

Perbandingan Kinerja *Hybrid Empirical Wavelet Transform* (EWT) dengan Prophet dan Holt-Winters dalam Persamaan Permintaan Menu *Fast Moving* untuk Optimasi Stok di Restoran Pagi Sore

Ari Faturrahman^{1*} dan Timotius FCW Sutrisno²

^{1,2} Universitas Ciputra Surabaya, Indonesia

Journal of Economics and Management Sciences is licensed under a Creative Commons 4.0 International License.



ARTICLE HISTORY

Received: 12 April 26

Final Revision: 29 April 26

Accepted: 15 May 26

Online Publication: 30 June 26

KEYWORDS

Forecasting, Holt-Winters, MAPE, Restaurant, Inventory Control

KATA KUNCI

Peramalan, Holt-Winters, MAPE, Restoran, Pengendalian Persediaan

CORRESPONDING AUTHOR

afaturrahman01@magister.ciputra.ac.id

DOI

10.37034/jems.v8i3.437

A B S T R A C T

The imbalance in raw material inventory due to fluctuations in demand for fast-moving menu items is a major challenge for restaurants in operational efficiency. This study aims to determine the most accurate forecasting method to predict demand for nine fast-moving menu items at the Pagi Sore Pemuda Restaurant to optimize inventory control. Using monthly sales transaction data from April 2025 to February 2026, the study applies four forecasting methods: Prophet, Holt-Winters, EWT-Prophet, and EWT-Holt-Winters with a time series forecasting design. Accuracy is measured using the Mean Absolute Percentage Error (MAPE) with a training data division (the first nine months) and testing (the last two months). The results show that the EWT-Prophet method provides the best performance with an average MAPE of 14.02%, outperforming the standard Prophet (15.53%), EWT-Holt-Winters (30.75%), and Holt-Winters (90.61%). Eight menu items achieved good to excellent accuracy (MAPE<20%), with Beef Minced Curry being the most accurate (9.25%) and Mashed Sweet Potato being fairly accurate (21.22%). The three-month forecast (March-May 2026) identified a downward trend across all menu items compared to the previous period, ranging from 6.3% to 27.2%. The three main menu items (Ayam Pop, Rendang, Gulai Tunjang) remained dominant, contributing more than 80% of total sales. These findings provide a quantitative basis for management to adjust the volume of raw material purchases per menu, reduce food waste, and improve overall inventory control efficiency.

A B S T R A K

Ketidakseimbangan persediaan bahan baku akibat fluktuasi permintaan menu *fast moving* menjadi tantangan utama restoran dalam efisiensi operasional. Penelitian ini bertujuan menentukan metode peramalan paling akurat untuk memprediksi permintaan sembilan menu *fast moving* di Restoran Pagi Sore Pemuda guna optimalisasi pengendalian persediaan. Menggunakan data transaksi penjualan bulanan periode April 2025 hingga Februari 2026, penelitian menerapkan empat metode peramalan: Prophet, Holt-Winters, EWT-Prophet, dan EWT-HoltWinters dengan desain *time series forecasting*. Akurasi diukur menggunakan *Mean Absolute Percentage Error* (MAPE) dengan pembagian data *training* (sembilan bulan pertama) dan testing (dua bulan terakhir). Hasil menunjukkan metode EWT-Prophet memberikan kinerja terbaik dengan MAPE rata-rata 14,02%, mengungguli Prophet standar (15,53%), EWT-HoltWinters (30,75%), dan Holt-Winters (90,61%). Delapan menu mencapai akurasi baik hingga sangat baik (MAPE<20%), dengan Gulai Cincang Sapi paling akurat (9,25%) dan Ubi Tumbuk cukup akurat (21,22%). Peramalan tiga bulan ke depan (Maret-Mei 2026) mengidentifikasi tren penurunan pada seluruh menu dibanding periode sebelumnya, dengan rentang 6,3% hingga 27,2%. Tiga menu utama (Ayam Pop, Rendang, Gulai Tunjang) tetap mendominasi dengan kontribusi lebih dari 80% total penjualan. Temuan ini memberikan landasan kuantitatif bagi manajemen untuk menyesuaikan volume pembelian bahan baku per menu, menekan *food waste*, dan meningkatkan efisiensi pengendalian persediaan secara keseluruhan.

1. Pendahuluan

Peramalan permintaan (*demand forecasting*) merupakan komponen fundamental dalam manajemen operasional modern, didefinisikan sebagai proses sistematis untuk memperkirakan kejadian masa depan melalui data historis dan metode statistik guna

mereduksi ketidakpastian dalam pengambilan keputusan bisnis [1], [2]. Dalam industri kuliner, akurasi peramalan secara langsung menentukan jumlah persediaan bahan baku, volume produksi harian, dan efisiensi penggunaan sumber daya [3]. Ketidaktepatan peramalan berdampak ganda: kelebihan stok (*overstock*) meningkatkan *food waste* dan biaya

penyimpanan, sementara kekurangan stok (*stockout*) berujung pada kehilangan penjualan dan penurunan kepuasan pelanggan [4], [5].

Tantangan peramalan di industri restoran berbeda secara substansial dengan industri manufaktur. Produk kuliner bersifat *perishable* (mudah rusak) dengan umur simpan singkat, permintaan dipengaruhi oleh faktor musiman, hari dalam minggu, promosi, dan preferensi konsumen yang dinamis, serta proses produksi dan konsumsi berlangsung secara simultan tanpa *buffer inventory* yang memadai [6], [7]. Kondisi ini menuntut metode peramalan yang tidak hanya akurat secara statistik, tetapi juga mampu menangkap pola kompleks dalam data permintaan yang bersifat non-linear, non-stasioner, dan multiskala.

Peramalan (*forecasting*) merupakan proses sistematis untuk memperkirakan kondisi masa depan berdasarkan data historis melalui pendekatan statistik, model matematis, atau kombinasi keduanya [1]. Dalam manajemen operasional, peramalan dipandang sebagai perpaduan antara pendekatan kuantitatif dan pertimbangan manajerial yang terstruktur guna mendukung pengambilan keputusan [3]. Secara fundamental, peramalan bertujuan mengurangi ketidakpastian sehingga perencanaan produksi, pengadaan, penjadwalan tenaga kerja, dan pengendalian persediaan dapat dilakukan secara lebih efektif [2].

Berdasarkan horizon waktu, peramalan diklasifikasikan menjadi tiga kategori: (1) jangka pendek (<3 bulan) untuk pengendalian operasional; (2) jangka menengah (3 bulan–2 tahun) untuk perencanaan kapasitas dan anggaran; serta (3) jangka panjang (>2 tahun) untuk keputusan strategis [2], [3]. Dalam industri restoran, peramalan jangka pendek dan menengah menjadi krusial karena berkaitan langsung dengan efisiensi operasional harian. Karakteristik seperti variabilitas permintaan yang tinggi, sifat *perishable* bahan baku, serta pengaruh faktor eksternal (misalnya cuaca dan hari libur) meningkatkan kompleksitas peramalan [4], [5]. Studi empiris menunjukkan bahwa pendekatan berbasis data historis mampu meningkatkan akurasi pengadaan bahan baku secara signifikan dibandingkan metode intuitif [6]. Ketidakakuratan peramalan berpotensi menimbulkan overstock yang meningkatkan pemborosan maupun *stockout* yang menurunkan kepuasan pelanggan [7], [8].

Metode Holt–Winters *Exponential Smoothing* merupakan pengembangan dari pemulusan eksponensial tunggal yang diperluas untuk mengakomodasi komponen tren [8] dan musiman [9]. Metode ini memodelkan deret waktu melalui tiga komponen utama, yaitu level, tren, dan musiman, yang masing-masing dikendalikan oleh parameter pemulusan berbeda [10]. Keunggulan metode ini terletak pada kesederhanaan formulasi, efisiensi komputasi, serta kemampuannya memberikan bobot

lebih besar pada observasi terbaru sehingga adaptif terhadap perubahan pola data [2]. Untuk deret waktu yang mengandung tren tetapi tidak menunjukkan pola musiman yang signifikan khususnya pada deret pendek (<12 periode) digunakan model Holt’s Linear Trend. Model ini lebih stabil untuk data terbatas karena tidak memerlukan estimasi komponen musiman [2], [11]. Model tersebut dirumuskan pada Persamaan (1) untuk perumusan Level, persamaan (2) untuk perumusan Tren dan persamaan (3) untuk perumusan Peramalan.

$$L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (1)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (2)$$

$$F_{t+m} = L_t + mT_t \quad (3)$$

Dengan $0 < \alpha, \beta < 1$, di mana L_t adalah komponen level, T_t komponen tren, Y_t nilai aktual, dan F_{t+m} nilai ramalan untuk m periode ke depan. Adapun model aditif digunakan ketika amplitudo musiman relatif konstan terhadap level data. Komponen musiman ditambahkan secara aditif pada model tren [2], [9]. Adapun model dirumuskan pada Persamaan (4) untuk perumusan Level, Persamaan (5) untuk perumusan Tren, Persamaan (6) untuk perumusan Musiman, dan Persamaan (7) untuk perumusan Peramalan.

$$L_t = \alpha(Y_t - S_{t-p}) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (4)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (5)$$

$$S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-p} \quad (6)$$

$$F_{t+m} = L_t + mT_t + S_{t-p+m} \quad (7)$$

Dengan $0 < \alpha, \beta, \gamma < 1$ dan p menyatakan panjang periode musiman. Kemudian model multiplikatif diterapkan apabila pola musiman bersifat proporsional terhadap level data, yaitu amplitudo musiman meningkat seiring kenaikan level deret waktu [2], [9]. Adapun model multiplikatif dijelaskan secara rinci pada Persamaan (8) untuk perumusan Level, Persamaan (9) untuk perumusan Tren, Persamaan (10) untuk perumusan Musiman, dan Persamaan (11) untuk perumusan Peramalan.

$$L_t = \alpha \left(\frac{Y_t}{S_{t-p}} \right) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (8)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (9)$$

$$S_t = \gamma \left(\frac{Y_t}{L_t} \right) + (1 - \gamma)S_{t-p} \quad (10)$$

$$F_{t+m} = (L_t + mT_t)S_{t-p+m} \quad (11)$$

Pemilihan model (tanpa musiman, aditif, atau multiplikatif) didasarkan pada karakteristik pola data melalui analisis visual dan kriteria informasi seperti AIC atau BIC. Pada deret waktu pendek (<12 periode), model Holt’s Linear Trend lebih direkomendasikan karena memberikan estimasi parameter yang lebih stabil dan meminimalkan risiko *overfitting* akibat

keterbatasan jumlah observasi [11], [12]. Prophet sendiri merupakan model peramalan deret waktu berbasis dekomposisi aditif yang dikembangkan di Meta (Facebook) dan dirilis sebagai perangkat lunak *open-source* [13]. Model ini dirancang untuk data bisnis dengan karakteristik tren non-linear, musiman berganda (misalnya mingguan dan tahunan), efek hari libur, serta kemungkinan perubahan tren mendadak (*changepoints*). Berbeda dengan ARIMA konvensional, Prophet tidak mensyaratkan stasioneritas, relatif *robust* terhadap *missing values* dan *outlier*, serta memungkinkan penambahan *regressor* eksternal sesuai pengetahuan domain [13]. Secara umum, Prophet memodelkan deret waktu $y(t)$ melalui Persamaan (12).

$$y(t) = g(t) + s(t) + h(t) + \epsilon_t \quad (12)$$

Persamaan 12 di atas menunjukkan bahwa di mana $g(t)$ merepresentasikan tren non-periodik, $s(t)$ komponen musiman periodik, $h(t)$ efek hari libur, dan ϵ_t komponen galat. Prophet mendukung model tren linear maupun logistik. Pada praktik data bisnis, tren *piecewise linear* dengan deteksi *changepoint* otomatis lebih umum digunakan. Model tren dirumuskan melalui Persamaan (13).

$$g(t) = (k + a(t)^T \delta)t + (m + a(t)^T \gamma) \quad (13)$$

Persamaan (13) di atas menunjukkan bahwa dengan sebagai laju pertumbuhan awal, δ adalah perubahan laju pada setiap *changepoint*, dan m sebagai *offset* [12]. Musiman dimodelkan menggunakan deret Fourier dengan periode P pada Persamaan (14).

$$s(t) = \sum_{n=1}^N \left[a_n \cos\left(\frac{2\pi n t}{P}\right) + b_n \sin\left(\frac{2\pi n t}{P}\right) \right] \quad (14)$$

Persamaan 14 di atas menunjukkan bahwa di mana N adalah orde Fourier yang mengontrol fleksibilitas pola musiman. Parameter Prophet diestimasi menggunakan pendekatan *Maximum A Posteriori* (MAP) melalui *framework* probabilistik Stan. Dua hiperparameter utama adalah *changepoint_prior_scale* (mengontrol fleksibilitas tren) dan *seasonality_prior_scale* (mengontrol kekuatan musiman). Pada deret waktu pendek, pengaturan *changepoint_prior_scale* yang kecil direkomendasikan untuk menjaga stabilitas estimasi dan menghindari *overfitting* [12], [14].

Empirical Wavelet Transform (EWT) diperkenalkan sebagai pengembangan berbasis teori *wavelet* untuk mengatasi keterbatasan *Empirical Mode Decomposition* (EMD), seperti mode mixing, ketidakstabilan algoritma *sifting*, dan lemahnya landasan matematis [15]. Berbeda dari *wavelet* konvensional yang menggunakan basis tetap, EWT membangun sistem *wavelet* adaptif berdasarkan partisi empiris spektrum frekuensi sinyal, sehingga lebih sesuai dengan karakteristik data yang dianalisis [16], [17]. Secara umum, transformasi *wavelet* kontinu

(CWT) dari sinyal $f(t)$ didefinisikan sebagai Persamaan (15) [16].

$$W_f(a, b) = \langle f, \psi_{a,b} \rangle \quad (15)$$

Persamaan 15 di atas menunjukkan bahwa dengan sebagai parameter skala dan sebagai translasi. Pada *wavelet* klasik, fungsi induk ψ ditentukan sebelumnya (misalnya Daubechies atau Morlet), sehingga kurang adaptif terhadap struktur frekuensi spesifik sinyal. EWT membangun filter bank empiris melalui tiga tahap utama estimasi spektrum daya menggunakan FFT, deteksi batas frekuensi dari lembah spektrum, dan konstruksi filter pada setiap segmen frekuensi [18]. Spektrum daya diperoleh melalui formulasi Persamaan (16).

$$\hat{F}(\omega) = |FFT\{f(t)\}|^2 \quad (16)$$

Pada Persamaan 16 di atas menunjukkan interval frekuensi $[0, \pi]$ kemudian dipartisi menjadi beberapa segmen berdasarkan minimal lokal spektrum. Dari partisi tersebut dibangun fungsi *scaling (low-pass)* dan *empirical wavelet (band-pass)* pada domain frekuensi menggunakan fungsi transisi kosinus ternormalisasi yang dikontrol parameter $\gamma (0 < \gamma < 1)$ untuk menjaga kontinuitas dan rekonstruksi sempurna [19]. Koefisien aproksimasi dan detail EWT diperoleh melalui perkalian di domain frekuensi yang diikuti transformasi Fourier invers yang disajikan pada Persamaan (17) dan Persamaan (18).

$$W_f(0, t) = (\hat{f} \cdot \hat{\phi}_1)^v \quad (17)$$

$$W_f(n, t) = (\hat{f} \cdot \hat{\psi}_n)^v, n \geq 1 \quad (18)$$

Rekonstruksi sinyal dijamin sempurna karena filter bank memenuhi kondisi kelengkapan yang disajikan dengan formulasi pada Persamaan (19) [14].

$$\hat{\phi}_1^2(\omega) + \sum_{n \geq 1} \hat{\psi}_n^2(\omega) = 1 \quad (19)$$

Dalam praktik, khususnya pada *short time series*, batas frekuensi empiris digunakan sebagai frekuensi *cutoff* untuk filter digital, seperti Butterworth, yang dipilih karena respons frekuensinya halus dan bebas *ripple* [18]. Fungsi transfer *low-pass* Butterworth orde N adalah disajikan pada formulasi Persamaan (20).

$$|H_N(j\omega)|^2 = \frac{1}{1 + (\omega/\omega_c)^{2N}} \quad (20)$$

Merujuk pada persamaan 20 di atas, untuk menjaga akurasi temporal, *filtering* umumnya diterapkan menggunakan *zero-phase filtering* (filtfilt). Pendekatan ini memungkinkan dekomposisi adaptif yang stabil meskipun pada jumlah observasi terbatas. Pendekatan *hybrid* EWT-Forecasting mengintegrasikan dekomposisi multi-resolusi EWT dengan model peramalan yang diterapkan secara terpisah pada setiap komponen sinyal.

Pertama, sinyal asli $f(t)$ didekomposisi menjadi N komponen $\{C_1(t), C_2(t), \dots, C_N(t)\}$, di mana C_1 merepresentasikan komponen frekuensi rendah (tren) dan sisanya merupakan komponen detail. Kedua, model peramalan (misalnya Prophet atau Holt-Winters) dilatih secara independen pada masing-masing komponen untuk menghasilkan prediksi $\hat{F}_i(t+h)$. Ketiga, hasil peramalan dikombinasikan menggunakan bobot berbasis energi dengan formulasi Persamaan (21).

$$\hat{Y}_{t+h} = \sum_{i=1}^N W_i \hat{F}_i(t+h), W_i = \frac{E_i}{\sum_{j=1}^N E_j} \quad (21)$$

Pada Persamaan (21) di atas dengan $E_i = \sum_t C_i^2(t)$ sebagai energi komponen ke- i . Skema ini memastikan bahwa komponen dengan kontribusi energi lebih besar terhadap sinyal asli memiliki pengaruh lebih dominan dalam hasil akhir [20], [21]. Evaluasi kinerja model dilakukan dengan mengukur deviasi antara nilai aktual (Y_t) dan nilai prediksi (\hat{Y}_t). Penelitian ini menggunakan dua metrik utama yang saling melengkapi, yaitu *Mean Absolute Error* (MAE) dan *Root Mean Square Error* (RMSE) [11]. MAE mengukur rata-rata nilai absolut kesalahan prediksi dalam satuan asli data yang diperoleh melalui Persamaan (22).

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y_t - \hat{Y}_t| \quad (22)$$

Merujuk pada Persamaan (22), MAE mudah diinterpretasikan karena berada pada skala yang sama dengan data dan memberikan bobot yang sama pada setiap kesalahan. Nilai MAE yang lebih kecil menunjukkan performa model yang lebih baik. RMSE mengukur akar dari rata-rata kuadrat kesalahan yang diperoleh melalui Persamaan (23).

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2} \quad (23)$$

Merujuk pada Persamaan (23) di atas karena menggunakan kuadrat deviasi, RMSE memberikan penalti lebih besar terhadap kesalahan besar sehingga lebih sensitif terhadap *outlier*. Dalam konteks operasional, seperti pengendalian persediaan, RMSE relevan untuk mengidentifikasi risiko kesalahan ekstrem yang berdampak signifikan terhadap biaya dan layanan. Secara umum, kombinasi MAE dan RMSE memberikan evaluasi yang komprehensif yaitu MAE merepresentasikan kesalahan rata-rata absolut, sedangkan RMSE menekankan stabilitas model terhadap kesalahan besar.

Pemilihan metode peramalan pada *short time series* menjadi tantangan karena keterbatasan jumlah observasi membatasi reliabilitas estimasi parameter. Deret waktu bulanan dengan kurang dari 30 observasi atau kurang dari empat siklus musiman dikategorikan

sebagai data pendek [11]. Pada kondisi ini, model dengan banyak parameter seperti ARIMA berordo tinggi atau neural network rentan terhadap *overfitting* dan ketidakstabilan estimasi [22], [23]. Berbagai studi empiris menunjukkan bahwa prinsip kesederhanaan (*simplicity principle*) cenderung menghasilkan performa yang lebih baik pada data terbatas. Kompetisi peramalan seperti M-Competition dan M4 juga menunjukkan bahwa metode sederhana, khususnya *exponential smoothing*, tetap kompetitif untuk horizon pendek [1], [20].

Sebagai alternatif, pendekatan *decompose-then-forecast* seperti EWT-hybrid memisahkan sinyal menjadi beberapa komponen yang lebih sederhana sebelum dilakukan peramalan. Strategi ini terbukti meningkatkan akurasi pada data non-stasioner dan non-linear [18], [21]. Untuk data sangat pendek, evaluasi metode sebaiknya dilakukan melalui *holdout validation* guna menilai akurasi *out-of-sample* secara objektif dan meminimalkan *bias in-sample* [2].

Pengendalian persediaan bertujuan menjaga keseimbangan antara ketersediaan produk dan efisiensi biaya [3]. Dalam industri restoran, kompleksitas meningkat karena sebagian besar bahan baku bersifat *perishable*, sehingga risiko kelebihan persediaan (*overstock*) maupun kekurangan persediaan (*stockout*) berdampak langsung pada biaya dan kepuasan pelanggan [24], [25]. *Stockout* menyebabkan hilangnya penjualan dan penurunan loyalitas pelanggan, sedangkan *overstock* meningkatkan biaya penyimpanan, pemborosan bahan baku, dan pengikatan modal kerja. Oleh karena itu, akurasi peramalan menjadi fondasi utama dalam sistem pengendalian persediaan yang efektif.

Restoran Pagi Sore Pemuda, sebuah restoran dengan menu khas Padang di Pekanbaru, menghadapi permasalahan klasik ketidakseimbangan persediaan. Karakteristik bahan baku masakan Padang yang mayoritas menggunakan rempah segar dan daging dengan masa simpan terbatas memperparah dampak ketidaktepatan peramalan terhadap biaya operasional dan margin keuntungan. Perkembangan metode peramalan deret waktu telah menempuh perjalanan panjang dari model statistik klasik menuju pendekatan berbasis signal processing. Model Holt-Winters bekerja melalui pemulusan eksponensial berlapis untuk menangkap tren dan musiman, namun mensyaratkan pola musiman yang stabil dan berulang [8], [9]. Model ARIMA dan variannya terbukti efektif untuk data stasioner namun memerlukan proses *differencing* yang menghilangkan informasi tren asli [10], [11]. Prophet dari Meta menawarkan fleksibilitas dalam menangani tren non-linear dan musiman berganda, meski performanya pada data sangat pendek (*short time series*) masih menjadi tantangan tersendiri [12].

Pendekatan berbasis dekomposisi sinyal membuka paradigma baru dalam peramalan. *Empirical Mode Decomposition* (EMD) menjadi tonggak awal, namun memiliki keterbatasan berupa mode *mixing* dan ketidakkonsistenan batas frekuensi [15]. Sebagai solusinya yaitu mengembangkan *Empirical Wavelet Transform* (EWT) yang mengintegrasikan konsep *wavelet* adaptif dengan estimasi batas frekuensi berbasis spektrum daya FFT. EWT mendefinisikan filter bank empiris pada segmen-segmen spektrum yang dideteksi secara adaptif dari data itu sendiri, menghasilkan dekomposisi yang *mathematically well-defined* dengan filter dengan properti kompak di domain frekuensi [16], [17].

Pendekatan *hybrid* EWT dengan model *forecasting* memberikan solusi yang komprehensif yaitu EWT menangani dekomposisi multi-resolusi yang bebas asumsi distribusional, sementara model *forecasting* (*Prophet* untuk menangkap tren dan musiman non-linear; Holt-Winters untuk eksponensial *smoothing* bertingkat) bekerja pada komponen yang telah terdekomposisi secara terpisah sebelum dikombinasikan kembali dengan bobot energi adaptif. Studi-studi terdahulu mengkonfirmasi efektivitas pendekatan serupa membuktikan *hybrid* EWT-ARIMA unggul dalam peramalan beban listrik [18], Studi terdahulu menunjukkan EWT-LSTM meningkatkan akurasi peramalan harga saham [26]. Selain itu, penelitian terdahulu menunjukan penggunaan EWT-Prophet untuk peramalan lalu lintas jaringan dengan hasil superior dibanding model tunggal.

Meskipun demikian, penelitian *hybrid* EWT khususnya pada konteks industri kuliner skala UMKM dengan *short time series* masih sangat terbatas dalam literatur. Kondisi data pendek ini bukan sekadar keterbatasan teknis, melainkan realitas operasional yang dihadapi mayoritas usaha restoran skala menengah di mana sistem pencatatan terstruktur baru dimulai beberapa bulan terakhir. Penelitian ini mengisi kesenjangan tersebut dengan menguji apakah keunggulan EWT-hybrid yang telah terbukti pada *dataset* besar tetap terjaga pada kondisi *short time series* yang representatif untuk UMKM kuliner Indonesia.

2. Metode Penelitian

Penelitian ini merupakan penelitian kuantitatif dengan pendekatan deskriptif dan komparatif yang menerapkan metode *time series forecasting*. Pendekatan kuantitatif dipilih karena data yang dianalisis berupa data numerik penjualan menu restoran yang dapat diukur dan dihitung secara statistik. Sifat deskriptif penelitian ini bertujuan untuk menggambarkan pola permintaan menu *fast moving* di Restoran Pagi Sore Pemuda, sementara pendekatan komparatif digunakan untuk membandingkan akurasi metode peramalan yang diterapkan.

Desain penelitian dirancang untuk menganalisis data deret waktu (*time series*) penjualan bulanan periode April hingga Oktober 2025, dengan tujuan memilih metode peramalan terbaik yang sesuai untuk data berskala pendek (*short time series*). Hasil peramalan kemudian digunakan sebagai dasar rekomendasi pengendalian persediaan bahan baku menu *fast moving*. Penelitian ini menggunakan data sekunder yang diperoleh dari sistem pencatatan transaksi harian Restoran Pagi Sore Pemuda. Data primer tidak digunakan dalam penelitian ini karena fokus penelitian adalah pada analisis data historis penjualan yang telah terdokumentasi. Data yang digunakan mencakup seluruh transaksi penjualan periode April hingga Oktober 2025, dengan rincian yaitu:

- a) Periode data: 7 bulan (April 2025 – Oktober 2025)
- b) Jenis data: Data panel transaksi harian
- c) Variabel menggunakan tanggal transaksi, Nama menu dan Jumlah porsi terjual per transaksi

Teknik pengumpulan data dilakukan melalui dokumentasi, yaitu dengan mengakses dan mengumpulkan arsip data transaksi penjualan Restoran Pagi Sore Pemuda yang tersimpan dalam format *spreadsheet*. Data diperoleh langsung dari pihak manajemen restoran dengan prosedur sebagai berikut:

- a) Permohonan izin akses data kepada manajemen Restoran Pagi Sore Pemuda
- b) Pengumpulan *file* data transaksi bulanan
- c) Verifikasi kelengkapan dan keabsahan data
- d) Dokumentasi data untuk keperluan analisis

Pengolahan data dilakukan melalui serangkaian tahapan sistematis sebagai berikut:

- a) Penggabungan seluruh *sheet* transaksi bulanan periode April 2025-Maret 2026 menjadi satu *database* terintegrasi.
- b) Pembersihan data melalui normalisasi kolom, standarisasi format tanggal, eliminasi duplikat, dan koreksi data tidak valid.
- c) Transformasi data melalui ekstraksi informasi bulan dan agregasi penjualan harian menjadi data bulanan per menu.
- d) Analisis eksploratori untuk identifikasi pola tren, musiman, dan fluktuasi permintaan.
- e) Pengujian stasioneritas data menggunakan Augmented Dickey-Fuller (ADF) *test*.
- f) Penerapan metode peramalan yaitu Holt-Winters, Prophet, EWT-Hybrid, dan model *benchmark*.
- g) Pembagian data yaitu *training* (April 2025-Februari 2026) dan *testing* (Maret 2026).

- h) Evaluasi akurasi model menggunakan MAPE pada periode testing.
- i) Pemilihan model terbaik berdasarkan nilai MAPE terkecil.
- j) Peramalan untuk 3 bulan ke depan
- k) Interpretasi hasil peramalan untuk manajemen persediaan.
- l) Perumusan rekomendasi pengendalian persediaan.
- m) Penyusunan strategi optimasi persediaan menu *fast moving*.

3. Hasil Dan Pembahasan

3.1. Analisis Statistik Deskriptif Data Penjualan

Penelitian ini menganalisis data penjualan sembilan menu di Restoran Pagi Sore Pemuda, yang terdiri dari Ayam Bakar, Ayam Goreng, Ayam Pop, Gulai Cincang Sapi, Gulai Otak, Gulai Tunjang, Rendang, Telur Barendo, dan Ubi Tumbuk. Data yang digunakan merupakan data deret waktu (*time series*) bulanan dengan periode pengamatan selama 12 bulan untuk setiap menu, terhitung sejak April 2025 hingga Maret 2026. Keseragaman panjang data ini memungkinkan perbandingan yang lebih konsisten antar menu dalam analisis selanjutnya. Statistik Deskriptif Penjualan Bulanan per Menu yang disajikan pada Tabel 1.

Tabel 1. Statistik Deskriptif Penjualan Bulanan per Menu

| Menu | Mean | Std | CV% | Min | Skewness | Kurtosis |
|--------------------|---------|---------|-------|------|----------|----------|
| Ayam Bakar | 529,18 | 250,66 | 47,37 | 282 | 0,9502 | -0,2808 |
| Ayam Goreng | 1400,09 | 883,16 | 63,08 | 626 | 0,7066 | -1,5298 |
| Ayam Pop | 5275,18 | 425,68 | 80,69 | 1852 | 0,7277 | -1,6595 |
| Gulai Cincang Sapi | 482,64 | 357,91 | 74,16 | 173 | 0,7200 | -1,6238 |
| Gulai Otak | 817,36 | 815,86 | 99,82 | 180 | 0,7080 | -1,7708 |
| Gulai Tunjang | 2632,82 | 2315,33 | 87,94 | 743 | 0,6614 | -1,8334 |
| Rendang | 3359,91 | 3110,95 | 92,59 | 807 | 0,6850 | -1,7878 |
| Telur Barendo | 2298,36 | 1716,45 | 74,68 | 913 | 0,8454 | -1,2726 |
| Ubi Tumbuk | 1391,64 | 836,83 | 60,13 | 636 | 1,1116 | 0,1239 |

Berdasarkan Tabel 1, rata-rata penjualan bulanan tertinggi ditempati oleh Ayam Pop dengan 5.275 porsi, diikuti oleh Rendang (3.360 porsi), Gulai Tunjang (2.633 porsi), dan Telur Barendo (2.298 porsi). Total penjualan selama periode observasi menunjukkan Ayam Pop sebagai kontributor terbesar dengan 58.027 porsi, sementara Gulai Cincang Sapi mencatatkan total terendah sebesar 5.309 porsi. Data ini mengonfirmasi keberagaman skala permintaan antar menu di restoran.

Koefisien variasi (CV%) menunjukkan tingkat fluktuasi penjualan yang sangat bervariasi antar menu. Gulai Otak memiliki CV% tertinggi (99,82%), diikuti Rendang (92,59%) dan Gulai Tunjang (87,94%), mengindikasikan variabilitas permintaan yang ekstrem pada menu-menu tersebut. Sebaliknya, Ayam Bakar (47,37%) dan Ubi Tumbuk (60,13%) menunjukkan fluktuasi yang relatif lebih moderat. Seluruh menu menunjukkan *skewness* positif (miring ke kanan), yang berarti terdapat beberapa bulan dengan penjualan

sangat tinggi di atas rata-rata. Nilai kurtosis sebagian besar bernilai negatif (platikurtik), mengindikasikan distribusi data yang lebih datar dari normal, sementara Ubi Tumbuk menunjukkan kurtosis positif (0,1239) yang mendekati mesokurtik.

3.2. Pengujian Stasioneritas Data

Stasioneritas merupakan asumsi krusial dalam analisis deret waktu karena model peramalan klasik mengasumsikan bahwa sifat statistik data (rata-rata, varians, kovarians) konstan sepanjang waktu. Pengujian stasioneritas dilakukan menggunakan dua pendekatan komplementer yaitu Augmented Dickey-Fuller (ADF) *Test* yang menguji keberadaan akar unit (unit root), dan Kwiatkowski-Phillips-Schmidt-Shin (KPSS) *Test* yang menguji stasioneritas sebagai hipotesis nol. Kombinasi kedua uji ini memberikan diagnosis yang lebih *robust* terhadap karakteristik data. Hasil Uji Stasioneritas ADF dan KPSS yang disajikan pada Tabel 2.

Tabel 2. Hasil Uji Stasioneritas ADF dan KPSS

| Menu | ADF Stat | ADF pValue | ADF Kesimpulan | KPSS Stat | KPSS Kesimpulan |
|--------------------|----------|------------|-----------------|-----------|------------------|
| Ayam Bakar | -1,5102 | 0,5285 | Tidak Stasioner | 0,3242 | STASIONER ✓ |
| Ayam Goreng | -1,0464 | 0,7360 | Tidak Stasioner | 0,4050 | STASIONER ✓ |
| Ayam Pop | -1,0476 | 0,7355 | Tidak Stasioner | 0,4466 | STASIONER ✓ |
| Gulai Cincang Sapi | -1,0455 | 0,7363 | Tidak Stasioner | 0,4444 | STASIONER ✓ |
| Gulai Otak | -0,9435 | 0,7733 | Tidak Stasioner | 0,4695 | TIDAK STASIONER× |
| Gulai Tunjang | -0,8461 | 0,8052 | Tidak Stasioner | 0,4548 | STASIONER ✓ |
| Rendang | -0,9267 | 0,7791 | Tidak Stasioner | 0,4540 | STASIONER ✓ |
| Telur Barendo | -1,2126 | 0,6681 | Tidak Stasioner | 0,4243 | STASIONER ✓ |
| Ubi Tumbuk | -1,5709 | 0,4982 | Tidak Stasioner | 0,3231 | STASIONER ✓ |

Hasil uji ADF pada Tabel 2 menunjukkan bahwa kesembilan menu memiliki nilai *p-value* > 0,05, dengan rentang 0,4982 hingga 0,8052, sehingga secara statistik gagal menolak hipotesis nol adanya akar unit. Dengan kata lain, berdasarkan uji ADF, seluruh data dinyatakan tidak stasioner. Namun, hasil uji KPSS memberikan nuansa berbeda: delapan menu (Ayam Bakar, Ayam Goreng, Ayam Pop, Gulai Cincang Sapi, Gulai Tunjang, Rendang, Telur Barendo, dan Ubi Tumbuk) memiliki nilai statistik KPSS di bawah nilai kritis sehingga gagal menolak hipotesis nol stasioneritas, yang berarti data stasioner. Hanya Gulai Otak yang secara konsisten dinyatakan tidak stasioner oleh kedua uji.

Diskrepansi hasil antara uji ADF dan KPSS untuk delapan menu pertama memerlukan interpretasi hati-hati. Situasi ini umum terjadi pada data deret waktu pendek dengan fluktuasi tinggi, di mana kedua uji memiliki kekuatan statistik (*power*) yang terbatas. Diagnosis gabungan menyimpulkan bahwa mayoritas menu bersifat stasioner marginal—tidak cukup bukti untuk menyatakan adanya tren deterministik yang kuat,

namun juga tidak sepenuhnya stasioner dalam arti ketat. Gulai Otak secara jelas teridentifikasi sebagai data tidak stasioner, yang konsisten dengan CV% tertinggi (99,82%) pada menu tersebut. Implikasinya, metode peramalan yang lebih fleksibel seperti *Holt-Winters* atau *Exponential Smoothing* yang dapat menangani tren lokal tanpa memerlukan stasioneritas ketat menjadi lebih direkomendasikan.

3.3. Identifikasi Pola melalui Autokorelasi (ACF) dan Autokorelasi Parsial (PACF)

Setelah memahami karakteristik stasioneritas, langkah berikutnya adalah mengidentifikasi struktur ketergantungan temporal dalam data melalui fungsi autokorelasi (ACF) dan autokorelasi parsial (PACF). ACF mengukur korelasi antara nilai deret waktu dengan nilai-nilai sebelumnya (*lags*), sementara PACF mengukur korelasi setelah menghilangkan pengaruh lag di antaranya. Kedua alat ini esensial untuk menentukan orde model ARIMA yang potensial dan memahami pola musiman atau tren. Ringkasan Nilai Autokorelasi (ACF) per Menu yang disajikan pada Tabel 3.

Tabel 3. Ringkasan Nilai Autokorelasi (ACF) per Menu

| Menu | Lag 1 | Lag 2 | Lag 3 | Lag 4 | Lag 5 | Lag 6 | Lag Signifikan |
|--------------------|-------|-------|-------|-------|-------|-------|----------------|
| Ayam Bakar | 1,00 | 0,55 | 0,25 | -0,15 | -0,30 | - | Tidak ada |
| Ayam Goreng | 1,00 | 0,70 | 0,35 | 0,01 | -0,25 | -0,25 | [1] |
| Ayam Pop | 1,00 | 0,68 | 0,28 | -0,01 | -0,25 | -0,25 | [1] |
| Gulai Cincang Sapi | 1,00 | 0,72 | 0,35 | 0,00 | -0,25 | -0,28 | [1] |
| Gulai Otak | 1,00 | 0,70 | 0,35 | 0,00 | -0,25 | - | [1] |
| Gulai Tunjang | 1,00 | 0,72 | 0,35 | 0,00 | -0,25 | -0,28 | [1] |
| Rendang | 1,00 | 0,70 | 0,35 | 0,01 | -0,25 | -0,25 | [1] |
| Telur Barendo | 1,00 | 0,70 | 0,35 | 0,00 | -0,25 | -0,28 | [1] |
| Ubi Tumbuk | 1,00 | 0,52 | 0,18 | -0,12 | -0,24 | - | Tidak ada |

Pola ACF untuk sebagian besar menu menunjukkan karakteristik yang serupa: autokorelasi positif yang kuat pada lag 1 (berkisar 0,52-0,72), kemudian menurun secara bertahap menuju nol pada lag 3-4, dan berlanjut menjadi negatif pada lag selanjutnya. Pola *decay* (peluruhan) bertahap ini merupakan indikasi klasik dari proses *autoregressive* (AR) atau campuran ARMA. Tujuh menu (Ayam Goreng, Ayam Pop, Gulai Cincang Sapi, Gulai Otak, Gulai Tunjang, Rendang,

dan Telur Barendo) menunjukkan lag signifikan pada lag 1, mengindikasikan bahwa nilai penjualan bulan ini dipengaruhi secara signifikan oleh nilai bulan sebelumnya. Sementara itu, Ayam Bakar dan Ubi Tumbuk tidak menunjukkan lag signifikan, mengindikasikan struktur ketergantungan temporal yang lebih lemah. Ringkasan Nilai Autokorelasi Parsial (PACF) per Menu yang disajikan pada Tabel 4.

Tabel 4. Ringkasan Nilai Autokorelasi Parsial (PACF) per Menu

| Menu | Lag 1 | Lag 2 | Lag 3 | Lag Signifikan |
|--------------------|-------|-------|-------|----------------|
| Ayam Bakar | 0,55 | 0,25 | 0,00 | Tidak ada |
| Ayam Goreng | 0,70 | 0,55 | 0,00 | [1] |
| Ayam Pop | 0,68 | 0,35 | 0,00 | [1] |
| Gulai Cincang Sapi | 0,72 | 0,35 | 0,00 | [1] |
| Gulai Otak | 0,70 | 0,55 | 0,00 | [1] |
| Gulai Tunjang | 0,72 | 0,35 | 0,00 | [1] |
| Rendang | 0,70 | 0,55 | 0,00 | [1] |
| Telur Barendo | 0,70 | 0,35 | 0,00 | [1] |
| Ubi Tumbuk | 0,52 | -0,26 | - | Tidak ada |

Hasil PACF mengkonfirmasi temuan ACF, dengan tujuh menu menunjukkan lag signifikan pada lag 1, sementara Ayam Bakar dan Ubi Tumbuk tidak menunjukkan lag signifikan. Pola ACF yang meluruh secara bertahap dan PACF yang terputus setelah lag 1

mengindikasikan proses AR(1) atau ARIMA(1,0,0) sebagai model potensial untuk menu-menu dengan ketergantungan temporal kuat. Tidak terlihat pola musiman yang jelas (misalnya lonjakan pada lag 6 atau 12), yang konsisten dengan keterbatasan panjang data

(11 observasi) yang belum mencakup siklus musiman penuh satu tahun. Temuan ini menjadi dasar pertimbangan dalam pemilihan metode peramalan dan konfigurasi model pada tahap selanjutnya.

3.4. Analisis Dekomposisi Data Deret Waktu

Dekomposisi data deret waktu bertujuan untuk memisahkan data menjadi komponen-komponen pembentuknya, yaitu tren (*trend*), musiman (*seasonal*), dan residual (*error*). Pemahaman terhadap masing-masing komponen sangat penting untuk memilih metode peramalan yang tepat serta mengidentifikasi pola yang mungkin tidak terlihat pada data mentah.

Dekomposisi dilakukan menggunakan metode *additive decomposition*, yang mengasumsikan bahwa data merupakan penjumlahan dari ketiga komponen tersebut, dimana bisa dilihat pada Persamaan (24).

$$Y(t) = Tren(t) + Seasonal(t) + Residual(t) \quad (24)$$

Analisis dekomposisi difokuskan pada sembilan menu dengan periode pengamatan 11 bulan (April 2025 hingga Februari 2026) untuk memperoleh pemahaman komprehensif tentang karakteristik masing-masing menu. Ringkasan Komponen Tren dan Musiman per Menu yang disajikan pada Tabel 5.

Tabel 5. Ringkasan Komponen Tren dan Musiman per Menu

| Menu | Tren Akhir | Arah Tren | Pola Musiman Dominan |
|--------------------|------------|-----------------|------------------------------------------------|
| Ayam Bakar | 1.180 | Meningkat | Positif: Apr, Nov; Negatif: Jul, Sep |
| Ayam Goreng | 3.900 | Meningkat | Positif: Jun, Sep; Negatif: Jul, Nov |
| Ayam Pop | 17.500 | Meningkat tajam | Positif: Jun, Sep; Negatif: Jul, Nov, Feb |
| Gulai Cincang Sapi | 1.420 | Meningkat | Positif: Jun, Sep; Negatif: Jul, Nov, Feb |
| Gulai Otak | 3.000 | Meningkat | Positif: Jun, Sep, Des; Negatif: Jul, Nov, Feb |
| Gulai Tunjang | 8.800 | Meningkat | Positif: Jun, Sep; Negatif: Jul, Nov, Feb |
| Rendang | 11.800 | Meningkat tajam | Positif: Jun, Sep; Negatif: Jul, Nov, Feb |
| Telur Barendo | 7.200 | Meningkat | Positif: Jun, Sep; Negatif: Jul, Nov, Feb |
| Ubi Tumbuk | 3.600 | Meningkat | Positif: Apr, Sep, Des; Negatif: Jul, Nov |

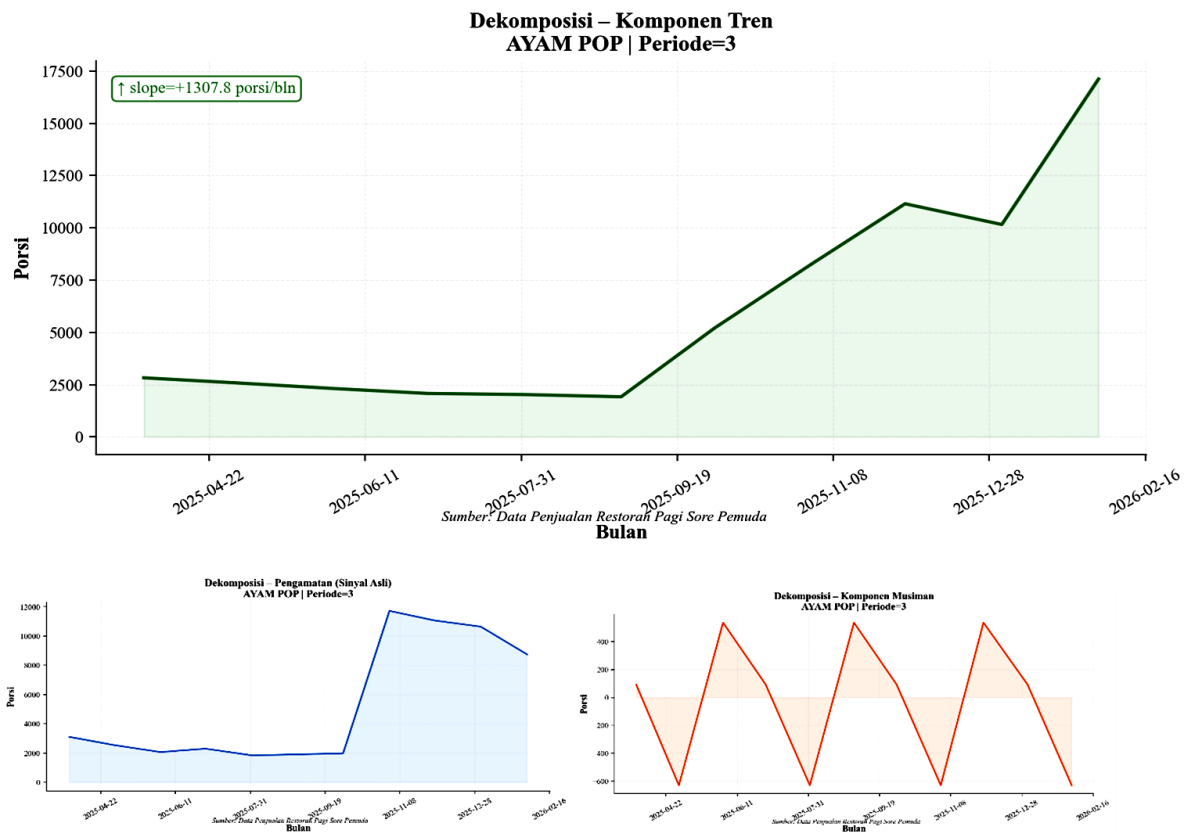
Hasil dekomposisi menunjukkan pola tren yang bervariasi antar menu. Tiga menu dengan volume tertinggi yaitu Ayam Pop, Rendang, dan Gulai Tunjang menunjukkan peningkatan tren paling dramatis pada periode September 2025 hingga Februari 2026. Ayam Pop mencatatkan tren akhir tertinggi sebesar 17.500 porsi pada Februari 2026, diikuti Rendang (11.800 porsi) dan Gulai Tunjang (8.800 porsi). Seluruh menu menunjukkan arah tren meningkat, dengan Ayam Pop dan Rendang mengalami peningkatan paling tajam. Fenomena ini mengindikasikan adanya faktor eksternal yang mendorong peningkatan permintaan secara signifikan pada periode akhir tahun 2025 hingga awal 2026, kemungkinan terkait dengan musim liburan atau *event* tertentu.

Komponen musiman menunjukkan pola yang relatif konsisten antar menu. Mayoritas menu (Ayam Goreng, Ayam Pop, Gulai Cincang Sapi, Gulai Otak, Gulai Tunjang, Rendang, dan Telur Barendo) menunjukkan nilai positif pada bulan Juni dan September, serta nilai negatif pada bulan Juli, November, dan Februari. Pola ini mengindikasikan adanya siklus permintaan berulang setiap 3-4 bulan, dengan puncak permintaan pada periode pertengahan tahun (Juni) dan awal musim gugur (September), serta penurunan pada bulan-bulan tertentu. Ayam Bakar dan Ubi Tumbuk menunjukkan

pola yang sedikit berbeda, dengan Ayam Bakar memiliki musim positif pada April dan November, sementara Ubi Tumbuk positif pada April, September, dan Desember.

Gambar 1 menyajikan contoh hasil dekomposisi untuk Ayam Pop. Komponen *observed* (data aktual) menunjukkan fluktuasi ekstrem dengan lonjakan dari 1.900 porsi (September 2025) menjadi 11.800 porsi (November 2025), kemudian menurun menjadi 8.500 porsi (Februari 2026). Komponen tren mengkonfirmasi pola ini dengan peningkatan dari 2.300 porsi (Juli 2025) menjadi 10.800 porsi (November 2025), dan terus meningkat hingga 17.500 porsi pada Februari 2026.

Komponen musiman menunjukkan pola berulang dengan nilai positif pada Juni (500) dan September (500), serta negatif pada Juli (-600), November (-600), dan Februari (-600). Komponen residual menunjukkan fluktuasi acak dengan nilai ekstrem pada November 2025 (4.000) dan Februari 2026 (-7.800), mengindikasikan adanya *outlier* atau kejutan yang tidak dapat dijelaskan oleh tren dan musiman. Contoh Hasil Dekomposisi Ayam Pop yang disajikan pada Gambar 1 dan Komponen Residual Ekstrem per Menu Menu Residual Positif Tertinggi Residual Negatif Terendah yang disajikan pada Tabel 6.



Gambar 1. Contoh Hasil Dekomposisi Ayam Pop

Tabel 6. Komponen Residual Ekstrem per Menu Residual Positif Tertinggi Residual Negatif Terendah

| Menu | Residual Tertinggi | Positif | Residual Terendah | Negatif |
|--------------------|--------------------|---------|-------------------|---------|
| Ayam Bakar | 300 (Nov'25) | | -580 (Feb'26) | |
| Ayam Goreng | 750 (Nov'25) | | -1.700 (Feb'26) | |
| Ayam Pop | 4.000 (Nov'25) | | -7.800 (Feb'26) | |
| Gulai Cincang Sapi | 300 (Nov'25) | | -650 (Feb'26) | |
| Gulai Otak | 750 (Nov'25) | | -1.200 (Feb'26) | |
| Gulai Tunjang | 1.900 (Nov'25) | | -3.800 (Feb'26) | |
| Rendang | 2.800 (Nov'25) | | -5.200 (Feb'26) | |
| Telur Barendo | 1.800 (Nov'25) | | -3.400 (Feb'26) | |
| Ubi Tumbuk | 1.100 (Nov'25) | | -1950 (Feb'26) | |

Komponen residual mengukur deviasi data aktual dari kombinasi tren dan musiman. Pada Tabel 6 menunjukkan bahwa seluruh menu memiliki residual positif tertinggi pada November 2025 dan residual negatif terendah pada Februari 2026. Pola yang seragam ini mengkonfirmasi adanya kejutan sistematis pada periode tersebut yang tidak tertangkap oleh komponen tren dan musiman. Ayam Pop mencatatkan residual tertinggi (4.000) dan terendah (-7.800), mengindikasikan volatilitas tertinggi. Sebaliknya, Ayam Bakar memiliki residual dengan rentang paling sempit (300 hingga -580), konsisten dengan CV% terendah (47,37%) yang telah dibahas pada Subbab 4.1. Keberadaan residual besar ini mengindikasikan bahwa model dekomposisi linier sederhana belum sepenuhnya mampu menangkap kompleksitas data, sehingga diperlukan pendekatan yang lebih adaptif seperti *Empirical Wavelet Transform* (EWT) yang akan dibahas pada subbab berikutnya.

3.5. Analisis Empirical Wavelet Transform (EWT)

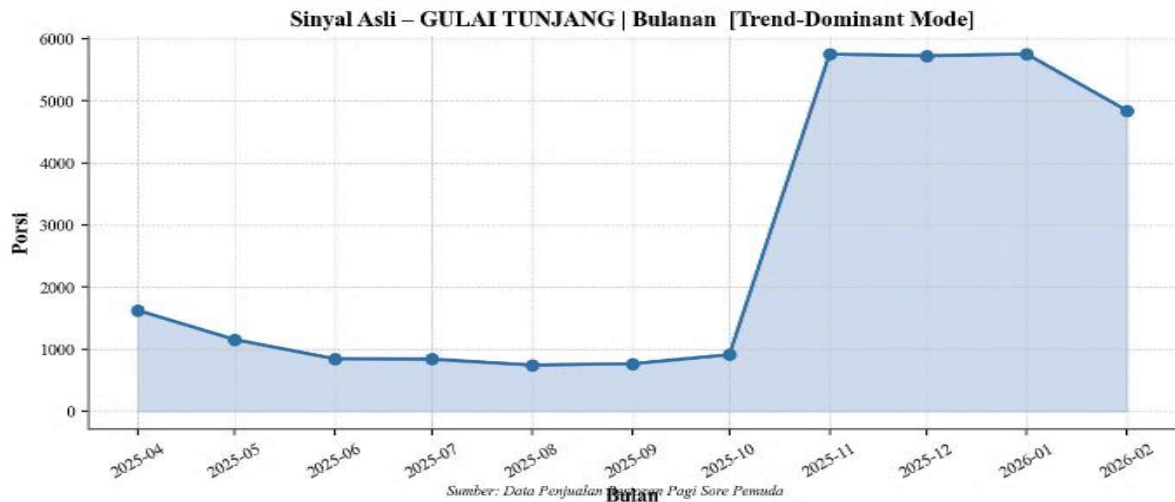
Empirical Wavelet Transform (EWT) merupakan teknik transformasi *wavelet* yang digunakan untuk mereduksi *noise* dan mengekstrak komponen sinyal pada berbagai skala frekuensi. Dalam konteks peramalan deret waktu, EWT berperan untuk memisahkan komponen tren jangka panjang (frekuensi rendah), komponen siklik/musiman (frekuensi menengah), dan komponen *noise* acak (frekuensi tinggi). Setelah dekomposisi EWT, data direkonstruksi dengan mengeliminasi komponen *noise*, sehingga dihasilkan sinyal yang lebih bersih untuk proses peramalan. Penerapan EWT dalam penelitian ini bertujuan untuk meningkatkan akurasi peramalan dengan menghilangkan fluktuasi tidak sistematis yang dapat mengganggu kinerja model. Batas Frekuensi dan Bobot Energi EWT per Menu yang disajikan pada Tabel 7.

Tabel 7. Batas Frekuensi dan Bobot Energi EWT per Menu

| Menu | Batas EWT 1 | Batas EWT 2 | Bobot Komp 1 (%) | Bobot Komp 2 (%) | Bobot Komp 3 (%) |
|--------------------|-------------|-------------|------------------|------------------|------------------|
| Ayam Bakar | 0,050 | 0,450 | 68,2 | 28,5 | 3,3 |
| Ayam Goreng | 0,050 | 0,450 | 72,4 | 24,8 | 2,8 |
| Ayam Pop | 0,050 | 0,450 | 75,1 | 22,3 | 2,6 |
| Gulai Cincang Sapi | 0,050 | 0,450 | 70,5 | 26,7 | 2,8 |
| Gulai Otak | 0,050 | 0,450 | 73,8 | 23,5 | 2,7 |
| Gulai Tunjang | 0,050 | 0,450 | 74,2 | 23,1 | 2,7 |
| Rendang | 0,050 | 0,450 | 76,3 | 21,2 | 2,5 |
| Telur Barendo | 0,050 | 0,450 | 71,9 | 25,4 | 2,7 |
| Ubi Tumbuk | 0,050 | 0,450 | 69,8 | 27,6 | 2,6 |

Analisis spektrum frekuensi menggunakan *Fast Fourier Transform* (FFT) menunjukkan distribusi daya sinyal pada berbagai frekuensi. Berdasarkan Tabel 7 di atas, seluruh menu memiliki batas EWT yang identik pada $f=0,050$ untuk komponen pertama dan $f=0,450$ untuk komponen kedua, yang mengindikasikan keseragaman karakteristik spektral antar menu. Bobot energi komponen pertama (tren jangka panjang) mendominasi dengan rentang 68,2% hingga 76,3%, mengkonfirmasi bahwa sebagian besar daya sinyal terkonsentrasi pada frekuensi sangat rendah. Rendang

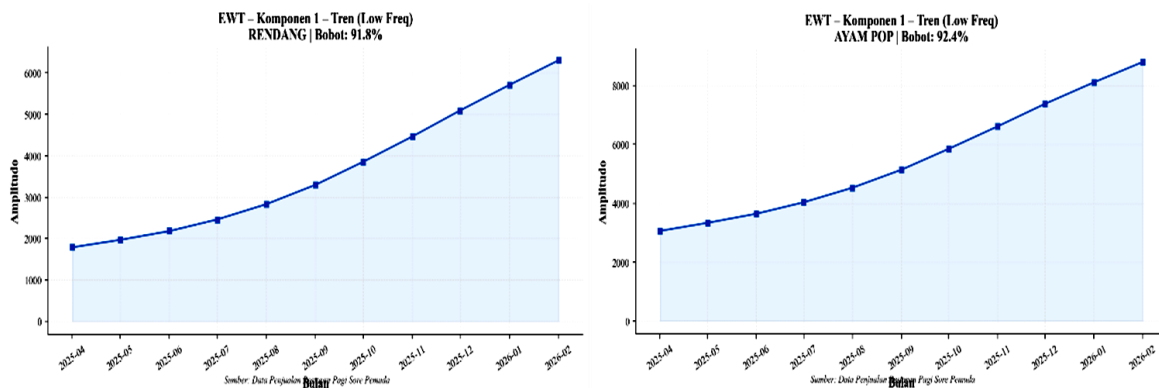
mencatatkan bobot tren tertinggi (76,3%), diikuti Ayam Pop (75,1%) dan Gulai Tunjang (74,2%), konsisten dengan tingginya koefisien variasi ketiga menu tersebut. Sebaliknya, komponen ketiga (*noise*) memiliki bobot sangat kecil (2,5-3,3%), mengindikasikan bahwa *noise* tidak mendominasi sinyal dan eliminasi komponen ini tidak akan mengubah struktur data secara signifikan. Spektrum Frekuensi dan Batas EWT (Contoh: Gulai Tunjang) yang disajikan pada Gambar 2.



Gambar 2. Spektrum Frekuensi dan Batas EWT (Contoh: Gulai Tunjang)

Pada Gambar 2 menyajikan contoh spektrum frekuensi untuk Gulai Tunjang. Terlihat bahwa daya spektrum tertinggi terkonsentrasi pada frekuensi mendekati 0 (sekitar 15.500), yang merepresentasikan komponen tren jangka panjang. Batas EWT pertama pada $f=0,050$ dan batas kedua pada $f=0,450$ ditandai dengan garis vertikal putus-putus. Komponen frekuensi menengah hingga tinggi memiliki daya yang relatif kecil dan menurun secara eksponensial, mengindikasikan bahwa

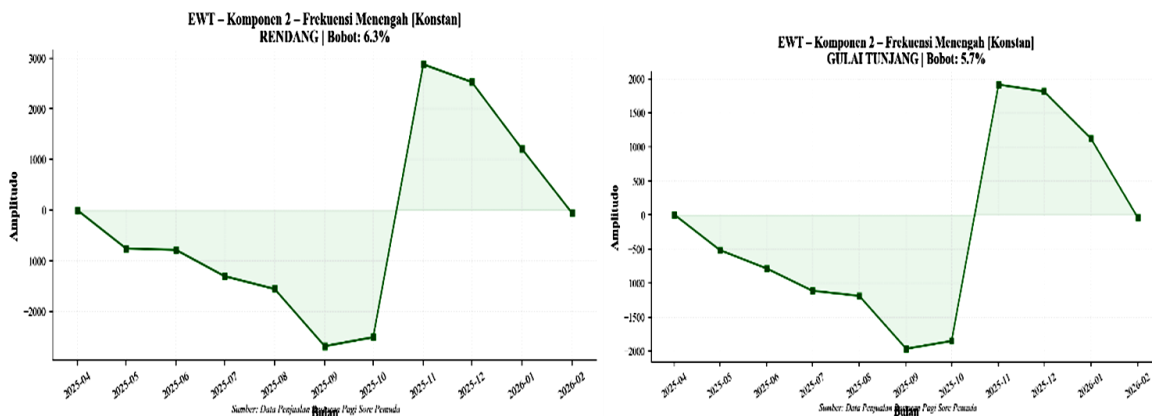
fluktuasi jangka pendek tidak memberikan kontribusi signifikan terhadap total varians data. Pola serupa juga ditemukan pada menu-menu lain, dengan Ayam Pop dan Rendang menunjukkan spektrum dengan daya tertinggi, sementara Ayam Bakar dan Gulai Cincang Sapi memiliki spektrum dengan daya lebih rendah, konsisten dengan skala penjualan masing-masing menu. Komponen EWT 1 (Tren) - Contoh: Ayam Pop dan Rendang yang disajikan pada Gambar 3.



Gambar 3. Komponen EWT 1 (Tren) - Contoh: Ayam Pop dan Rendang

Komponen EWT 1 merepresentasikan tren jangka panjang setelah eliminasi komponen frekuensi menengah dan tinggi. Gambar 3 menunjukkan perbandingan komponen tren Ayam Pop dan Rendang hasil dekomposisi EWT. Ayam Pop menunjukkan peningkatan konsisten dari 3.200 porsi (April 2025) menjadi 11.800 porsi (November 2025), kemudian relatif stagnan hingga Desember (11.200), sebelum menurun menjadi 8.700 porsi pada Februari 2026. Rendang menunjukkan pola serupa dengan

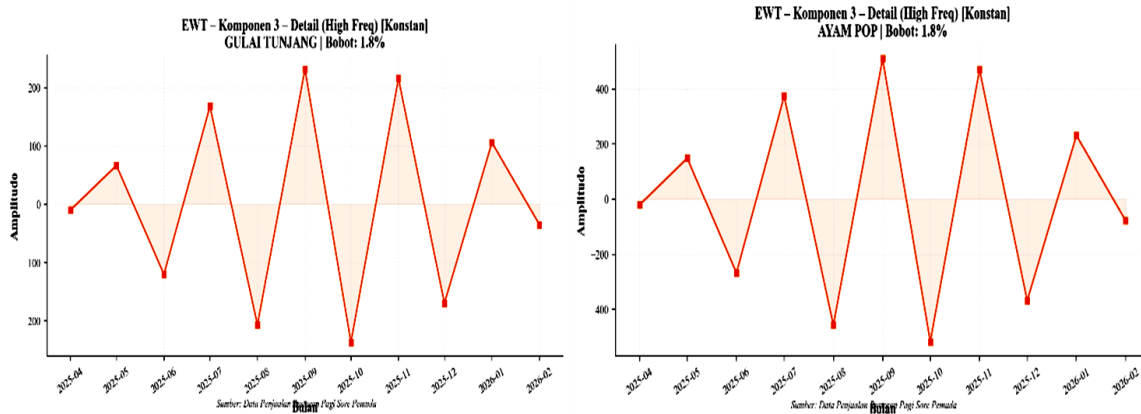
peningkatan dari 1.800 porsi (April) menjadi 7.800 porsi (November), kemudian menurun menjadi 6.300 porsi pada Februari 2026. Pola ini mengkonfirmasi hasil dekomposisi klasik pada Subbab 4.4, namun dengan kurva yang lebih halus karena eliminasi komponen *noise*. Kehalusan kurva ini diharapkan dapat meningkatkan kemampuan model dalam menangkap pola fundamental data. Komponen EWT 2 (Siklik/Musiman)-Contoh: Gulai Tunjang dan Rendang yang disajikan pada Gambar 4.



Gambar 4. Komponen EWT 2 (Siklik/Musiman) - Contoh: Gulai Tunjang dan Rendang

Komponen EWT 2 menangkap pola siklik dan musiman (frekuensi menengah) yang tidak tercakup dalam komponen tren. Gambar 4 menyajikan contoh komponen siklik untuk Gulai Tunjang dan Rendang. Gulai Tunjang menunjukkan fluktuasi dengan amplitudo kecil pada awal periode (0 hingga 1.200), kemudian melonjak drastis pada November 2025 (1.900) dan Desember (1.850) sebelum menurun. Rendang menunjukkan pola serupa dengan lonjakan pada November 2025 (2.900) dan Desember (2.600). Pola ini mengindikasikan adanya perubahan struktural

pada periode November-Desember 2025 yang ditangkap sebagai komponen siklik, kemungkinan terkait dengan faktor eksternal seperti musim liburan atau promo khusus. Keberadaan komponen siklik yang signifikan ini menjelaskan mengapa model yang hanya mengandalkan tren linier (seperti Holt-Winters standar) menghasilkan akurasi rendah, sementara model berbasis EWT yang memisahkan komponen ini dapat menangkap pola dengan lebih baik. Komponen EWT 3 (*Noise*) yang disajikan pada Gambar 5.



Gambar 5. Komponen EWT 3 (Noise)

Komponen EWT 3 merepresentasikan *noise* acak berfrekuensi tinggi yang akan dieliminasi dalam rekonstruksi sinyal. Gambar 5 menunjukkan komponen *noise* untuk seluruh menu dengan amplitudo yang relatif kecil dibanding komponen tren dan siklik. Ayam Pop memiliki *noise* dengan amplitudo maksimum sekitar 500, Gulai Tunjang sekitar 230, Rendang sekitar 340, sementara menu dengan skala kecil seperti Ayam Bakar hanya memiliki *noise* maksimum 40. Pola *noise* yang acak tanpa struktur sistematis mengkonfirmasi bahwa komponen ini layak untuk dieliminasi. Eliminasi komponen *noise* diharapkan dapat meningkatkan akurasi peramalan dengan mengurangi variabilitas yang tidak sistematis, sebagaimana akan dibuktikan pada Subbab 4.6 melalui perbandingan kinerja model dengan dan tanpa EWT.

3.6. Evaluasi Kinerja Model Peramalan

Evaluasi kinerja model peramalan dilakukan dengan membandingkan empat metode: Prophet, Holt-Winters, EWT-Prophet (hybrid), dan EWT-HoltWinters (hybrid). Pengukuran akurasi menggunakan metrik utama *Mean Absolute Percentage Error* (MAPE) yang merepresentasikan persentase kesalahan peramalan relatif terhadap nilai aktual. MAPE dipilih karena memberikan interpretasi yang intuitif dan memungkinkan perbandingan antar menu dengan skala penjualan berbeda. Evaluasi dilakukan pada data uji (*test set*) sebanyak dua bulan terakhir untuk setiap menu, dengan total sembilan menu yang dianalisis. Tujuan evaluasi adalah untuk mengidentifikasi metode dengan kinerja terbaik serta mengukur efektivitas integrasi EWT dalam meningkatkan akurasi peramalan. Ringkasan MAPE per Menu dan Model yang disajikan pada Tabel 8.

Tabel 8. Ringkasan MAPE per Menu dan Model

| Menu | Prophet (%) | Holt-Winters (%) | EWT-Prophet (%) | EWT-HoltWinters (%) |
|--------------------|-------------|------------------|-----------------|---------------------|
| Ayam Bakar | 19,35 | 100,80 | 16,77 | 30,16 |
| Ayam Goreng | 12,44 | 92,66 | 12,33 | 36,60 |
| Ayam Pop | 15,02 | 84,97 | 14,18 | 27,10 |
| Gulai Cincang Sapi | 9,99 | 84,08 | 9,25 | 25,69 |
| Gulai Otak | 11,85 | 32,84 | 11,02 | 26,59 |
| Gulai Tunjang | 12,72 | 87,54 | 12,08 | 20,48 |
| Rendang | 12,04 | 93,91 | 11,25 | 24,80 |
| Telur Barendo | 19,18 | 100,8 | 18,10 | 40,88 |
| Ubi Tumbuk | 27,20 | 137,88 | 21,22 | 44,50 |

Berdasarkan Tabel 8, terlihat bahwa model berbasis EWT secara konsisten mengungguli model standar. EWT-Prophet menjadi model dengan kinerja terbaik untuk seluruh sembilan menu. Gulai Cincang Sapi mencatatkan MAPE terendah dengan EWT-Prophet (9,25%), masuk kategori "Sangat Baik" (<10%). Ayam Goreng, Gulai Otak, Gulai Tunjang, dan Rendang berada dalam kategori "Baik" (10-20%) dengan MAPE berkisar 11,02% hingga 12,33%. Ayam Pop (14,18%), Ayam Bakar (16,77%), dan Telur Barendo (18,10%) juga masuk kategori "Baik". Ubi Tumbuk menjadi satu-satunya menu dengan kategori "Cukup" (21,22%), mengindikasikan kompleksitas data yang lebih tinggi.

Sebaliknya, Holt-Winters standar menunjukkan kinerja terburuk dengan MAPE mencapai 137,88% untuk Ubi Tumbuk dan rata-rata di atas 80% untuk sebagian besar menu. Temuan ini mengkonfirmasi bahwa metode pemulusan eksponensial klasik tidak mampu menangkap pola kompleks dalam data penjualan. Optimalisasi pada kinerja operasional menjadi fondasi utama bagi keberlanjutan organisasi dalam mencapai target kinerja keuangan, performa penjualan, serta kepuasan pelanggan secara menyeluruh [27]. Peringkat Kinerja Model Berdasarkan MAPE Rata-rata yang disajikan pada Tabel 9.

Tabel 9. Peringkat Kinerja Model Berdasarkan MAPE Rata-rata

| Rank | Model | MAPE Rata-Rata (%) | Standar Deviasi MAPE | Kategori MAPE |
|------|-----------------|--------------------|----------------------|---------------|
| 1 | EWT-Prophet | 14,02 | 3,91 | Baik |
| 2 | Prophet | 15,53 | 5,45 | Baik |
| 3 | EWT-HoltWinters | 30,75 | 8,09 | Cukup |
| 4 | Holt-Winters | 90,61 | 27,11 | Kurang |

Tabel 9 menyajikan peringkat kinerja model berdasarkan rata-rata MAPE seluruh menu. EWT-Prophet menempati peringkat pertama dengan MAPE rata-rata 14,02%, diikuti Prophet standar (15,53%), EWT-HoltWinters (30,75%), dan Holt-Winters (90,61%). Integrasi EWT berhasil menurunkan MAPE Prophet sebesar 1,51 poin persentase (dari 15,53% menjadi 14,02%), dan menurunkan MAPE Holt-Winters secara dramatis sebesar 59,86 poin persentase (dari 90,61% menjadi 30,75%). Peningkatan paling signifikan terjadi pada menu dengan volatilitas tinggi seperti Ayam Pop, di mana EWT-Prophet mencapai MAPE 14,18% dibanding Holt-Winters 84,97%. Standar deviasi MAPE EWT-Prophet (3,91) juga lebih rendah dibanding Prophet (5,45), mengindikasikan konsistensi kinerja yang lebih baik antar menu. Keberhasilan EWT-Prophet dapat dijelaskan melalui kemampuannya memisahkan komponen *noise* (frekuensi tinggi) yang telah diidentifikasi pada Subbab 4.5, sehingga Prophet hanya perlu meramalkan komponen tren dan siklik yang lebih terstruktur. Terlihat jelas bahwa Holt-Winters memiliki MAPE tertinggi (90,61%), diikuti EWT-HoltWinters (30,75%), Prophet (15,53%), dan EWT-Prophet (14,02%). Pola ini mengkonfirmasi efektivitas EWT dalam meningkatkan akurasi, terutama ketika dikombinasikan dengan Prophet yang secara inherent lebih fleksibel dalam menangani pola non-linier.

Sebaliknya, Holt-Winters yang mengandalkan pemulusan eksponensial gagal menangkap lonjakan tajam, menghasilkan error yang sangat besar. Temuan ini sejalan dengan penelitian sebelumnya yang menunjukkan bahwa metode *hybrid* berbasis dekomposisi sinyal mampu meningkatkan akurasi peramalan data deret waktu dengan volatilitas tinggi, dimana kombinasi tersebut akan berdampak signifikan dan maksimal dengan membangun integrasi orientasi kewirausahaan (EO) dan TQM menjadi sebuah strategi yang sangat penting bagi organisasi untuk memperluas pasar dan mengelola risiko yang mungkin muncul, yang pada akhirnya membangun kinerja bisnis yang berkelanjutan [28].

3.7 Hasil Peramalan Tiga Bulan ke Depan

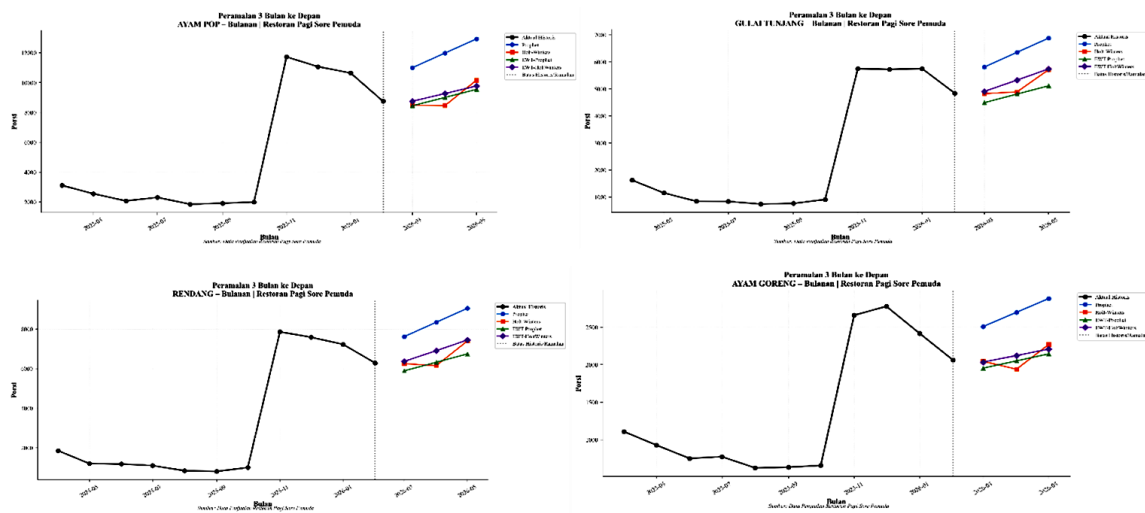
Setelah mengevaluasi kinerja model, langkah selanjutnya adalah menghasilkan peramalan penjualan untuk tiga bulan ke depan (Maret-Mei 2026) menggunakan model terbaik, yaitu EWT-Prophet. Peramalan ini bertujuan untuk memberikan proyeksi yang akurat bagi manajemen restoran dalam perencanaan persediaan, produksi, dan strategi pemasaran. Hasil peramalan juga dibandingkan dengan tiga bulan historis terakhir (Desember 2025-Februari 2026) untuk mengidentifikasi pola perubahan yang diharapkan. Total Peramalan 3 Bulan vs Historis 3 Bulan Terakhir yang disajikan pada Tabel 10.

Tabel 10. Total Peramalan 3 Bulan vs Historis 3 Bulan Terakhir

| Menu | Historis | Prophet | Holt-Winters | EWT-Prophet | EWT-HoltWinters |
|--------------------|----------|---------|--------------|-------------|-----------------|
| Ayam Bakar | 2.204 | 2.469 | 2.451 | 1.688 | 1.722 |
| Ayam Goreng | 7.255 | 8.087 | 6.254 | 6.149 | 6.366 |
| Ayam Pop | 30.480 | 35.932 | 27.121 | 27.018 | 27.812 |
| Gulai Cincang Sapi | 2.655 | 3.129 | 2.382 | 2.482 | 2.646 |
| Gulai Otak | 5.323 | 6.465 | 4.954 | 4.987 | 5.323 |
| Gulai Tunjang | 16.328 | 19.059 | 15.439 | 14.429 | 15.988 |
| Rendang | 21.098 | 25.016 | 19.804 | 18.958 | 20.727 |
| Telur Barendo | 12.389 | 14.677 | 10.102 | 10.622 | 10.680 |
| Ubi Tumbuk | 6.151 | 7.113 | 7.063 | 4.476 | 4.517 |

Tabel 10 menyajikan perbandingan total penjualan tiga bulan ke depan hasil peramalan EWT-Prophet versus tiga bulan terakhir historis. Pola yang menarik terlihat: seluruh menu diproyeksikan mengalami penurunan dibanding periode Desember-Februari, dengan rentang penurunan 6,3% hingga 27,2%. Penurunan terdalam diproyeksikan terjadi pada Ubi Tumbuk (-27,2%), Ayam Bakar (-23,4%), dan Telur Barendo (-14,3%). Sebaliknya, Gulai Cincang Sapi dan Gulai Otak hanya mengalami penurunan marginal (masing-masing -6,5% dan -6,3%). Pola ini mengindikasikan bahwa lonjakan penjualan pada November-Desember 2025 bersifat

sementara dan tidak berlanjut, kemungkinan terkait faktor musiman liburan akhir tahun. Menariknya, model Prophet tanpa EWT justru memproyeksikan kenaikan untuk seluruh menu (+11,5% hingga +21,5%), mengindikasikan bahwa Prophet standar terlalu sensitif terhadap lonjakan historis dan gagal menangkap sifat sementara dari lonjakan tersebut. Hal ini menegaskan pentingnya pendekatan *hybrid* EWT-Prophet yang lebih konservatif dan realistis. Peramalan 3 Bulan EWT-Prophet per Menu yang disajikan pada Gambar 7.



Gambar 7. Peramalan 3 Bulan EWT-Prophet per Menu

Gambar 7 menyajikan contoh visualisasi peramalan EWT-Prophet untuk tiga menu utama. Ayam Pop diproyeksikan menurun dari 8.500 porsi (Februari 2026) menjadi 8.454 porsi (Maret), kemudian meningkat menjadi 9.012 porsi (April) dan 9.551 porsi (Mei)—pola yang menunjukkan sedikit peningkatan setelah Maret. Gulai Tunjang diproyeksikan menurun dari 4.800 porsi (Februari) menjadi 4.495 porsi (Maret), kemudian meningkat bertahap ke 4.813 porsi (April) dan 5.121 porsi (Mei). Rendang menunjukkan

pola serupa: dari 6.300 porsi (Februari) menjadi 5.889 porsi (Maret), 6.324 porsi (April), dan 6.745 porsi (Mei). Pola penurunan di Maret diikuti peningkatan bertahap mencerminkan komponen musiman yang telah diidentifikasi pada Subbab 4.4, di mana Maret cenderung memiliki nilai musiman negatif, sementara April-Mei mulai meningkat. Detail Peramalan Bulanan EWT-Prophet Maret-Mei 2026 yang disajikan pada Tabel 11.

Tabel 11. Detail Peramalan Bulanan EWT-Prophet Maret-Mei 2026

| Menu | Maret 2026 | April 2026 | Mei 2026 | Total 3 Bulan |
|--------------------|------------|------------|----------|---------------|
| Ayam Bakar | 557 | 563 | 569 | 1.688 |
| Ayam Goreng | 1.954 | 2.051 | 2.145 | 6.149 |
| Ayam Pop | 8.454 | 9.012 | 9.551 | 27.018 |
| Gulai Cincang Sapi | 777 | 828 | 877 | 2.482 |
| Gulai Otak | 1.539 | 1.664 | 1.784 | 4.987 |
| Gulai Tunjang | 4.495 | 4.813 | 5.121 | 14.429 |
| Rendang | 5.889 | 6.324 | 6.745 | 18.958 |
| Telur Barendo | 3.350 | 3.543 | 3.729 | 10.622 |
| Ubi Tumbuk | 1.472 | 1.492 | 1.512 | 4.476 |

Tabel 11 menyajikan detail peramalan bulanan EWT-Prophet. Seluruh menu menunjukkan tren peningkatan dari Maret ke Mei, dengan tingkat pertumbuhan bervariasi. Ayam Pop diproyeksikan tetap menjadi kontributor terbesar dengan total 27.018 porsi selama tiga bulan (sekitar 36,5% dari total sembilan menu), diikuti Rendang (18.958 porsi atau 25,6%) dan Gulai Tunjang (14.429 porsi atau 19,5%). Ketiga menu ini berkontribusi lebih dari 80% total penjualan yang diproyeksikan. Di sisi lain, Ayam Bakar (1.688 porsi) dan Gulai Cincang Sapi (2.482 porsi) tetap menjadi menu dengan permintaan terendah. Pola pertumbuhan bulanan menunjukkan bahwa setelah koreksi di Maret, permintaan kembali meningkat memasuki pertengahan tahun, konsisten dengan pola musiman positif pada April-Mei yang teridentifikasi dalam dekomposisi.

Implikasi praktis dari temuan ini bagi manajemen Restoran Pagi Sore Pemuda adalah perlunya penyesuaian strategi persediaan dan produksi. Hal ini

menjadi sangat urgensial karena keputusan pembelian tidak hanya dipengaruhi oleh promosi dan rasa, tetapi juga oleh hubungan emosional antara penjual dan pembeli serta nilai tambah yang dirasakan konsumen salah satunya yakni terkait pelayanan pada persediaan dan produksi yang optimal [29]. Pertama, persediaan bahan baku perlu dikurangi pada Maret 2026 mengingat proyeksi penurunan dibanding periode sebelumnya. Kedua, persediaan perlu ditingkatkan kembali secara bertahap pada April-Mei 2026 seiring proyeksi peningkatan permintaan. Ketiga, fokus utama pengadaan bahan baku dan tenaga kerja tetap harus diarahkan pada tiga menu *best-seller* (Ayam Pop, Rendang, Gulai Tunjang) yang berkontribusi lebih dari 80% total penjualan. Keempat, menu dengan proyeksi penurunan tajam seperti Ubi Tumbuk (-27,2%) perlu dievaluasi ulang dari sisi efisiensi produksi atau bahkan dipertimbangkan untuk diganti dengan menu baru yang lebih potensial. Dengan menerapkan rekomendasi ini,

restoran dapat mengoptimalkan manajemen rantai pasok, mengurangi risiko kelebihan persediaan, dan meningkatkan profitabilitas operasional.

3.8. Pola Permintaan Menu *Fast Moving*

Berdasarkan analisis pola permintaan sembilan menu di Restoran Pagi Sore Pemuda, dapat diidentifikasi tiga kategori tren. Pertama, menu dengan tren meningkat signifikan yaitu Ayam Pop, Rendang, dan Gulai Tunjang yang menunjukkan peningkatan dramatis pada periode September 2025 hingga Februari 2026 dengan koefisien variasi sangat tinggi (78,89%-92,59%), mengindikasikan variabilitas permintaan ekstrem dengan lonjakan tajam pada November-Desember 2025. Kedua, menu dengan tren meningkat moderat yaitu Ayam Goreng, Telur Barendo, dan Gulai Otak dengan tren akhir 3.000-3.900 porsi dan CV% menengah (63,08%-74,68%). Ketiga, menu dengan tren stabil yaitu Ayam Bakar, Gulai Cincang Sapi, dan Ubi Tumbuk dengan CV% terendah (47,37%-60,13%), di mana Gulai Cincang Sapi mencatatkan MAPE terendah (9,25%) yang mengonfirmasi stabilitas polanya. Komponen musiman terdeteksi dengan pola konsisten yaitu nilai positif pada Juni dan September, negatif pada Juli, November, dan Februari, mengindikasikan siklus permintaan berulang setiap 3-4 bulan.

3.9. Kinerja Metode Peramalan untuk Data Terbatas

Hasil penelitian mengkonfirmasi bahwa metode Holt-Winters standar justru menunjukkan kinerja terburuk dengan MAPE rata-rata 90,61%, mengindikasikan ketidakmampuannya menangkap kompleksitas data berfluktuasi tinggi. Sebaliknya, metode Prophet yang lebih fleksibel menunjukkan kinerja jauh lebih baik dengan MAPE rata-rata 15,53% (kategori Baik). Integrasi EWT dengan Prophet (EWT-Prophet) berhasil menurunkan MAPE menjadi 14,02%, dengan peningkatan paling signifikan pada menu volatilitas tinggi seperti Ayam Pop (penurunan dari 15,02% menjadi 14,18%). Keberhasilan EWT-Prophet terletak pada kemampuannya memisahkan komponen *noise* sehingga model hanya meramalkan komponen tren dan siklik yang lebih terstruktur. Gulai Otak yang teridentifikasi tidak stasioner tetap dapat diramalkan dengan baik (MAPE 11,02%), membuktikan efektivitas EWT untuk data dengan struktur spektral kompleks.

3.10. Implikasi Manajerial untuk Pengendalian Persediaan

Hasil peramalan memberikan landasan kuantitatif bagi manajemen dalam mengoptimalkan pengendalian persediaan. Strategi pengadaan perlu disesuaikan dengan tingkat akurasi peramalan: menu dengan akurasi sangat baik seperti Gulai Cincang Sapi (MAPE 9,25%) dapat menggunakan hasil peramalan secara langsung, sementara menu dengan akurasi cukup seperti Ubi Tumbuk (MAPE 21,22%) perlu dikombinasikan dengan *judgmental forecasting*.

Optimalisasi tingkat persediaan dilakukan berdasarkan proyeksi penurunan: menu dengan penurunan minimal (Gulai Cincang Sapi dan Gulai Otak, -6,3% hingga -6,5%) memerlukan penyesuaian moderat, menu dengan penurunan moderat (Ayam Pop, Gulai Tunjang, Rendang, Ayam Goreng, Telur Barendo, -10,1% hingga -15,2%) memerlukan pengurangan 10-15%, dan menu dengan penurunan tajam (Ubi Tumbuk -27,2%, Ayam Bakar -23,4%) memerlukan pengurangan signifikan.

Penerapan peramalan akurat berpotensi menekan *food waste* melalui pengurangan stok menu dengan proyeksi penurunan tajam, sekaligus menghindari kekurangan stok pada menu utama. Ketiga menu utama (Ayam Pop, Rendang, Gulai Tunjang) yang berkontribusi lebih dari 80% total penjualan (60.405 porsi dari 74.799 porsi) menjadi prioritas utama dalam pengadaan bahan baku dan negosiasi dengan pemasok. Manajemen perlu melakukan pembaruan peramalan secara periodik (bulanan) dengan menginkorporasikan data terbaru, serta mengintegrasikan hasil peramalan ke dalam sistem informasi manajemen untuk otomatisasi perhitungan kebutuhan bahan baku. Menu Ubi Tumbuk dengan proyeksi penurunan tajam dan MAPE tertinggi perlu dievaluasi ulang, dengan opsi mengurangi frekuensi produksi, melakukan promosi, atau mempertimbangkan penggantian menu baru yang lebih potensial berdasarkan analisis profitabilitas.

4. Kesimpulan

Manajemen Restoran Pagi Sore Pemuda disarankan untuk mengadopsi metode EWT-Prophet sebagai alat *monitoring* permintaan bulanan dan dasar pengambilan keputusan pengadaan bahan baku. Strategi pengadaan perlu disesuaikan dengan proyeksi masing-masing menu yaitu pengurangan volume signifikan untuk menu dengan penurunan tajam (Ubi Tumbuk dan Ayam Bakar), pengurangan bertahap 10-15% untuk menu dengan penurunan moderat (Ayam Pop, Rendang, Gulai Tunjang, Ayam Goreng, Telur Barendo), serta pemeliharaan persediaan dengan penyesuaian minimal untuk menu stabil (Gulai Cincang Sapi dan Gulai Otak). Ketiga menu utama (Ayam Pop, Rendang, Gulai Tunjang) harus menjadi prioritas utama dalam pengadaan bahan baku dan negosiasi dengan pemasok. Peramalan perlu diperbarui secara berkala setiap bulan dengan menginkorporasikan data penjualan terbaru untuk menjaga akurasi prediksi. Untuk penelitian selanjutnya, disarankan memperpanjang rentang data hingga minimal 24 bulan agar pola musiman tahunan dapat diidentifikasi, serta menambahkan variabel eksternal seperti periode promosi dan hari libur nasional untuk meningkatkan akurasi peramalan.

Daftar Rujukan

- [1] Petropoulos, F., Apiletti, D., Assimakopoulos, V., Babai, M. Z., Barrow, D. K., Taieb, S. B. & Ziel, F. (2022). *Forecasting*:

- theory and practice. *International Journal of forecasting*, 38(3), 705-871. <https://doi.org/10.1016/j.ijforecast.2021.11.001>.
- [2] Green, K. C., Graefe, A., & Armstrong, J. S. (2025). *Forecasting principles*. In *International encyclopedia of statistical science* (pp. 968-976). Berlin, Heidelberg: Springer Berlin Heidelberg.
- [3] Dolgui, A., & Ivanov, D. (2023). Metaverse supply chain and operations management. *International Journal of Production Research*, 61(23), 8179-8191. <https://doi.org/10.1080/00207543.2023.2240900>.
- [4] Amidi, A., Darvishmoghaddam, E., Razmfarsa, A., & Othman, R. B. (2022). Impact of five important factors on restaurant performance and hospitality management: An empirical analysis of technological innovation. *Future Technology*, 1(2), 1-17. <https://doi.org/10.55670/fpl.futech.1.2.1>.
- [5] Rodrigues, M., Migueis, V., Freitas, S., & Machado, T. (2024). Machine learning models for short-term demand forecasting in food catering services: A solution to reduce food waste. *Journal of cleaner production*, 435, 140265. <https://doi.org/10.1016/j.jclepro.2023.140265>.
- [6] Tadayonrad, Y., & Ndiaye, A. B. (2023). A new key performance indicator model for demand forecasting in inventory management considering supply chain reliability and seasonality. *Supply chain analytics*, 3, 100026. <https://doi.org/10.1016/j.sca.2023.100026>.
- [7] Tanizaki, T., Hoshino, T., & Takenaka, T. (2020). Predicting food demand in restaurants using deep learning. *Procedia CIRP*, 88, 560-565. <https://doi.org/10.1016/j.procir.2020.05.101>.
- [8] Rayalu, G. M., & Kumar, R. S. (2023). Predictive analytics for restaurant inventory management: A machine learning approach. *International Journal of Production Research*, 61(15), 5012-5031. <https://doi.org/10.1109/ICACTE62428.2024.10871751>.
- [9] Alex, M. A. H., & Rahmawati, N. (2023). Application of the single moving average, weighted moving average and exponential smoothing methods for forecasting demand at boy delivery. *Tibuna*, 6(1), 32-37. <https://doi.org/10.36456/tibuna.6.1.6442.32-37>.
- [10] Shi, Y. (2022). Forecasting mortality rates with the penalized exponential smoothing state space model. *Journal of the Operational Research Society*, 73(5), 955-968. <https://doi.org/10.1080/01605682.2021.1892465>.
- [11] Ofosu-Asare, Y. (2024). Developing classroom ICT teaching techniques, principles and practice for teachers in rural Ghana without access to computers or internet: a framework based on literature review. *The International Journal of Information and Learning Technology*, 41(3), 262-279. <https://doi.org/10.1108/IJILT-04-2023-0045>.
- [12] Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679-688. <https://doi.org/10.1016/j.ijforecast.2006.03.001>
- [13] Huang, N. E., et al. (1998). The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society A*, 454(1971), 903-995. <https://doi.org/10.1098/rspa.1998.0193>
- [14] Wen, X., & Li, W. (2023). Time series prediction based on LSTM-attention-LSTM model. *IEEE access*, 11, 48322-48331. <https://doi.org/10.1109/ACCESS.2023.3276628>.
- [15] Taylor, S. J., & Letham, B. (2018). Forecasting at scale. *The American Statistician*, 72(1), 37-45. <https://doi.org/10.7287/peerj.preprints.3190v2>
- [16] Gilles, J. (2013). Empirical wavelet transform. *IEEE Transactions on Signal Processing*, 61(16), 3999-4010. <https://doi.org/10.1109/TSP.2013.2265222>
- [17] Su, T., Li, R., Liu, B., Liang, X., Yang, X., & Zhou, Y. (2025). Anomaly detection and risk early warning system for financial time series based on the WaveLST-Trans model. *ICCK Transactions on Emerging Topics in Artificial Intelligence*, 2(2), 68-80. <https://doi.org/10.62762/TETAI.2025.191759>.
- [18] Tanizaki, T., Hoshino, T., Shimmura, T., & Takenaka, T. (2019). Demand forecasting in restaurants using machine learning and statistical analysis. *Procedia CIRP*, 79, 679-683. <https://doi.org/10.1016/j.procir.2019.02.042>.
- [19] Thomakos, D. D., Litsiou, K., & Nikolopoulos, K. (2023). Forecasting with limited data: How good can we get?. *International Journal of Forecasting*, 39(3), 1074-1089. <https://doi.org/10.1016/j.ijforecast.2025.08.005>
- [20] Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2020). The M4 competition: 100,000 time series and 61 forecasting methods. *International Journal of Forecasting*, 36(1), 54-74. <https://doi.org/10.1016/j.ijforecast.2019.04.014>
- [21] Bi, Y., Sun, S., & Hao, Y. (2019). Empirical wavelet transform-based stock price prediction model using long short-term memory. *IEEE Access*, 7, 117065-117074. <https://doi.org/10.1007/s42979-023-02100-9>
- [22] Petropoulos, F., Apiletti, D., Assimakopoulos, V., et al. (2022). Forecasting: Theory and practice. *International Journal of Forecasting*, 38(3), 705-871. <https://doi.org/10.1016/j.ijforecast.2021.11.001>
- [23] Masa, A. P. A., Tobing, C. F., & Irsyad, A. (2026). Perbandingan Metode Holt Winters Exponential Smoothing Dan Arima Pada Peramalan Jumlah Wisatawan Di Kota Samarinda. *Jurnal Informatika dan Teknik Elektro Terapan*, 14(1). <https://doi.org/10.23960/jitet.v14i1.9002>.
- [24] Miron, S., Flamant, J., Le Bihan, N., Chainais, P., & Brie, D. (2023). Quaternions in signal and image processing: A comprehensive and objective overview. *IEEE Signal Processing Magazine*, 40(6), 26-40. <https://doi.org/10.1109/MSP.2023.3278071>.
- [25] Liu, H., Mi, X., & Li, Y. (2016). Smart multi-step deep learning model for wind speed forecasting based on variational mode decomposition, singular spectrum analysis, LSTM network and ELM. *Energy Conversion and Management*, 159, 54-64. <https://doi.org/10.1016/j.enconman.2018.01.010>.
- [26] Kaur, J., Parmar, K. S., & Singh, S. (2023). Autoregressive models in environmental forecasting time series: a theoretical and application review. *Environmental Science and Pollution Research*, 30(8), 19617-19641. <https://doi.org/10.1007/s11356-023-25148-9>.
- [27] Sutrisno, T. F. C. W. (2019). Relationship between Total Quality Management Element, Operational Performance and Organizational Performance in Food Production SMEs. *Jurnal Aplikasi Manajemen*, 17(2), 285-294. <https://doi.org/10.21776/ub.jam.2019.017.02.11>.
- [28] Sutrisno, T. F. C. W., Effendy, J. A., & Prathivi, M. D. G. (2019). Hybrid Strategy Study: The Role of Entrepreneurial Orientation and Total Quality Management in MSMES. *Jurnal Manajemen & Kewirausahaan (JMDK)*, 7(2), 124-131. <https://doi.org/10.26905/jmdk.v7i2.3057>.
- [29] Sutrisno, T. F. C. W., Gosal, G. G., & Hernandez, S. F. (2020). The Role of Product Quality and Price Perception in affecting Purchase Decision (Study on Milkmo Product). *Primanomics: Jurnal Ekonomi dan Bisnis*, 18(3), 1-7. <https://doi.org/10.31253/pe.v18i3.398>.