode baseline yang lebih sederhana. Dalam literatur peramalan energi, metode naïve, khususnya seasonal naïve, sering digunakan sebagai benchmark penting karena mampu merepresentasikan pola dasar musiman dengan sangat baik. Kajian mengenai metode peramalan konsumsi listrik bulanan juga menunjukkan bahwa seasonal naïve tetap relevan sebagai titik pembanding yang kuat, terutama pada data yang memiliki pola musiman yang stabil. Sejumlah studi komparatif pada peramalan beban listrik bangunan dan konsumsi energi juga tetap menempatkan model naïve musiman sebagai benchmark utama dalam mengevaluasi model machine learning (Groß et al., 2021; Krstev et al., 2023).

Selain persoalan pemilihan model, isu penting lain dalam penelitian peramalan adalah metode evaluasi. Banyak studi masih mengandalkan pemisahan train-test konvensional, padahal untuk data deret waktu pendekatan evaluasi seperti itu belum tentu merepresentasikan kondisi prediksi aktual di lapangan. Dalam konteks time series forecasting, pendekatan walk-forward validation dipandang lebih sesuai karena mempertahankan urutan temporal data dan mengevaluasi model secara bertahap seiring bertambahnya data historis. Studi mengenai multilayer perceptron berbasis walk-forward validation pada data electric load menunjukkan bahwa pendekatan ini relevan

untuk pemilihan dan pengujian model jaringan saraf pada deret waktu Listrik (Kouassi & Moodley, 2020).

Berdasarkan kondisi tersebut, penelitian ini memfokuskan diri pada perbandingan performa Jaringan Saraf Tiruan dan Naïve Approach dalam peramalan konsumsi listrik bulanan rumah tangga. Penelitian ini tidak hanya mengevaluasi model pada skema test set konvensional, tetapi juga menggunakan walk-forward validation multi-horizon agar diperoleh gambaran performa yang lebih realistis pada peramalan jangka pendek hingga menengah. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi metodologis dalam pemilihan model peramalan konsumsi listrik rumah tangga yang tidak hanya akurat pada pengujian statis, tetapi juga robust pada skenario prediksi berulang ke depan.

Secara khusus, penelitian ini bertujuan untuk: (1) membangun model peramalan konsumsi listrik bulanan rumah tangga menggunakan jaringan saraf tiruan, (2) membandingkan performanya dengan metode naïve dan seasonal naïve, serta (3) mengevaluasi konsistensi performa kedua pendekatan tersebut melalui walk-forward validation pada beberapa horizon prediksi. Dengan pendekatan ini, penelitian berupaya memberikan bukti empiris mengenai apakah model yang lebih kompleks benar-benar memberikan keunggulan dibandingkan baseline sederhana pada data konsumsi listrik rumah tangga bulanan.

## **Tinjauan Pustaka**

### **Peramalan Konsumsi Listrik**

Peramalan konsumsi listrik merupakan bagian penting dari manajemen energi karena berkaitan langsung dengan perencanaan kapasitas, efisiensi operasional, pengendalian beban, dan pengambilan keputusan ekonomi. Literatur menunjukkan bahwa peramalan beban listrik telah berkembang menjadi area riset yang sangat luas, mencakup horizon jangka pendek, menengah, hingga panjang, serta berbagai pendekatan metodologis mulai dari model statistik, machine learning, hingga deep learning. Kajian sistematis dan survei mutakhir menegaskan bahwa tidak ada satu model yang unggul secara universal; performa sangat dipengaruhi oleh karakteristik data, horizon prediksi, granularitas waktu, dan metode evaluasi yang digunakan (Ahmad et al., 2022; Nti et al., 2020).

Dalam konteks data rumah tangga, peramalan menjadi lebih menantang karena pola konsumsi cenderung dipengaruhi oleh kebiasaan penghuni, aktivitas harian, faktor cuaca, dan musiman. Pada level individual household, data sering menunjukkan fluktuasi yang lebih tinggi dibandingkan data agregat, tetapi tetap dapat mengandung pola periodik tertentu yang dapat dimanfaatkan oleh model prediksi. Karena itu, pemilihan pendekatan peramalan harus mempertimbangkan sifat data rumah tangga yang spesifik, termasuk keberadaan tren dan seasonality (Gajowniczek & Zabkowski, 2017).

### **Jaringan Saraf Tiruan dalam Peramalan Energi**

Jaringan saraf tiruan merupakan salah satu pendekatan yang paling banyak digunakan dalam peramalan energi karena kemampuannya untuk memodelkan pola nonlinier dan hubungan kompleks antarvariabel. Penggunaan recurrent artificial neural networks untuk memprediksi konsumsi listrik rumah tangga telah dilaporkan oleh Marvuglia dan Messineo, yang menunjukkan bahwa ANN dapat digunakan untuk menangkap pola konsumsi rumah tangga berdasarkan data historis. Studi lain oleh Rodrigues dkk. juga menunjukkan penggunaan artificial neural networks untuk memprediksi konsumsi energi harian dan per jam pada sekumpulan rumah tangga di Portugal, yang memperkuat posisi ANN sebagai metode yang relevan dalam domain load forecasting (Marvuglia & Messineo, 2012; Rodrigues et al., 2014).

Untuk horizon bulanan, pendekatan deep learning juga telah digunakan. Berriel dkk. meneliti monthly energy consumption forecast menggunakan deep learning, yang menunjukkan bahwa model berbasis jaringan saraf dapat diterapkan tidak hanya pada data berfrekuensi tinggi, tetapi juga pada data bulanan. Dengan demikian, ANN dan turunannya memiliki potensi sebagai metode peramalan konsumsi energi bulanan, termasuk pada skala rumah tangga (Berriel et al., 2017). Meski banyak penelitian menyoroti keunggulan ANN, literatur juga menunjukkan bahwa performa model kompleks sering bergantung pada jumlah data, struktur musiman, strategi pelatihan, dan desain evaluasi. Oleh karena itu, ANN perlu diuji terhadap baseline yang kuat agar peningkatan performa yang dihasilkan benar-benar memiliki makna empiris.

### **Naïve Approach sebagai Baseline**

Dalam penelitian time series forecasting, metode naïve digunakan sebagai baseline karena sederhana, transparan, dan mudah diinterpretasikan. Untuk data yang memiliki pola musiman, seasonal naïve sering menjadi benchmark yang sangat kuat. Tinjauan mengenai metode peramalan konsumsi listrik bulanan menunjukkan bahwa seasonal naïve tetap digunakan sebagai pendekatan acuan dalam evaluasi forecasting bulanan. Selain itu, studi komparatif pada peramalan beban listrik bangunan juga menempatkan naïve seasonal model sebagai benchmark terhadap berbagai metode machine learning (Groß et al., 2021; Krstev et al., 2023).

Penggunaan benchmark yang kuat menjadi penting agar model kompleks tidak dinilai hanya berdasarkan akurasi absolut, tetapi juga berdasarkan kemampuannya mengungguli metode sederhana yang sudah cukup representatif. Dalam praktiknya, jika pola musiman data sangat stabil, seasonal naïve dapat memberikan hasil yang sulit dikalahkan, sehingga menjadi pembanding yang relevan dan ketat dalam studi peramalan energi.

### **Walk-Forward Validation dalam Time Series Forecasting**

Evaluasi model pada data deret waktu memerlukan prosedur yang mempertahankan struktur temporal data. Berbeda dengan random split atau cross-validation konvensional, **walk-forward validation** melatih model pada data historis hingga suatu titik origin, lalu mengujinya pada periode setelah origin tersebut. Proses ini kemudian diulang secara bertahap seiring bertambahnya data training. Pendekatan ini banyak direkomendasikan dalam studi time series karena lebih realistis dalam merepresentasikan proses prediksi aktual.

Dalam konteks pemodelan multilayer perceptron untuk electric load time series, pendekatan walk-forward juga telah digunakan sebagai dasar grid search dan validasi performa model. Relevansi metode ini semakin penting ketika penelitian membandingkan model kompleks dengan baseline sederhana pada horizon multi-step, karena evaluasi statis pada satu test set sering belum cukup untuk menggambarkan robustness model dalam praktik peramalan.

### **Penelitian Terdahulu**

Beberapa penelitian terdahulu yang relevan dapat diringkas sebagai berikut. Marvuglia dan Messineo menggunakan recurrent artificial neural networks untuk peramalan konsumsi listrik rumah tangga. Rodrigues dkk. menerapkan ANN pada data 93 rumah tangga di Portugal untuk prediksi energi harian dan per jam. Berriel dkk. mengkaji peramalan konsumsi energi bulanan menggunakan deep learning. Gajowniczek dan Ząbkowski mengeksplorasi forecasting listrik pada level rumah tangga individual dengan mempertimbangkan pola aktivitas. Sementara itu, studi-studi review dan komparatif lain menekankan pentingnya benchmark, termasuk seasonal naïve, dalam evaluasi model load forecasting.

Secara umum, penelitian terdahulu menunjukkan tiga kecenderungan utama. Pertama, ANN dan deep learning banyak digunakan karena fleksibilitasnya dalam memodelkan pola konsumsi energi. Kedua, penelitian sering berfokus pada data berfrekuensi tinggi seperti harian atau per jam, meskipun ada juga studi pada data bulanan. Ketiga, benchmark sederhana seperti seasonal naïve tetap penting, tetapi tidak selalu menjadi fokus utama pembahasan, khususnya pada studi yang lebih menekankan eksplorasi model kompleks.

### **Gap Penelitian**

Berdasarkan telaah pustaka, terdapat beberapa gap penelitian yang menjadi dasar dilakukannya studi ini.

Pertama, masih terdapat kebutuhan akan studi yang secara spesifik membandingkan Jaringan Saraf Tiruan dan Naïve Approach pada data konsumsi listrik bulanan rumah tangga. Sebagian penelitian terdahulu meneliti konsumsi listrik rumah tangga dengan ANN, tetapi banyak yang berfokus pada horizon harian atau per jam, atau pada data agregat yang berbeda karakteristiknya dengan data bulanan rumah tangga.

Kedua, belum semua penelitian menempatkan seasonal naïve sebagai benchmark sentral yang diuji secara serius pada horizon multi-step. Padahal, literatur menunjukkan bahwa baseline musiman dapat menjadi pembanding yang sangat kuat, khususnya pada data bulanan yang memiliki pola seasonality yang stabil. Oleh sebab itu, ada kebutuhan untuk menilai apakah model kompleks benar-benar mampu melampaui baseline sederhana dalam kondisi evaluasi yang ketat.

Ketiga, dari sisi metodologi evaluasi, masih diperlukan penelitian yang tidak hanya bergantung pada train-test split konvensional, tetapi juga menggunakan walk-forward validation untuk menguji robustness model pada skenario peramalan multi-step. Literatur menunjukkan bahwa walk-forward validation lebih sesuai untuk time series forecasting, namun penerapannya secara eksplisit dalam komparasi ANN versus naïve pada data konsumsi listrik bulanan rumah tangga masih relatif terbatas.

Berdasarkan gap tersebut, penelitian ini menempatkan kontribusinya pada tiga hal: (1) pengujian ANN pada data konsumsi listrik bulanan rumah tangga, (2) komparasi langsung dengan Naïve-1 dan Seasonal Naïve-12, serta (3) evaluasi menggunakan walk-forward validation multi-horizon untuk memperoleh gambaran performa model yang lebih realistis dan metodologis kuat.

## **II. METODE PENELITIAN**

### **Desain Penelitian**

Penelitian ini menggunakan pendekatan kuantitatif dengan desain studi komparatif peramalan deret waktu (time series forecasting). Fokus penelitian adalah membandingkan performa Jaringan Saraf Tiruan (Artificial Neural Network/ANN) dengan Naïve Approach dalam memprediksi konsumsi listrik bulanan rumah tangga. Evaluasi dilakukan melalui dua skema, yaitu pengujian pada test set konvensional dan walk-forward validation untuk mensimulasikan kondisi peramalan multi-step yang lebih realistis. Dataset yang digunakan berupa data konsumsi listrik rumah tangga bulanan selama periode Januari 2020 sampai Desember 2024, sehingga total terdapat 60 observasi bulanan. Setiap observasi terdiri atas dua atribut, yaitu: Bulan, yang menunjukkan periode pengamatan dalam format tahun-bulan. Konsumsi (kWh), yang menunjukkan jumlah penggunaan energi listrik rumah tangga pada bulan terkait. Karena data disusun secara berkala berdasarkan waktu, maka dataset dikategorikan sebagai univariate time series, dengan variabel target tunggal berupa konsumsi listrik bulanan dalam satuan kilowatt-hour (kWh). Secara umum, tahapan awal pengolahan data meliputi: konversi atribut waktu ke format tanggal bulanan, penetapan variabel waktu sebagai indeks deret, pengurutan data secara kronologis, dan pemeriksaan struktur data agar siap digunakan dalam pemodelan peramalan.

### Pra-pemrosesan Data

Sebelum dilakukan pemodelan, data deret waktu diubah terlebih dahulu ke dalam bentuk supervised learning agar dapat diproses oleh model jaringan saraf tiruan. Transformasi ini dilakukan melalui pembentukan fitur-fitur berbasis waktu dan nilai historis (*lag features*). Fitur yang digunakan dalam pemodelan meliputi: month, yaitu nomor bulan (1–12), year\_progress, yaitu indeks progres waktu bulanan sejak awal observasi, lag\_1 sampai lag\_12, yaitu konsumsi listrik pada 1 sampai 12 bulan sebelumnya. Dengan demikian, total fitur input yang digunakan adalah 14 fitur, yaitu: 1 fitur bulan, 1 fitur progres waktu, 12 fitur lag historis. Penggunaan 12 lag dimaksudkan untuk menangkap pola musiman tahunan yang terdapat pada data konsumsi listrik bulanan. Karena pembentukan lag 12 bulan menyebabkan 12 observasi pertama tidak memiliki nilai lengkap, maka observasi tersebut dihapus dari data supervised. Dengan demikian, jumlah data yang dapat digunakan untuk pemodelan menjadi 48 sampel supervised.

### Normalisasi Data

Untuk meningkatkan stabilitas proses pelatihan model jaringan saraf tiruan, dilakukan normalisasi data menggunakan MinMaxScaler. Normalisasi diterapkan secara terpisah pada: matriks fitur input (X), dan variabel target (y). Transformasi Min-Max digunakan untuk memetakan nilai data ke rentang ([0,1]). Setelah proses prediksi selesai, hasil keluaran model dikembalikan ke skala asli menggunakan proses inverse transformation.

### Arsitektur Jaringan Saraf Tiruan

Model ANN yang digunakan dalam penelitian ini adalah *Multi-Layer Perceptron* (MLP), yaitu salah satu bentuk jaringan saraf tiruan feed-forward yang umum digunakan untuk regresi nonlinier. Arsitektur model terdiri atas: Lapisan input: 14 neuron, sesuai jumlah fitur input, Hidden layer 1: 128 neuron, Hidden layer 2: 64 neuron, Hidden layer 3: 32 neuron, Lapisan output: 1 neuron untuk memprediksi nilai konsumsi listrik bulan berikutnya. Fungsi aktivasi yang digunakan pada hidden layer adalah ReLU (*Rectified Linear Unit*). Lapisan output menggunakan konfigurasi regresi standar untuk menghasilkan keluaran numerik kontinu. Secara skematis, arsitektur model dapat dituliskan sebagai berikut:

$$14 \rightarrow 128 \rightarrow 64 \rightarrow 32 \rightarrow 1$$

Pemilihan struktur multilayer ini bertujuan untuk memungkinkan model mempelajari pola nonlinier dari data historis konsumsi listrik.

### Parameter Training Model Neural Network

Pelatihan model dilakukan menggunakan implementasi MLPRegressor dari pustaka *scikit-learn*. Parameter utama yang digunakan adalah sebagai berikut: hidden\_layer\_sizes = (128, 64, 32), activation = 'relu', solver = 'adam', max\_iter = 1000 pada pemodelan utama, dan hingga 1500 pada skenario walk-forward, learning\_rate\_init = 0.001, early\_stopping = True pada pemodelan utama, validation\_fraction = 0.2, n\_iter\_no\_change = 50, random\_state = 42. Pada pemodelan utama, proses training berhenti pada 277 iterasi, sesuai mekanisme early stopping yang menghindari pelatihan berlebih (overfitting).

Untuk evaluasi awal model jaringan saraf tiruan, dataset supervised sebanyak 48 sampel dibagi menjadi: 80% data pelatihan, dan 20% data pengujian. Dengan pembagian tersebut, diperoleh: 38 sampel training, dan 10 sampel testing. Evaluasi ini digunakan untuk mengukur kemampuan model

dalam melakukan prediksi pada data yang tidak digunakan saat pelatihan, tetapi masih dalam kerangka pengujian konvensional.

### **Metode Naïve sebagai Baseline**

Sebagai pembandingan, penelitian ini menggunakan dua metode baseline sederhana, yaitu:

#### **Naïve-1**

Metode ini memprediksi nilai periode saat ini berdasarkan nilai aktual pada satu periode sebelumnya, yang dirumuskan sebagai:  $y_t = y_{t-1}$ . Pada data bulanan, pendekatan ini berarti bahwa konsumsi listrik bulan ini diperkirakan sama dengan konsumsi bulan sebelumnya.

#### **Seasonal Naïve-12**

Metode ini memprediksi nilai suatu bulan berdasarkan nilai aktual pada bulan yang sama tahun sebelumnya, yang dirumuskan sebagai:  $y_t = y_{t-12}$ . Karena data yang digunakan bersifat bulanan dan memiliki indikasi musiman tahunan, maka Seasonal Naïve-12 dipilih sebagai baseline musiman yang relevan.

### **Prosedur Peramalan**

#### **Peramalan dengan Neural Network**

Setelah model ANN dilatih, prediksi dilakukan secara *one-step ahead* pada test set konvensional, dan *iteratif multi-step* untuk peramalan jangka lebih panjang, termasuk target Mei 2026. Pada peramalan iteratif, hasil prediksi bulan sebelumnya digunakan kembali sebagai bagian dari fitur lag untuk memprediksi bulan berikutnya. Dengan mekanisme ini, model dapat menghasilkan urutan prediksi berantai untuk beberapa bulan ke depan. Peramalan konsumsi listrik hingga Mei 2026 dilakukan mulai dari data historis terakhir pada Desember 2024, kemudian diproyeksikan secara bulanan sampai mencapai horizon 17 bulan ke depan.

#### **Prosedur Walk-Forward Validation**

Untuk memperoleh evaluasi yang lebih kuat pada skenario peramalan multi-step, digunakan metode walk-forward validation dengan expanding window. Pada pendekatan ini, model tidak hanya diuji sekali, tetapi dilatih ulang secara bertahap pada banyak titik origin. Untuk setiap origin, model dilatih menggunakan seluruh data yang tersedia hingga titik tersebut, lalu digunakan untuk memprediksi beberapa langkah ke depan. Pendekatan ini lebih representatif terhadap situasi riil, karena mencerminkan bagaimana model akan digunakan pada kondisi operasional saat data baru tersedia secara bertahap. Walk-forward validation dilakukan dengan: Origin: dari Desember 2021 sampai Desember 2023, Total origin: 25 titik origin, Horizon prediksi yang diuji 1 bulan, 3 bulan, 6 bulan dan 12 bulan.

#### **Langkah-Langkah Walk-Forward**

Untuk setiap origin, dilakukan prosedur sebagai berikut:

1. Mengambil seluruh data historis sampai periode origin sebagai data training.
2. Membentuk dataset supervised berbasis 12 lag.
3. Melatih model ANN pada data training tersebut.
4. Melakukan prediksi iteratif untuk horizon 1, 3, 6, dan 12 bulan ke depan.

5. Menghasilkan prediksi baseline menggunakan Naïve-1 dan Seasonal Naïve-12 untuk horizon yang sama.
6. Membandingkan hasil prediksi dengan data aktual pada horizon tersebut.
7. Menghitung metrik error untuk setiap model dan setiap horizon.
8. Mengulangi prosedur untuk seluruh origin, kemudian merata-ratakan hasilnya.

**Metrik Evaluasi**

Kinerja model dievaluasi menggunakan tiga metrik error utama dan satu koefisien determinasi.

**Mean Absolute Error (MAE)**

MAE mengukur rata-rata selisih absolut antara nilai aktual dan nilai prediksi:

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

**Root Mean Squared Error (RMSE)**

RMSE mengukur akar dari rata-rata kuadrat error:

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

**Mean Absolute Percentage Error (MAPE)**

MAPE mengukur rata-rata persentase error absolut:

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

**Koefisien Determinasi (R<sup>2</sup>)**

R<sup>2</sup> digunakan untuk mengevaluasi seberapa besar variasi data aktual dapat dijelaskan oleh model:

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

Pada evaluasi walk-forward, fokus utama perbandingan digunakan pada MAE, RMSE, dan MAPE, karena ketiganya lebih relevan untuk membandingkan performa multi-step forecasting antar metode.

**III. HASIL DAN PEMBAHASAN**

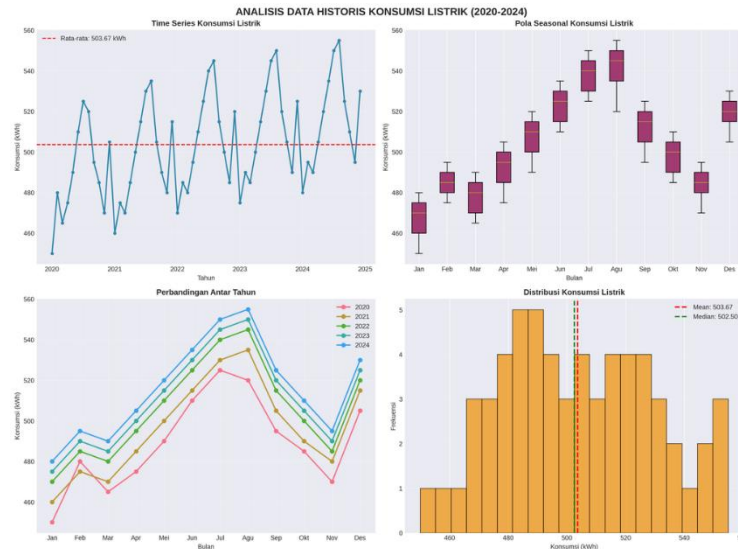
**Hasil**

**Karakteristik Data Konsumsi Listrik Bulanan**

Penelitian ini menggunakan data konsumsi listrik rumah tangga bagian Sumatera Utara bulanan selama periode Januari 2020 sampai Desember 2024 dengan total 60 data pengamatan. Berdasarkan statistik deskriptif, rata-rata konsumsi listrik selama periode pengamatan adalah 503,67 kWh, dengan nilai minimum sebesar 450,00 kWh yang terjadi pada Januari 2020, dan nilai maksimum sebesar 555,00 kWh yang terjadi pada Agustus 2024. Standar deviasi data sebesar 24,92 kWh, yang menunjukkan adanya variasi konsumsi listrik antarbulan dalam rentang yang cukup jelas.

Secara tahunan, rerata konsumsi listrik menunjukkan kecenderungan meningkat. Nilai rata-rata konsumsi listrik per tahun berturut-turut adalah 489,17 kWh pada tahun 2020, 496,67 kWh pada tahun 2021, 505,83 kWh pada tahun 2022, 510,83 kWh pada tahun 2023, dan 515,83 kWh pada

tahun 2024. Pola ini menunjukkan adanya tren kenaikan konsumsi listrik dari tahun ke tahun. Selain itu, pola musiman juga tampak cukup kuat, dengan konsumsi yang cenderung lebih tinggi pada pertengahan tahun, khususnya pada bulan Juli–Agustus, dan relatif lebih rendah pada awal tahun. Visualisasi pola historis ditunjukkan pada Gambar 1.



**Gambar 1. Analisis data historis konsumsi listrik bulanan 2020–2024**

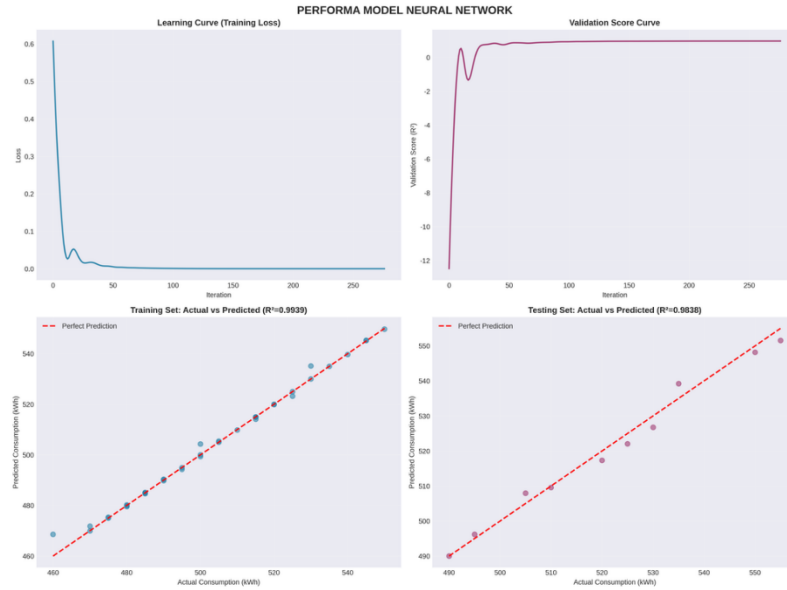
**Hasil Pemodelan Jaringan Saraf Tiruan**

Pemodelan peramalan dilakukan menggunakan Jaringan Saraf Tiruan tipe Multi-Layer Perceptron (MLP). Arsitektur model terdiri atas 14 neuron pada lapisan input yang merepresentasikan fitur waktu dan 12 lag konsumsi sebelumnya, kemudian diikuti oleh tiga hidden layer dengan jumlah neuron berturut-turut 128, 64, dan 32, serta satu neuron pada lapisan output untuk menghasilkan nilai prediksi. Model dilatih menggunakan optimizer Adam dan berhenti pada 277 iterasi. Jumlah sampel simulasi yang digunakan adalah 38, sedangkan sampel pengujian berjumlah 10. Kinerja model pada data simulasi menunjukkan hasil yang sangat baik. Hal ini dapat dilihat dari table berikut ini.


**Table 1. Performa Model**

Metrik	Training Set	Testing Set
MAE	0.75 kWh	2.30 kWh
RMSE	1.84 kWh	2.64 kWh
MAPE	-	0.43%
R <sup>2</sup> Score	99.39%	98.38%

Berdasarkan table diatas, diperoleh nilai MAE pada data simulasi adalah 0,75 kWh, RMSE sebesar 1,84 kWh, dan R<sup>2</sup> sebesar 0,9939. Pada data pengujian, model juga menunjukkan performa yang tinggi dengan MAE 2,30 kWh, RMSE 2,64 kWh, MAPE 0,43%, dan R<sup>2</sup> 0,9838. Hasil ini menunjukkan bahwa model jaringan saraf tiruan mampu mempelajari pola data historis dengan sangat baik serta menghasilkan kesalahan prediksi yang relatif kecil pada data pengujian. Kurva pembelajaran model dan hubungan antara nilai aktual dan nilai prediksi ditampilkan pada Gambar 2, sedangkan hasil validasi pada data uji ditampilkan pada Gambar 3.



**Gambar 2. Performa model jaringan saraf tiruan**



**Gambar 3. Validasi model pada data uji**

**Hasil Peramalan Konsumsi Listrik Hingga Mei 2026**

Berdasarkan model jaringan saraf tiruan yang telah dibangun, dilakukan peramalan konsumsi listrik mulai Januari 2025 hingga Mei 2026. Berikut ini diberikan table hasil peramalan dengan model jaringan saraf yang telah dibangun sebelumnya.

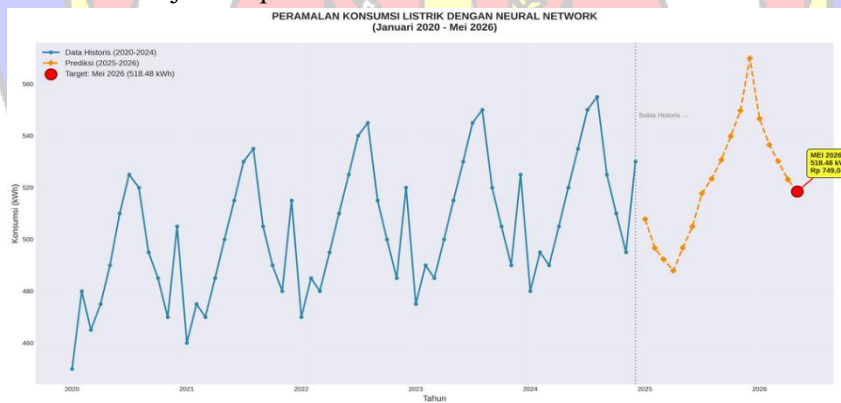
**Table 2. Hasil Peramalan Lengkap (2025-2026)**

Bulan	Prediksi (kWh)	Estimasi Biaya
Januari 2025	507.76	Rp 733,574
Februari 2025	496.63	Rp 717,491
Maret 2025	492.32	Rp 711,260
April 2025	487.82	Rp 704,764
Mei 2025	496.68	Rp 717,563
Juni 2025	504.96	Rp 729,519
Juli 2025	517.69	Rp 747,896
Agustus 2025	523.30	Rp 755,999
September 2025	530.68	Rp 766,661
Oktober 2025	539.81	Rp 779,844
November 2025	549.70	Rp 794,143
Desember 2025	569.86	Rp 823,281
Januari 2026	546.57	Rp 789,546


<b>Februari 2026</b>	536.51	Rp 775,019
<b>Maret 2026</b>	530.12	Rp 765,794
<b>April 2026</b>	523.14	Rp 755,704
<b>MEI 2026</b>	<b>518.48</b>	<b>Rp 749,045</b>

Hasil prediksi menunjukkan nilai konsumsi listrik bulanan sebagai berikut: 507,762878 kWh pada Januari 2025, 496,634881 kWh pada Februari 2025, 492,315902 kWh pada Maret 2025, 487,822544 kWh pada April 2025, 496,682877 kWh pada Mei 2025, 504,961877 kWh pada Juni 2025, 517,691274 kWh pada Juli 2025, 523,296671 kWh pada Agustus 2025, 530,684435 kWh pada September 2025, 539,806942 kWh pada Oktober 2025, 549,698757 kWh pada November 2025, 569,856985 kWh pada Desember 2025, 546,567384 kWh pada Januari 2026, 536,510559 kWh pada Februari 2026, 530,118143 kWh pada Maret 2026, 523,144913 kWh pada April 2026, dan 518,478054 kWh pada Mei 2026.

Dengan demikian, nilai prediksi konsumsi listrik untuk Mei 2026 adalah 518,48 kWh. Jika menggunakan asumsi tarif listrik sebesar Rp1.444,70 per kWh untuk golongan non-subsidi (R-1/TR) daya 1.300VA – 2.200VA, maka estimasi pembayaran listrik pada bulan tersebut adalah sebesar Rp749.045,24. Namun, jika menggunakan asumsi tarif listrik sebesar Rp1.699,53 per kWh untuk daya diatas 3.500VA, maka estimasi pembayaran listrik pada bulan tersebut adalah sebesar Rp865.617,914. Dibandingkan dengan konsumsi listrik pada bulan Mei pada tahun-tahun sebelumnya, yaitu 490,00 kWh pada 2020, 500,00 kWh pada 2021, 510,00 kWh pada 2022, 515,00 kWh pada 2023, dan 520,00 kWh pada 2024, maka prediksi konsumsi listrik pada Mei 2026 masih berada dalam pola historis yang sejenis. Secara numerik, prediksi Mei 2026 menunjukkan perubahan sebesar +2,26% terhadap rata-rata konsumsi listrik bulan Mei pada periode historis. Hasil peramalan keseluruhan divisualisasikan pada Gambar 4, sedangkan komparasi konsumsi listrik khusus bulan Mei tahun 2020–2026 ditunjukkan pada Gambar 5.



**Gambar 4. Hasil peramalan konsumsi listrik hingga Mei 2026**



**Gambar 5. Perbandingan konsumsi listrik bulan Mei tahun 2020–2026**

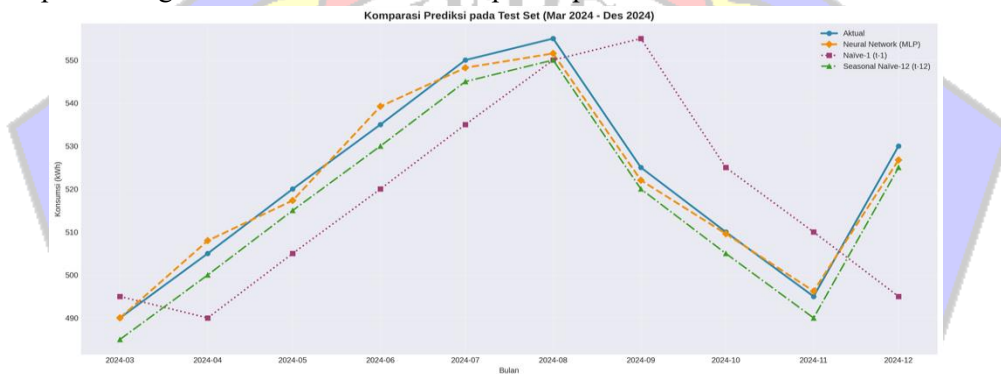
**Hasil Komparasi dengan Naïve Approach pada Test Set**

Untuk mengevaluasi apakah model jaringan saraf tiruan memberikan peningkatan performa dibandingkan metode sederhana, dilakukan komparasi dengan dua baseline, yaitu Naïve-1 dengan pendekatan  $y_t = y_{t-1}$ , serta Seasonal Naïve-12 dengan pendekatan  $y_t = y_{t-12}$ . Evaluasi dilakukan pada test set yang sama. Berikut ini diberikan table hasil uji komparasinya.

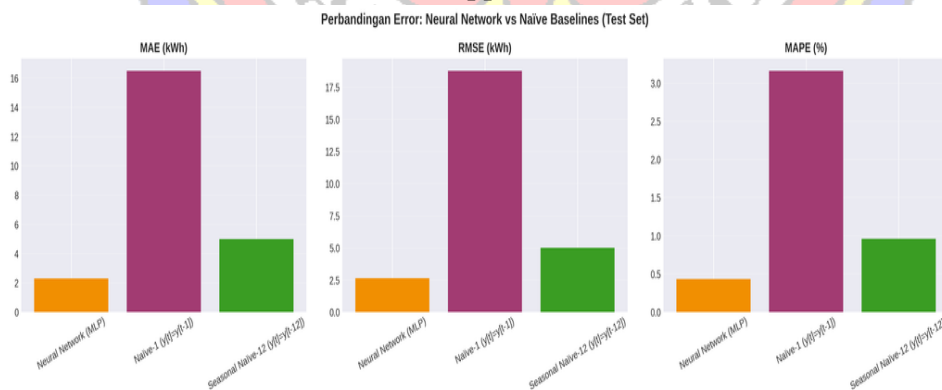
**Table 3. Hasil Akurasi (Test Set)**

Model	MAE (kWh)	RMSE (kWh)	MAPE (%)	R <sup>2</sup>
Neural Network (MLP)	2.2972	2.6440	0.4348	0.9838
Naïve-1 (t-1)	16.5000	18.7750	3.1597	0.1807
Seasonal Naïve-12 (t-12)	5.0000	5.0000	0.9603	0.9419

Hasil komparasi menunjukkan bahwa model jaringan saraf tiruan memperoleh MAE 2,2972 kWh, RMSE 2,6440 kWh, MAPE 0,4348%, dan R<sup>2</sup> 0,9838. Sementara itu, metode Naïve-1 menghasilkan MAE 16,5000 kWh, RMSE 18,7750 kWh, MAPE 3,1597%, dan R<sup>2</sup> 0,1807. Adapun metode Seasonal Naïve-12 menghasilkan MAE 5,0000 kWh, RMSE 5,0000 kWh, MAPE 0,9603%, dan R<sup>2</sup> 0,9419. Dengan demikian, pada evaluasi test set, model jaringan saraf tiruan memberikan hasil yang lebih baik dibandingkan kedua baseline naïve, baik dari sisi MAE, RMSE, MAPE, maupun koefisien determinasi. Komparasi prediksi pada test set ditunjukkan pada Gambar 6, sedangkan perbandingan error antarmetode ditampilkan pada Gambar 7.



**Gambar 6. Komparasi prediksi pada test set antara jaringan saraf tiruan dan naïve approach**



**Gambar 7. Perbandingan metrik error jaringan saraf tiruan dan naïve approach pada test set**

**Hasil Walk-Forward Validation**

Untuk memperoleh evaluasi yang lebih fair pada skenario peramalan multi-step, dilakukan walk-forward validation dengan horizon prediksi 1, 3, 6, dan 12 bulan, menggunakan origin dari 2021-12 sampai 2023-12 sebanyak 25 origin. Hasil ini memberikan gambaran yang lebih realistis mengenai performa model ketika digunakan untuk meramalkan beberapa langkah ke depan secara berulang.

**Table 4. Ringkasan Hasil Walk-Forward (Rata-Rata Dari Semua Origin)**


Horizon	Model	MAE (kWh)	RMSE (kWh)	MAPE (%)
1	Naïve-1 (konstan t-1)	19.8000	19.8000	3.9478
1	Neural Network (MLP)	18.6563	18.6563	3.7251
1	Seasonal Naïve-12	<b>7.0000</b>	<b>7.0000</b>	<b>1.3836</b>
3	Naïve-1 (konstan t-1)	24.6667	26.6372	4.8682
3	Neural Network (MLP)	23.3951	25.4215	4.6418
3	Seasonal Naïve-12	<b>6.8000</b>	<b>6.8293</b>	<b>1.3399</b>
6	Naïve-1 (konstan t-1)	27.9667	31.8551	5.4854
6	Neural Network (MLP)	27.9587	31.3525	5.5396
6	Seasonal Naïve-12	<b>6.5000</b>	<b>6.5646</b>	<b>1.2758</b>
12	Naïve-1 (konstan t-1)	25.5667	30.6764	4.9925
12	Neural Network (MLP)	33.9069	40.3955	6.7412
12	Seasonal Naïve-12	<b>5.9167</b>	<b>6.0450</b>	<b>1.1589</b>

Pada horizon 1 bulan, metode Naïve-1 menghasilkan MAE 19,8000, RMSE 19,8000, dan MAPE 3,9478%; model jaringan saraf tiruan menghasilkan MAE 18,6563, RMSE 18,6563, dan MAPE 3,7251%; sedangkan Seasonal Naïve-12 menghasilkan MAE 7,0000, RMSE 7,0000, dan MAPE 1,3836%. Pada horizon 3 bulan, metode Naïve-1 menghasilkan MAE 24,6667, RMSE 26,6372, dan MAPE 4,8682%; model jaringan saraf tiruan menghasilkan MAE 23,3951, RMSE 25,4215, dan MAPE 4,6418%; sedangkan Seasonal Naïve-12 menghasilkan MAE 6,8000, RMSE 6,8293, dan MAPE 1,3399%. Pada horizon 6 bulan, metode Naïve-1 menghasilkan MAE 27,9667, RMSE 31,8551, dan MAPE 5,4854%; model jaringan saraf tiruan menghasilkan MAE 27,9587, RMSE 31,3525, dan MAPE 5,5396%; sedangkan Seasonal Naïve-12 menghasilkan MAE 6,5000, RMSE 6,5646, dan MAPE 1,2758%. Pada horizon 12 bulan, metode Naïve-1 menghasilkan MAE 25,5667, RMSE 30,6764, dan MAPE 4,9925%; model jaringan saraf tiruan menghasilkan MAE 33,9069, RMSE 40,3955, dan MAPE 6,7412%; sedangkan Seasonal Naïve-12 menghasilkan MAE 5,9167, RMSE 6,0450, dan MAPE 1,1589%.

Hasil ini menunjukkan bahwa pada skenario walk-forward multi-step, metode Seasonal Naïve-12 justru memberikan performa terbaik secara konsisten pada seluruh horizon pengujian. Perubahan error terhadap horizon ditunjukkan pada Gambar 9, visualisasi perbandingan keunggulan jaringan saraf tiruan terhadap Seasonal Naïve ditunjukkan pada Gambar 10, dan salah satu contoh trajectory 12-step forecast pada origin terakhir ditampilkan pada Gambar 11.



Gambar 9. Walk-forward validation: perubahan error terhadap horizon prediksi



Gambar 10. Heatmap perbandingan performa jaringan saraf tiruan terhadap Seasonal Naive



Gambar 11. Contoh hasil 12-step forecast pada walk-forward validation

**Komparasi Prediksi Mei 2026 antar Metode**

Selain evaluasi historis, dilakukan pula komparasi nilai prediksi untuk target Mei 2026. Model jaringan saraf tiruan menghasilkan prediksi sebesar 518,48 kWh, metode Naive konstan = Desember 2024 menghasilkan prediksi sebesar 530,00 kWh, sedangkan metode Seasonal Naive = Mei 2024 menghasilkan prediksi sebesar 520,00 kWh. Dengan tarif listrik yang sama, estimasi biaya listrik untuk Mei 2026 masing-masing adalah Rp749.045 untuk model jaringan saraf tiruan, Rp765.691 untuk Naive konstan, dan Rp751.244 untuk Seasonal Naive. Nilai prediksi jaringan saraf

tiruan dan Seasonal Naïve berada sangat berdekatan, sedangkan Naïve konstan menghasilkan nilai yang lebih tinggi.

### Pembahasan

Hasil penelitian ini menunjukkan bahwa model jaringan saraf tiruan memiliki performa yang sangat baik ketika dievaluasi pada data pengujian konvensional. Hal ini tercermin dari nilai  $R^2$  sebesar 0,9838 dan MAPE sebesar 0,43%, yang menandakan bahwa model mampu menangkap pola data historis dengan tingkat kesalahan yang rendah. Secara langsung, temuan ini memperlihatkan bahwa pendekatan berbasis jaringan saraf tiruan efektif dalam mempelajari hubungan nonlinear dan pola temporal yang terdapat dalam data konsumsi listrik bulanan rumah tangga.

Namun demikian, hasil evaluasi menjadi lebih menarik ketika dibandingkan dengan metode baseline sederhana. Pada test set, model jaringan saraf tiruan memang mengungguli Naïve-1 dan juga Seasonal Naïve-12, sehingga secara awal dapat disimpulkan bahwa model kompleks lebih baik daripada metode sederhana. Akan tetapi, hasil ini tidak sepenuhnya bertahan ketika evaluasi dilakukan menggunakan walk-forward validation untuk skenario multi-step forecasting.

Pada pengujian walk-forward, Seasonal Naïve-12 justru menunjukkan performa yang paling stabil dan terbaik pada semua horizon, mulai dari 1 bulan hingga 12 bulan. Bahkan pada horizon 12 bulan, Seasonal Naïve-12 menghasilkan MAE 5,9167, jauh lebih kecil daripada jaringan saraf tiruan yang menghasilkan MAE 33,9069. Temuan ini menunjukkan bahwa meskipun jaringan saraf tiruan sangat baik pada prediksi jangka pendek dalam skema evaluasi tertentu, metode sederhana berbasis pola musiman tahunan tetap sangat kompetitif, bahkan lebih unggul, ketika digunakan untuk multi-step forecasting pada data yang memiliki pola musiman kuat dan relatif stabil.

Perbedaan hasil antara evaluasi test set dan walk-forward dapat dijelaskan oleh mekanisme prediksi yang digunakan. Pada evaluasi test set, model jaringan saraf tiruan melakukan prediksi dengan bantuan fitur lag yang masih berasal dari data aktual, sehingga akurasi yang diperoleh menjadi sangat tinggi. Sebaliknya, pada walk-forward multi-step forecasting, model harus melakukan prediksi secara iteratif, di mana hasil prediksi pada satu periode digunakan kembali sebagai input untuk periode berikutnya. Kondisi ini menyebabkan terjadinya *akumulasi error* dari satu langkah ke langkah berikutnya, yang pada akhirnya menurunkan akurasi model untuk horizon yang lebih panjang. Seasonal Naïve-12 tidak mengalami drift semacam ini karena secara langsung menyalin pola dari bulan yang sama pada tahun sebelumnya.

Dari perspektif ilmiah, hasil ini penting karena menunjukkan bahwa model yang lebih kompleks tidak selalu memberikan performa terbaik pada semua skenario. Pada data konsumsi listrik rumah tangga bulanan yang memiliki pola musiman yang kuat dan konsisten, baseline sederhana seperti Seasonal Naïve dapat menjadi pembanding yang sangat relevan dan tidak boleh diabaikan. Dengan kata lain, penggunaan model kompleks seperti jaringan saraf tiruan perlu selalu diuji terhadap baseline sederhana agar keunggulan model benar-benar dapat dibuktikan secara objektif.

Meskipun demikian, hasil prediksi target Mei 2026 menunjukkan bahwa nilai yang dihasilkan jaringan saraf tiruan (518,48 kWh) dan Seasonal Naïve (520,00 kWh) sangat dekat. Hal ini mengindikasikan bahwa pada kasus ini kedua pendekatan memberikan estimasi yang relatif sejalan untuk satu titik prediksi tertentu. Walaupun demikian, jika penilaian didasarkan pada konsistensi performa sepanjang horizon multi-step pada walk-forward validation, maka Seasonal Naïve-12 memiliki landasan empiris yang lebih kuat.

Temuan ini memberi implikasi metodologis yang penting bagi penelitian peramalan energi. Pertama, evaluasi model tidak cukup dilakukan hanya pada pembagian train-test sederhana, tetapi perlu mencakup evaluasi walk-forward agar performa model pada kondisi operasional yang lebih realistis dapat terlihat. Kedua, model baseline sederhana tetap memiliki nilai ilmiah yang tinggi dan dapat menjadi standar pembanding yang ketat. Ketiga, dalam konteks data bulanan dengan musiman

tahunan yang kuat, seasonal baseline dapat menjadi pilihan yang sangat efisien dan akurat, terutama untuk peramalan multi-step.

Secara keseluruhan, hasil penelitian ini memperlihatkan dua sisi yang saling melengkapi. Di satu sisi, jaringan saraf tiruan menunjukkan kemampuan prediktif yang sangat baik pada evaluasi test set dan menghasilkan prediksi Mei 2026 sebesar 518,48 kWh dengan estimasi biaya Rp749.045,24. Di sisi lain, pendekatan Seasonal Naïve-12 terbukti lebih unggul dalam evaluasi walk-forward multi-horizon, sehingga layak diposisikan sebagai baseline utama dalam studi peramalan konsumsi listrik bulanan rumah tangga.

#### IV. KESIMPULAN

Penelitian ini bertujuan untuk membandingkan kinerja Jaringan Saraf Tiruan dan metode Naïve dalam peramalan konsumsi listrik bulanan rumah tangga dengan pendekatan evaluasi yang lebih komprehensif. Berdasarkan hasil analisis, dapat disimpulkan beberapa hal utama. Pertama, model Jaringan Saraf Tiruan menunjukkan performa yang sangat baik pada evaluasi test set konvensional, dengan tingkat kesalahan yang rendah dan nilai koefisien determinasi yang tinggi. Hal ini menunjukkan bahwa model mampu menangkap pola historis data secara akurat, khususnya dalam skenario prediksi jangka pendek. Kedua, ketika dibandingkan dengan metode baseline, model ANN terbukti mengungguli Naïve-1 dan Seasonal Naïve-12 pada pengujian test set. Namun demikian, keunggulan ini tidak sepenuhnya konsisten ketika dilakukan evaluasi menggunakan walk-forward validation. Ketiga, pada skenario walk-forward validation multi-horizon, metode Seasonal Naïve-12 justru menunjukkan performa terbaik secara konsisten pada seluruh horizon prediksi. Hal ini mengindikasikan bahwa pada data dengan pola musiman yang kuat dan stabil, pendekatan sederhana berbasis seasonality dapat memberikan hasil yang lebih robust dibandingkan model kompleks, terutama untuk peramalan multi-step. Keempat, perbedaan hasil antara evaluasi test set dan walk-forward validation menegaskan bahwa metode evaluasi memiliki pengaruh signifikan terhadap interpretasi kinerja model. Evaluasi berbasis walk-forward lebih mampu merepresentasikan kondisi operasional nyata, sehingga memberikan gambaran performa model yang lebih reliabel. Secara keseluruhan, penelitian ini menegaskan bahwa model kompleks seperti Jaringan Saraf Tiruan tidak selalu unggul dalam semua kondisi. Oleh karena itu, penggunaan baseline sederhana seperti Seasonal Naïve tetap penting sebagai pembanding utama. Selain itu, penerapan metode evaluasi yang tepat menjadi kunci dalam menghasilkan kesimpulan yang valid dalam studi peramalan deret waktu.

#### V. REFERENSI

- Ahmad, N., Ghadi, Y., Adnan, M., & Ali, M. (2022). Load Forecasting Techniques for Power System: Research Challenges and Survey. *IEEE Access*, *10*, 71054–71090. <https://doi.org/10.1109/ACCESS.2022.3187839>
- Berriel, R. F., Lopes, A. T., Rodrigues, A., Varejao, F. M., & Oliveira-Santos, T. (2017). Monthly energy consumption forecast: A deep learning approach. *Proceedings of the International Joint Conference on Neural Networks*, 2017-May, 4283–4290. <https://doi.org/10.1109/IJCNN.2017.7966398>
- Gajowniczek, K., & Zabkowski, T. (2017). Electricity forecasting on the individual household level enhanced based on activity patterns. *PLOS ONE*, *12*(4), e0174098. <https://doi.org/10.1371/JOURNAL.PONE.0174098>
- Groß, A., Lenders, A., Schwenker, F., Braun, D. A., & Fischer, D. (2021). Comparison of short-term electrical load forecasting methods for different building types. *Energy Informatics 2021 4:3*, 4(3), 13-. <https://doi.org/10.1186/S42162-021-00172-6>

- Kouassi, K. H., & Moodley, D. (2020). An Analysis of Deep Neural Networks for Predicting Trends in Time Series Data. *Communications in Computer and Information Science*, 1342, 119–140. [https://doi.org/10.1007/978-3-030-66151-9\\_8/TABLES/13](https://doi.org/10.1007/978-3-030-66151-9_8/TABLES/13)
- Krstev, S., Forcan, J., & Krneta, D. (2023). An Overview of Forecasting Methods for Monthly Electricity Consumption. *Tehnički Vjesnik*, 30(3), 993–1001. <https://doi.org/10.17559/TV-20220430111309>
- Marvuglia, A., & Messineo, A. (2012). Using Recurrent Artificial Neural Networks to Forecast Household Electricity Consumption. *Energy Procedia*, 14, 45–55. <https://doi.org/10.1016/J.EGYPRO.2011.12.895>
- Nti, I. K., Teimeh, M., Nyarko-Boateng, O., & Adekoya, A. F. (2020). Electricity load forecasting: a systematic review. *Journal of Electrical Systems and Information Technology*, 7(1). <https://doi.org/10.1186/s43067-020-00021-8>
- Rodrigues, F., Cardeira, C., & Calado, J. M. F. (2014). The Daily and Hourly Energy Consumption and Load Forecasting Using Artificial Neural Network Method: A Case Study Using a Set of 93 Households in Portugal. *Energy Procedia*, 62, 220–229. <https://doi.org/10.1016/J.EGYPRO.2014.12.383>

