PERAMALAN PENJUALAN PER JAM PADA *MARKETPLACE* MENGGUNAKAN MODEL *HYBRID* SARIMAX DAN XGBOOST

[1]Helen Nur Septiananda, [2]Ulfa Siti Nuraini*

Program Studi Sains Data, Universitas Negeri Surabaya

Jl. Ketintang Wiyata, Ketintang, Kec. Gayungan, Surabaya, Jawa Timur 60231
[1] helen.23231@mhs.unesa.ac.id, [2] ulfanuraini@unesa.ac.id

Abstract

Marketplace growth increases the need for accurate sales forecasting that captures temporal patterns, seasonality, and external factors. This study compares two mechanisms for integrating SARIMAX and XGBoost to forecast hourly sales, using data from January 2023 to October 2024 with the exogenous variables Sum of Users and Twin Date. Scenario 1 (Sequential Hybrid): XGBoost predicts SARIMAX residuals from exogenous variables and residual lags, and the result is added to SARIMAX predictions. Scenario 2 (Ensemble Parallel Hybrid): XGBoost is trained separately on sales using both exogenous variables, and its predictions are averaged with SARIMAX. Both use four SARIMAX models with seasonal periods of 12 and 24 hours and are compared with standalone SARIMAX and XGBoost. Evaluation for August–October 2024 shows that Scenario 2 with a 24-hour seasonal period gives the lowest RMSE, while standalone XGBoost gives the lowest MAE and Scenario 2 with a 12-hour seasonal period gives the lowest MAPE. Scenario 1 only improves base models with a 12-hour period and worsens those with a 24-hour period. These results show that the effectiveness of hybrid models depends on the integration mechanism, the quality of the base models, and the evaluation metrics used.

Keywords : *Hybrid Model, Marketplace, SARIMAX, Time Series Forecasting, XGBoost*

Abstrak

Pertumbuhan transaksi pada platform *marketplace* meningkatkan kebutuhan akan metode peramalan penjualan yang akurat dan adaptif terhadap pola temporal, musiman, serta faktor eksternal. Penelitian ini membandingkan dua mekanisme integrasi SARIMAX dan XGBoost untuk peramalan nilai penjualan per jam menggunakan data Januari 2023 hingga Oktober 2024 dengan variabel eksogen Jumlah Pengguna dan Tanggal Kembar. Skenario 1 (*Hybrid* Sekuensial): XGBoost dilatih memprediksi residual SARIMAX menggunakan variabel eksogen dan *lag* residual, lalu *output*-nya dijumlahkan dengan prediksi SARIMAX. Skenario 2 (*Hybrid Ensemble* Paralel): XGBoost dan SARIMAX dilatih terpisah pada nilai penjualan dengan kedua variabel eksogen, kemudian hasil prediksinya dirata-rata. Keduanya dibangun pada empat model SARIMAX dengan periode musiman 12 dan 24 jam, serta dibandingkan dengan SARIMAX dan XGBoost tunggal. Evaluasi pada periode Agustus–Oktober 2024 menunjukkan Skenario 2 dengan periode musiman 24 jam memberikan RMSE terendah, sedangkan XGBoost tunggal memberikan MAE terendah dan Skenario 2 dengan periode musiman 12 jam memberikan MAPE terendah. Skenario 1 hanya memperbaiki model dasar dengan periode 12 jam dan memperburuk model dasar dengan periode 24 jam. Hasil ini menunjukkan bahwa efektivitas model *hybrid* berkaitan dengan mekanisme integrasi, kualitas model dasar, dan metrik evaluasi yang digunakan.

Kata kunci : *Hybrid Model, Marketplace*, Peramalan Deret Waktu, SARIMAX, XGBoost

1. PENDAHULUAN

Perkembangan teknologi telah menggeser pola transaksi masyarakat dari tatap muka menjadi berbasis daring atau *online*. Jangkauan pasar yang luas serta biaya operasional yang efisien menjadikan pasar digital sebagai pilihan utama para pelaku usaha. Dua platform

marketplace terbesar di Indonesia, yaitu Shopee dan Tokopedia, mencatat jutaan transaksi setiap harinya. Aktivitas ini menghasilkan data transaksional bervolume tinggi yang dipengaruhi oleh tren makroekonomi, ulasan produk, dan persepsi publik [1]. Data tersebut merefleksikan perilaku konsumen yang krusial sebagai fondasi peramalan penjualan, pengelolaan persediaan, penyesuaian operasional, serta penyusunan strategi promosi [2]. Ketidaktepatan peramalan penjualan berisiko menghambat efisiensi operasional dan pertumbuhan bisnis, sehingga pengembangan model peramalan yang akurat pada data transaksional *marketplace* menjadi sangat krusial.

Permasalahan utama dalam peramalan tersebut terletak pada kompleksitas karakteristik data transaksional *marketplace* berfrekuensi tinggi. Data ini tidak hanya menunjukkan pola musiman berbasis Kalender yang kuat, seperti tanggal kembar dan Harbolnas, tetapi juga memuat lonjakan sporadis di luar periode promosi. Fenomena ini menyebabkan satu model sering kali tidak mampu merepresentasikan seluruh karakteristik data secara optimal [3]. Oleh karena itu, pemilihan model yang tepat merupakan kunci untuk menghasilkan prediksi yang akurat.

Model deret waktu statistik telah lama dimanfaatkan dalam peramalan penjualan. Metode *AutoRegressive Integrated Moving Average* (ARIMA), misalnya, mampu memberikan prediksi akurat pada sistem yang dinamis. Namun, ARIMA memiliki keterbatasan karena tidak mampu mengakomodasi variabel eksogen yang memengaruhi pola data, padahal penyertaan variabel eksogen dapat meningkatkan akurasi peramalan [4]. Untuk mengatasi keterbatasan ini, dikembangkan metode *AutoRegressive Integrated Moving Average with Exogenous Variables* (ARIMAX) yang selanjutnya disempurnakan menjadi *Seasonal AutoRegressive Integrated Moving Average with Exogenous Variables* (SARIMAX) guna menangkap pola musiman sekaligus variabel prediktor eksternal [5]. Keunggulan model statistik berbasis musiman diperkuat oleh temuan Thejovathi dkk. pada peramalan permintaan produk [6], serta temuan Nuraini dkk. yang menguji data transaksional *marketplace* per jam dengan variabel eksogen jumlah pengguna dan tanggal kembar [7]. Kedua studi tersebut melaporkan bahwa model statistika menghasilkan prediksi yang lebih akurat dibandingkan model *machine learning* tunggal seperti XGBoost dan LSTM pada data berpola musiman kuat. Meskipun demikian, pendekatan ini masih memiliki keterbatasan karena belum mampu menangani hubungan nonlinier yang tersisa pada data.

Pendekatan *machine learning* digunakan untuk menangani hubungan nonlinier tersebut. Extreme Gradient Boosting (XGBoost), sebuah metode berbasis *ensemble decision tree* yang dibangun secara sekuensial untuk meminimalkan eror prediksi [8], banyak diterapkan untuk mengatasi keterbatasan model statistik karena kemampuannya dalam menangkap pola nonlinier kompleks. Atanda dkk. mengaplikasikan XGBoost pada kasus peramalan penjualan dan menemukan bahwa metode ini lebih akurat dibandingkan metode statistik konvensional [9]. Selain itu, Yadav dkk. juga mengatakan bahwa XGBoost memberikan metrik hasil yang paling presisi dan berhasil mengungguli SARIMAX pada data yang digunakan [10]. Meskipun demikian, studi-studi tersebut umumnya memperlakukan XGBoost sebagai model tunggal. Padahal, efektivitas model *machine learning* pada data yang sangat fluktuaktif masih perlu dievaluasi lebih lanjut mengingat adanya risiko *overfitting*.

Penggunaan pendekatan *hybrid* yang menggabungkan model statistik dan *machine learning* didorong oleh keterbatasan model statistik tunggal dalam menangani hubungan nonlinier. Pendekatan ini didasari premis bahwa data deret waktu mengandung komponen linier dan nonlinier secara bersamaan [6]. Secara umum, terdapat dua mekanisme utama dalam mengintegrasikan kedua pendekatan tersebut. Mekanisme pertama dilakukan dengan memodelkan komponen residual dari model statistik menggunakan *machine learning*. Penerapan kombinasi *hybrid* SARIMA dan XGBoost melalui mekanisme ini terbukti menghasilkan akurasi yang lebih tinggi dibandingkan model tunggal, sebagaimana dilaporkan pada peramalan kedatangan wisatawan asing di Bandara Ngurah Rai [11], serta peramalan gempa spasiotemporal oleh Kaushal dkk. [12]. Sementara itu, mekanisme kedua dilakukan dengan mengintegrasikan hasil prediksi dari kedua model. Sebagai contoh, penelitian peramalan pembangkit listrik tenaga surya yang mengombinasikan metode statistik dan *deep learning* melalui pemrosesan agregasi prediksi terbukti mengungguli kinerja model tunggalnya [13]. Temuan lintas domain tersebut menunjukkan bahwa pendekatan *hybrid* memiliki potensi besar dalam peramalan deret waktu yang kompleks. Meskipun demikian, sejauh penelusuran penulis, studi-studi tersebut hanya menerapkan satu mekanisme integrasi pada

pasangan model tertentu dan pada domain yang berbeda dari data transaksional marketplace beresolusi per jam. Studi pada [11], misalnya, memodelkan residual SARIMA dengan XGBoost secara sekuensial menggunakan fitur eksogen berupa indikator musim dan periode pandemi, tanpa membandingkannya dengan mekanisme *ensemble*. Akibatnya, belum diketahui skema integrasi mana yang lebih efektif apabila keduanya diterapkan pada data dan model dasar yang sama, serta bagaimana kualitas model dasar SARIMAX memengaruhi efektivitas masing-masing mekanisme.

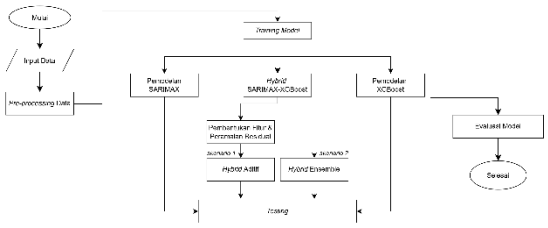
Guna mengisi kesenjangan penelitian tersebut, studi ini bertujuan membandingkan dua skema integrasi SARIMAX dan XGBoost pada data transaksional *marketplace* beresolusi per jam yang melibatkan variabel eksogen Jumlah Pengguna dan Tanggal Kembar. Skenario pertama mengadopsi pendekatan *hybrid* sekuensial (Skenario 1), yakni mengoreksi residual SARIMAX menggunakan XGBoost dengan memanfaatkan variabel eksogen serta fitur *lag* residual. Skenario kedua menerapkan *hybrid ensemble* paralel (Skenario 2) melalui penggabungan hasil prediksi SARIMAX dan XGBoost secara rata-rata sederhana. Kedua skenario ini dikonstruksi di atas empat variasi model dasar SARIMAX berperiode musiman 12 dan 24 jam, untuk kemudian dievaluasi performanya terhadap model tunggal SARIMAX dan XGBoost berdasarkan metrik RMSE, MAE, dan MAPE.

Kontribusi utama dari penelitian ini mencakup beberapa aspek penting. Pertama, penelitian ini menyajikan perbandingan empiris secara langsung antara dua skema integrasi pada kumpulan data, model dasar, dan kerangka evaluasi yang identik, suatu hal yang belum dieksplorasi pada studi-studi sebelumnya. Kedua, penelitian ini menganalisis secara mendalam sejauh mana tingkat akurasi model dasar SARIMAX memengaruhi efektivitas masing-masing skema integrasi. Ketiga, penelitian ini menjabarkan prosedur koreksi residual secara transparan dan sistematis, meliputi kriteria seleksi lag residual berbasis signifikansi statistik parameter SARIMAX serta mekanisme peramalan rekursif selama periode *test*. Secara praktis, temuan dari studi ini dapat menjadi panduan strategis bagi pengelola *marketplace* dalam memilih skema peramalan yang paling sesuai dengan prioritas operasional dan toleransi risiko, khususnya untuk alokasi persediaan saat terjadi lonjakan transaksi.

2. METODOLOGI PENELITIAN

2.1. Tahapan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan desain eksperimen peramalan deret waktu (*time series forecasting*). Tujuan utama dari penelitian ini adalah untuk mengevaluasi dan membandingkan kinerja prediktif antara masing-masing model SARIMAX dan XGBoost serta model *hybrid* SARIMAX-XGBoost dalam memprediksi volume transaksi *marketplace* beresolusi per jam. Secara sistematis, alur pelaksanaan penelitian disajikan pada Gambar 1.



Gambar 1. *Flowchart* Penelitian

2.2. Dataset dan *Pre-processing* Data

Penelitian ini menggunakan data transaksional dari platform *marketplace* Shopee dan Tokopedia milik PT. X dengan periode 1 Januari 2023 hingga 31 Oktober 2024. Sebelum dilakukan pemodelan, data mentah melalui beberapa tahapan *pre-processing*, meliputi: (1) penghapusan entri duplikat pada *order-level*, (2) penyaringan transaksi yang dibatalkan atau ditolak, serta (3) penghapusan item non-penjualan seperti biaya pengemasan.

Data yang telah bersih selanjutnya diagregasi ke dalam resolusi waktu per jam (*hourly resolution*) dengan mempertahankan nilai nol untuk menjaga kontinuitas deret waktu tanpa menghasilkan *missing values*. Pada data *train* terdapat satu jam bernilai nol, sedangkan pada data *test* tidak terdapat jam bernilai nol. Proses agregasi ini menghasilkan dua variabel utama, yaitu Total Nilai Penjualan dan Jumlah Pengguna. Untuk meningkatkan stabilitas numerik pada estimasi parameter saat pemodelan, variabel Total Nilai Penjualan ditransformasikan skalanya dari satuan Rupiah menjadi Juta Rupiah.

Jumlah Pengguna dipilih sebagai variabel eksogen karena berkorelasi kuat dengan nilai penjualan dan diasumsikan membantu model menjelaskan variasi yang tidak tertangkap oleh

pola waktu. Variabel Tanggal Kembar ditambahkan sebagai indikator biner yang bernilai 1 pada tanggal promosi besar (1.1 hingga 12.12) dan 0 pada tanggal lainnya, karena tanggal-tanggal tersebut secara konsisten memicu lonjakan transaksi yang signifikan sehingga perlu direpresentasikan secara eksplisit agar model dapat membedakan pola penjualan promosi dari penjualan regular. Tanggal Kembar ditentukan oleh kalender sehingga nilainya diketahui sebelum periode peramalan, sedangkan Jumlah Pengguna merupakan hasil agregasi transaksi pada jam yang sama dengan nilai penjualan. Pada penelitian ini, nilai Jumlah Pengguna diasumsikan telah diketahui selama periode peramalan (data *test*). Namun pada penerapan nyata, variabel ini perlu diramalkan terlebih dahulu.

Dataset final menghasilkan 16.080 observasi jam, yang dibagi menjadi 13.872 observasi data *train* (periode Januari 2023–Juli 2024) dan 2.208 observasi data *test* (periode Agustus–Oktober 2024). Rincian variabel yang digunakan dalam penelitian ini disajikan pada TABEL I.

TABEL I. VARIABEL PENELITIAN

Notasi	Variabel	Tipe Data
Y	Total Nilai Penjualan	*Float*
X1	Jumlah Pengguna	*Integer*
X2	Tanggal Kembar	Biner (0/1)

2.3. Pemodelan SARIMAX

Pada penelitian ini, pemodelan linier dan musiman dilakukan menggunakan pendekatan *Seasonal AutoRegressive Integrated Moving Average with Exogenous Variables* (SARIMAX). Secara matematis, model SARIMAX $(p,d,q)(P,D,Q)S$ yang digunakan direpresentasikan sebagai regresi linier dengan komponen galat (*error*) yang terautokorelasi [5], [14], seperti ditunjukkan pada Persamaan (1) dan (2).

$$y_t = \beta_0 + \beta_1 X_{1,t} + \beta_2 X_{2,t} + \cdots + \beta_k X_{k,t} + \eta_t \quad (1)$$

dimana

$$\eta_t = \frac{\Theta_Q(B^S)\theta_q(B)}{\Phi_P(B^S)\phi_p(B)(1-B)^d(1-B^S)^D}\varepsilon_t \quad (2)$$

dengan y_t adalah nilai penjualan pada jam ke-t, $X_{k,t}$ adalah nilai variabel eksogen ke-k pada jam ke-t, β_k adalah koefisien variabel eksogen ke-k, dan η_t adalah komponen sisaan/galat regresi. Operator B merupakan *backshift operator* ($B^k y_t = y_{t-k}$), S menyatakan periode musiman, dan ε_t adalah galat *white noise*. Kemudian, Φ dan ϕ adalah koefisien *autoregressive* non-musiman dan musiman, Θ dan θ adalah koefisien *moving average* non-musiman dan musiman. Parameter D dan d adalah orde diferensiasi musiman dan non-musiman.

Dalam penelitian ini, penentuan orde SARIMAX $(p,d,q)(P,D,Q)_S$ diawali dengan uji stasioneritas *Augmented Dickey-Fuller* (ADF). Pola autokorelasi kemudian diidentifikasi melalui plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) untuk mengestimasi struktur musiman dan non-musiman. Jika diperlukan, akan dilakukan *differencing* dengan mempertimbangkan beberapa alasan yang memengaruhi kinerja model SARIMAX. Dari hasil identifikasi tersebut, disusun beberapa kombinasi model kandidat dengan variasi orde (p,d,q) dengan mempertimbangkan periode musiman S=12 dan S=24. Setiap model kandidat diestimasi menggunakan data *train* yang menyertakan variabel eksogen Jumlah Pengguna dan Tanggal Kembar, lalu dievaluasi tingkat signifikansi parameternya melalui uji-t. Model-model SARIMAX yang dihasilkan kemudian digunakan sebagai model dasar untuk skenario integrasi *hybrid*.

2.4. Pemodelan XGBoost

Penelitian ini juga menggunakan pendekatan *machine learning* dengan algoritma *Extreme Gradient Boosting* (XGBoost). XGBoost merupakan pemodelan data melalui pendekatan aditif dari K buah *decision tree* yang dibangun secara sekuensial untuk meminimalkan *loss function* sekaligus mengendalikan kompleksitas model melalui penalti regularisasi [15], [16]. Prediksi aditif XGBoost untuk sampel data ke-i dinyatakan pada Persamaan (3).

$$\hat{y}_i = \sum_{k=1}^{K} f_k(x_i), \quad f_k \in \mathcal{F} \quad (3)$$

dengan $\mathcal{F}$ menyatakan ruang yang memuat seluruh struktur pohon regresi (*regression trees*), dan $f_k(x_i)$ merupakan bobot keluaran pohon ke-k untuk sampel x_i. Setiap pohon ditambahkan secara bertahap dengan meminimalkan fungsi objektif $\mathcal{L}$ yang menggabungkan *loss function* konveks l dan suku penalti regularisasi $\Omega(f)$, sebagaimana dirumuskan pada Persamaan (4) dan (5).

$$\mathcal{L}^k = \sum_{i=1}^{n} l(y_i, \hat{y}_i^{k-1} + f_k(x_i)) + \Omega(f_k) \quad (4)$$

dimana

$$\Omega(f) = \gamma T + \frac{1}{2}\lambda\|w\|^2 \quad (5)$$

dengan n adalah jumlah data *train*, y_i adalah nilai aktual, $\hat{y}_i^{k-1}$ adalah akumulasi prediksi pada

iterasi sebelumnya, f_k adalah fungsi pohon baru yang ditambahkan, serta *l* menyatakan fungsi *loss* konveks yang dapat diturunkan (*differentiable*) [17]. Suku regularisasi $\Omega(f_k)$ berfungsi mengendalikan kompleksitas struktur pohon guna mencegah *overfitting*, dimana *T* menyatakan jumlah daun (*leaves*), *w* adalah vektor bobot daun, serta γ dan λ masing-masing merupakan parameter penalti untuk pemangkasan daun dan regularisasi L_2 (*Ridge*) [18].

Model XGBoost dalam penelitian ini dibangun secara spesifik hanya menggunakan dua variabel eksogen, yaitu Jumlah Pengguna (X1) dan Tanggal Kembar (X2), sebagai fitur prediktor. Penggunaan fitur ini disamakan dengan variabel eksogen pada model SARIMAX agar kinerja kedua pendekatan dapat dievaluasi secara adil dengan *input*-an yang setara. Model dilatih pada data *train* dengan menerapkan *tuning* parameter melalui *grid search* untuk menentukan kombinasi *hyperparameter* optimal [19]. Konfigurasi terbaik diambil untuk kemudian diterapkan pada pemodelan XGBoost tunggal serta integrasi *hybrid*. Karena fitur prediktor XGBoost tunggal tidak memuat *lag* penjualan, peramalan pada data *test* dapat dieksekusi secara langsung (*direct multi-step*) untuk seluruh rentang 2.208 observasi jam tanpa memerlukan skema rekursif.

2.5. Integrasi Model *Hybrid*

Pemodelan *hybrid* SARIMAX-XGBoost pada penelitian ini dilakukan menggunakan dua skenario integrasi untuk menganalisis pengaruh kualitas model dasar (*baseline model*) terhadap kinerja peramalan *hybrid*.

2.5.1 Skenario 1: *Hybrid* Sekuensial (Koreksi Residual SARIMAX dengan XGBoost)

Skenario 1 mengadopsi konsep pemodelan *hybrid* sekuensial oleh Zhang [20], dimana suatu deret waktu y_t diasumsikan terdiri dari komponen linier (L_t) dan komponen nonlinier (N_t). Dalam kerangka ini, model SARIMAX ditugaskan untuk menangkap komponen linier, musiman, serta pengaruh variabel eksogen, sementara XGBoost dimanfaatkan untuk memodelkan struktur nonlinier yang tersisa pada residual SARIMAX.

Proses pemodelan diawali dengan mengestimasi parameter model SARIMAX menggunakan data *train* guna menghasilkan nilai prediksi *in-sample* ($\hat{L}_t$), dengan tingkat signifikansi setiap parameter diuji melalui uji-*t* ($p < 0{,}05$). Selanjutnya, residual (e_t) dihitung sebagai selisih antara nilai observasi aktual dan hasil prediksi SARIMAX pada data train, sebagaimana dirumuskan dalam Persamaan (6). Residual yang diperoleh ini kemudian dijadikan sebagai variabel target dalam proses pelatihan XGBoost.

$$e_t = y_t - \hat{L}_t \tag{6}$$

Hasil uji signifikansi parameter SARIMAX mendasari kriteria seleksi fitur masukan untuk XGBoost. Variabel eksogen yang terbukti signifikan secara statistik, yaitu Jumlah Pengguna dan Tanggal Kembar, dipertahankan secara langsung sebagai fitur. Sementara itu, apabila komponen *autoregressive* (AR) atau *moving average* (MA) non-musiman terdeteksi signifikan (ar.L1 atau ma.L1), fitur *lag* residual satu jam sebelumnya (e_{t-1}) turut ditambahkan. Demikian pula jika komponen AR atau MA musiman bernilai signifikan, *lag* residual pada periode musiman (e_{t-s}, yaitu *lag* 12 atau 24) disertakan ke dalam model. Dalam hal ini, nilai koefisien AR dan MA tidak dimasukkan sebagai fitur, melainkan signifikansinya hanya menjadi penentu keberadaan *lag* yang relevan. Pada data *train*, pembentukan fitur lag dilakukan dengan menggeser deret residual, sedangkan pada data *test*, komponen residual ($\hat{N}_t$) diramalkan oleh XGBoost secara rekursif mengingat nilai residual aktual tidak tersedia selama periode peramalan. Nilai lag untuk jam-jam awal diambil dari residual aktual di akhir data train, sementara horizon jam-jam berikutnya diisi secara berurutan menggunakan nilai prediksi residual dari jam sebelumnya. Konfigurasi *hyperparameter* XGBoost yang digunakan pada skenario ini sama dengan XGBoost tunggal.

$$\hat{y}_t = \hat{L}_t + \hat{N}_t \tag{7}$$

Prediksi akhir Skenario 1 diperoleh melalui penjumlahan aditif dari keluaran kedua model, seperti yang ditunjukkan pada Persamaan (7). Pendekatan sekuensial ini diharapkan mampu meningkatkan akurasi peramalan karena XGBoost berfokus mengoreksi pola kesalahan yang ditinggalkan oleh model statistik [11], [21].

2.5.2 Skenario 2: *Hybrid Ensemble* Paralel (Rata-rata Prediksi SARIMAX dan XGBoost)

Skenario 2 menerapkan pendekatan *ensemble* paralel dengan menghitung prediksi akhir ($\hat{y}_t$) sebagai rata-rata dari hasil prediksi *m* buah model anggotanya [13]. Secara matematis, pendekatan ini dituliskan seperti Persamaan (8).

$$\hat{y}_t = \frac{\sum_{j=1}^{m} \hat{y}_{j,t}}{m} \tag{8}$$

Dalam penelitian ini, jumlah model yang dikombinasikan adalah dua (m=2), yaitu model

SARIMAX dan model XGBoost independen dengan fitur Jumlah Pengguna serta Tanggal Kembar. Dengan memberikan bobot seimbang ($w_1 = w_2 =$ 0,5), formulasi Skenario 2 dinyatakan pada Persamaan (9).

$$\hat{y}_t = 0{,}5\hat{y}_{SARIMAX,t} + 0{,}5\hat{y}_{XGBoost,t} \quad (9)$$

Penggunaan metode *simple average* didasarkan pada efektivitasnya dalam menghasilkan peramalan yang stabil tanpa risiko kesalahan estimasi parameter saat menentukan bobot kombinasi [22], sekaligus meredam varians galat total dan meminimalkan ketidakpastian model tunggal.

2.6. Evaluasi Model

Kinerja model peramalan dievaluasi menggunakan tiga metrik utama, yaitu *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). Secara matematis, formulasi ketiga metrik evaluasi tersbeut ditunjukkan pada Persamaan (10), (11), dan (12).

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(\hat{y}_i - y_i)^2} \quad (10)$$

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|\hat{y}_i - y_i| \quad (11)$$

$$MAPE = \frac{100}{n}\sum_{i=1}^{n}\left|\frac{y_i - \hat{y}_i}{y_i}\right| \quad (12)$$

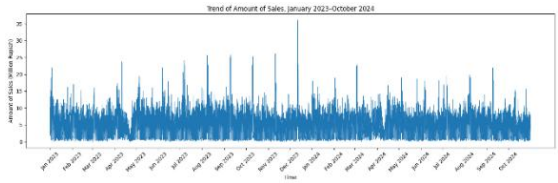
dimana n menyatakan jumlah observasi data, y_i adalah nilai transaksi aktual pada jam ke-i, dan $\hat{y}_t$ merupakan nilai hasil prediksi model.

RMSE dijadikan sebagai acuan utama dalam menentukan model terbaik karena tidak melibatkan pembagian dengan nilai aktual sehingga tidak bermasalah pada nilai nol atau sangat kecil, dan MAE sebagai acuan kedua. Sementara itu, MAPE digunakan sebagai metrik pendukung untuk memberikan interpretasi kesalahan secara relatif dalam persentase. Karena MAPE tidak terdefinisi pada nilai aktual nol, observasi dengan y_t=0 dikeluarkan dari perhitungan MAPE. Pada data *test* tidak terdapat observasi bernilai nol, sehingga MAPE dihitung pada seluruh observasi, sedangkan pada data *train* satu observasi bernilai nol dikeluarkan. Karena MAPE tetap sensitif terhadap nilai aktual yang sangat kecil, metrik ini digunakan sebagai pendukung.

3. HASIL DAN PEMBAHASAN

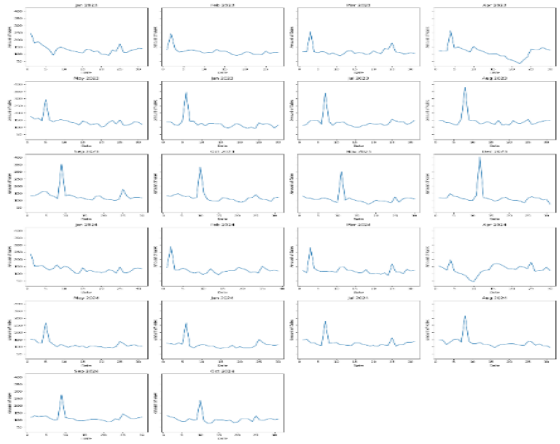
3.1. Analisis Data Eksplorasi

Data yang telah diproses menghasilkan 16.080 baris data per jam mencakup periode Januari 2023 hingga Oktober 2024, data terbagi menjadi 13.872 data *train* (Januari 2023–Juli 2024) dan 2.208 data *test* (Agustus–Oktober 2024). Gambar 2 menampilkan tren keseluruhan variabel Total Nilai Penjualan selama periode pengamatan, yang memperlihatkan garis dasar yang relatif stabil namun diselingi oleh lonjakan tajam dan berulang pada interval waktu yang tidak teratur.



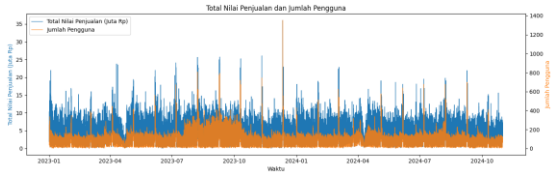
Gambar 2. Tren Total Nilai Penjualan

Statistik deskriptif menunjukkan bahwa variabel Total Nilai Pejualan memiliki nilai rata-rata sebesar Rp5,17 juta, dengan nilai maksimum Rp36,05 juta, angka yang kira-kira tujuh kali lipat dari nilai mediannya. Kesenjangan yang signifikan antara nilai rata-rata, median, dan maksimum mengindikasikan bahwa distribusi data cenderung ke kanan (*right-skewed*) akibat adanya *outliers*; nilai koefisien variasi sebesar 0,630 juga menunjukkan tingkat volatilitas transaksi yang tinggi selama periode pengamatan. Karakteristik serupa juga teramati pada variabel Jumlah Pengguna dengan nilai koefisien variansi sebesar 0,689, yang mengindikasikan bahwa jumlah pengguna aktif per jam juga berfluktuasi secara signifikan sepanjang periode pengamatan.



Gambar 3. Distribusi Total Nilai Penjualan

Gambar 3 menyajikan distribusi variabel Total Nilai Penjualan yang dirinci berdasarkan bulan. Rincian bulanan ini memperlihatkan bahwa lonjakan yang teramati dalam tren keseluruhan terjadi secara konsisten pada posisi relatif yang sama di setiap bulannya, yang bertepatan dengan acara promosi tanggal kembar.

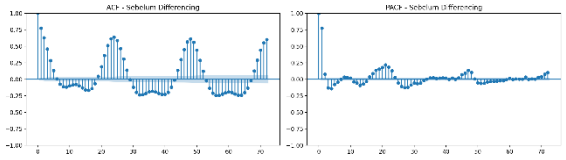


Gambar 4. Perbandingan Tren Total Nilai Penilaian dan Jumlah Pengguna

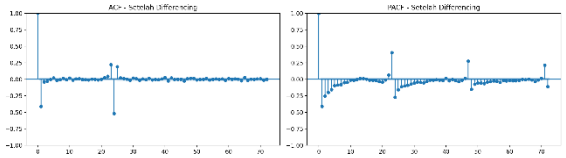
Hal ini didukung oleh Gambar 4 yakni perbandingan antara Total Nilai Penjualan dan Jumlah Pengguna, yang menunjukkan adanya hubungan kuat antara jumlah pengguna aktif dan nilai transaksi pada jam tertentu. Selain pola musiman berbasis kalender, terdapat pula indikasi transaksi bervolume tinggi yang terjadi secara tidak teratur di luar periode tanggal kembar. Fenomena ini ditandai dengan rasio nilai transaksi terhadap pengguna yang jauh melampaui rata-rata normal. Karakteristik ini menunjukkan bahwa dinamika transaksi dalam data *marketplace* tidak hanya dipengaruhi oleh faktor musiman yang dapat diprediksi, tetapi juga oleh peristiwa sporadis yang berdampak signifikan terhadap volatilitas data. Tingginya volatilitas ini menjadi pertimbangan penting dalam tahap pemodelan selanjutnya, mengingat pola transaksi yang tidak sepenuhnya dijelaskan oleh faktor kalender berpotensi memengaruhi akurasi prediksi model, baik menggunakan pendekatan statistik maupun *machine learning*.

3.2. SARIMAX

Sebelum melakukan identifikasi dan estimasi model, tahap awal analisis melibatkan pengujian stasioneritas data deret waktu. Berdasarkan hasil uji ADF, diperoleh *p-value* <0,05 yang mengindikasikan bahwa data stasioner pada level. Meskipun demikian, plot ACF pada Gambar 4 menunjukkan pola berulang dengan puncak *lag* 24, 48, dan 72 yang nyaris tidak meluruh. ACF pada deret stasioner seharusnya turun ke nol relatif cepat [23], sehingga pola ini menandakan masih adanya autokorelasi musiman harian yang kuat. Oleh karena itu, *differencing* musiman (D=1) diterapkan untuk menghilangkan pola tersebut. *Differencing* non-musiman (d=1) dipertahankan sebagai pilihan konservatif; perbandingan d=0 dan d=1 menunjukkan selisih kinerja yang sangat kecil. Periode musiman S=24 dipilih berdasarkan pola ACF, sedangkan S=12 diuji sebagai alternatif pembanding.



Gambar 5. Plot ACF dan PACF Sebelum *Differencing*



Gambar 6. Plot ACF dan PACF Setelah *Differencing*

Gambar 5 dan Gambar 6 menunjukkan plot ACF dan PACF sebelum dan sesudah dilakukan *differencing*. Setelah *differencing,* pola ACF menunjukkan *cut-off* pada *lag* 1 (sekitar -0,42) dan lonjakan negatif pada *lag* 24, sehingga mengindikasikan komponen *moving average* (MA) non-musiman orde 1 dan MA musiman orde 1. Sementara itu, PACF tidak terputus tegas melainkan meluruh bertahap, dengan lonjakan terbesar pada *lag* 1 dan lonjakan berulang pada kelipatan musiman. Pola ini tidak cukup untuk memastikan tidak adanya komponen *autoregressive* (AR) non-musiman, sehingga orde p=0 dan p=1 sama-sama dimasukkan sebagai kandidat untuk diuji melalui signifikansi parameter dan kinerja model. Berdasarkan identifikasi tersebut, dirumuskan empat kombinasi model kandidat, yaitu $(1,1,1)(0,1,1)_S$ dan $(0,1,1)(0,1,1)_S$ untuk periode musiman S=12 dan S=24, sebagaimana dirinci pada TABEL II.

TABEL II. HASIL PEMODELAN SARIMAX

Model	Parameter	Signifikan	RMSE	MAE	MAPE
SARIMAX$(1,1,1)(0,1,1)_{24}$	X1	v	**1,31**	**1,05**	44,80%
	X2	v			
	ar.L1	v			

	ma.L1	v			
	ma.S.L24	v			
SARIMAX(0,1,1)(0,1,1)$_{24}$	X1	v	1,39	1,13	50,50%
	X2	v			
	ma.L1	v			
	ma.S.L24	v			
SARIMAX(1,1,1)(0,1,1)$_{12}$	X1	v	1,82	1,38	36,49%
	X2	v			
	ar.L1	x			
	ma.L1	v			
	ma.S.L12	v			
SARIMAX(0,1,1)(0,1,1)$_{12}$	X1	v	1,82	1,37	**36,39%**
	X2	v			
	ma.L1	v			
	ma.S.L12	v			

Hasil evaluasi menunjukkan bahwa periode musiman *S*=24 secara konsisten mengungguli *S*=12. Nilai RMSE terendah pada *S*=24 (1,31) lebih rendah dibandingkan *S*=12 (1,82), mengonfirmasi bahwa pola musiman 24 jam lebih merepresentasikan dinamika data transaksi. Penambahan komponen AR(1) non-musiman memberikan peningkatan akurasi pada *S*=24 dengan penurunan RMSE sebesar 0,08. Sebaliknya, penambahan variabel tersebut pada S=12 tidak memberikan perbaikan berarti, di mana koefisien ar.L1 pada model SARIMAX(1,1,1)(0,1,1)$_{12}$ tidak signifikan secara statistik. Temuan ini sejalan dengan hasil identifikasi ACF/PACF bahwa komponen MA saja telah memadai untuk menjelaskan struktur non-musiman pada *S*=12.

Pada tahap diagnostik, uji *Ljung-Box* menunjukkan bahwa residual keempat model kandidat belum memenuhi asumsi *white noise* (p < 0,001). Namun, tingkat autokorelasi sisa tersebut menunjukkan perbedaan yang signifikan antar-model. Pada lag 24, statistik *Q* untuk model basis *S*=24 berada pada rentang 154,5–271,4, sedangkan pada model basis *S*=12 nilainya membengkak hingga 2.078,3–2.090,1. Di antara kelompok model *S*=24, spesifikasi dengan komponen AR(1) menghasilkan nilai *Q* yang lebih rendah (154,5 dan 271,4 pada *lag* 24), sejalan dengan pencapaian RMSE-nya yang lebih baik.

Belum terpenuhinya asumsi *white noise* ini memberikan implikasi pada tiga aspek utama. Pertama, nilai *p* pada uji-*t* parameter perlu ditafsirkan secara hati-hati mengingat uji tersebut mengasumsikan galat acak yang independen. Kedua, hal ini mengindikasikan masih adanya struktur non-linier kompleks yang belum tertangkap oleh model linier, yang diduga kuat berkaitan dengan fluktuasi transaksi *bulk order* sebagaimana teridentifikasi pada analisis eksploratif data. Ketiga, evaluasi akurasi peramalan pada data *test* tidak bergantung pada asumsi ini, sehingga perbandingan performansi RMSE, MAE, dan MAPE antarmodel tetap valid, sementara inferensi terhadap parameter model tidak dijadikan dasar kesimpulan utama.Meskipun demikian, seluruh model kandidat tetap dipertahankan sebagai basis pemodelan *hybrid* guna mengevaluasi pengaruh kualitas model dasar (*baseline*) terhadap kinerja peramalan akhir.

3.3. XGBoost

Model XGBoost dibangun menggunakan variabel eksogen Jumlah Pengguna dan Tanggal Kembar dengan optimasi *hyperparameter* via *grid search*. Konfigurasi *hyperparameter* optimal yang diperoleh dari proses optimasi ini meliputi *n_estimators* = 50, *max_depth* = 4, *learning_rate* = 0,05, *subsample* = 0,8, dan *colsample_bytree* = 1,0. Pada data *test*, model ini menghasilkan nilai RMSE sebesar 1,24, MAE sebesar 0,90, dan MAPE sebesar 31,38%. Kinerja ini secara konsisten mengungguli seluruh model SARIMAX tunggal, dengan penurunan RMSE serta nilai MAPE yang lebih rendah dibandingkan rentang model SARIMAX. Hasil analisis *feature importance* menunjukkan bahwa variabel Jumlah Pengguna mendominasi kontribusi pembentukan model sebesar 97,6%, sementara Tanggal Kembar berkontribusi sebesar 2,4%. Temuan ini mengonfirmasi bahwa aktivitas pengguna di jam-jam tertentu merupakan faktor eksternal paling krusial dan dominan dalam menjelaskan variabilitas nilai transaksi penjualan.

3.4. Skenario 1: *Hybrid* Sekuensial (Koreksi Residual SARIMAX dengan XGBoost)

Skenario 1 diterapkan pada keempat kombinasi orde SARIMAX sebagai basis, dengan fitur XGBoost yang ditentukan berdasarkan signifikansi parameter SARIMAX. Pada keempat model dasar, Jumlah Pengguna, Tanggal Kembar, dan komponen MA non-musiman signifikan, sehingga fitur yang digunakan hampir sama, yaitu Jumlah Pengguna, Tanggal Kembar, *lag* 1 residual, dan *lag* musiman residual (*lag* 24 pada model dasar *S*=24 dan *lag* 12 pada *S*=12). Konfigurasi *hyperparameter* XGBoost yang digunakan pada Skenario 1 sama dengan XGBoost tunggal, yakni *n_estimators* = 50, *max_depth* = 4, *learning_rate* = 0,05, *subsample* = 0,8, dan *colsample_bytree* = 1,0. Hasil perbandingan disajikan pada TABEL III.

TABEL III. HASIL SKENARIO 1

Basis SARIMAX	RMSE	MAE	MAPE
$(1,1,1)(0,1,1)_{24}$	**1,34**	**1,08**	47,25%
$(0,1,1)(0,1,1)_{24}$	1,43	1,18	53,18%
$(1,1,1)(0,1,1)_{12}$	1,78	1,34	35,10%
$(0,1,1)(0,1,1)_{12}$	1,78	1,34	**34,82%**

Hasil evaluasi menunjukkan pola yang konsisten pada ketiga metrik. Skenario 1 hanya mampu meningkatkan performa pada model dasar *S*=12, namun justru menurunkan performa pada model dasar *S*=24. Perbaikan pada *S*=12 tergolong kecil, dan hasil akhirnya masih jauh dari XGBoost tunggal maupun SARIMAX (tunggal) terbaik. Pola ini diduga berkaitan dengan besarnya pola yang tersisa pada residual. Uji Ljung-Box menunjukkan bahwa sisa autokorelasi model *S*=24 jauh lebih kecil dibandingkan model *S*=12. Pada basis *S*=24, ruang koreksi bagi XGBoost lebih terbatas sehingga koreksi tambahan lebih mungkin menambah varians prediksi, sedangkan pada basis *S*=12 pola harian masih tersisa pada residual sehingga koreksi dapat memberikan sedikit perbaikan. Temuan ini mengindikasikan bahwa efektivitas koreksi residual bergantung pada kualitas model dasarnya.

3.5. Skenario 2: *Hybrid Ensemble* Paralel (Rata-rata Prediksi SARIMAX dan XGBoost)

Skenario 2 diterapkan pada empat kombinasi orde SARIMAX yang sama, yang digabungkan dengan satu model XGBoost menggunakan metode perata-rataan sederhana dengan bobot yang sama (0,5) untuk kedua model tersebut. Berbeda dengan Skenario 1, XGBoost pada skenario ini tidak memuat *lag* sehingga meramal secara langsung untuk seluruh periode *test*. Hasil skenario ini disajikan dalam TABEL IV.

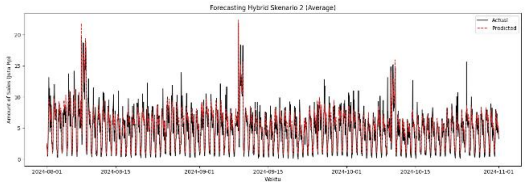
TABEL IV. HASIL SKENARIO 2

Basis SARIMAX	RMSE	MAE	MAPE
$(1,1,1)(0,1,1)_{24}$	**1,20**	**0,92**	37,16%
$(0,1,1)(0,1,1)_{24}$	1,23	0,96	39,82%
$(1,1,1)(0,1,1)_{12}$	1,36	0,94	22,55%
$(0,1,1)(0,1,1)_{12}$	1,36	0,94	**22,54%**

Berbeda dengan Skenario 1, Skenario 2 mengungguli model dasar SARIMAX pada seluruh metrik di keempat kombinasi orde, dengan penurunan RMSE sebesar 0,10-0,46, MAE 0,12-0,43, dan MAPE 7,63%-13,94%. Peningkatan akurasi paling signifikan terjadi pada model dasar *S*=12 yang memiliki kinerja paling lemah. Terhadap XGBoost tunggal, hasilnya bergantung pada metrik. *Ensemble* berbasis *S*=24 memiliki RMSE lebih rendah (1,20 dan 1,23), tetapi MAE dan MAPE lebih tinggi. *Ensemble* berbasis *S*=12 tidak mengungguli XGBoost tunggal pada RMSE dan MAE, namun menghasilkan MAPE terendah di antara seluruh model (22,54%). Temuan ini mengonfirmasi bahwa pendekatan *simple averaging* efektif memperbaiki performa model statistik, namun keunggulannya terhadap model *machine learning* tunggal sangat bergantung pada kualitas model dasar yang dikombinasikan.

3.6. *Summary* Keseluruhan Model

Berdasarkan RMSE sebagai kriteria utama, model *hybrid* Skenario 2 dengan model dasar SARIMAX $(1,1,1)(0,1,1)_{24}$ ditetapkan sebagai model terbaik dengan nilai RMSE terkecil, yaitu 1,20. Dua peringkat teratas secara keseluruhan ditempati oleh Skenario 2 yang menggunakan model dasar berperiode musiman *S*=24. Visualisasi hasil peramalan dari model terbaik tersebut disajikan pada Gambar 7.



Gambar 7. Hasil Peramalan dengan Model Terbaik

Hasil evaluasi metrik MAE dan MAPE memberikan perspektif yang berbeda terhadap performa peramalan. Model XGBoost tunggal mencatatkan MAE terendah sebesar 0,90, sedangkan Skenario 2 dengan basis *S*=12

menghasilkan MAPE terendah sebesar 22,54%, jauh di bawah XGBoost tunggal (31,38%). Hal ini mengindikasikan bahwa penentuan model terbaik bersifat kontekstual bergantung pada metrik evaluasi yang diprioritaskan. Evaluasi berbasis RMSE relevan ketika kesalahan besar perlu diminimalkan melalui pembobotan kuadratik. Sementara itu, MAE memberikan estimasi kesalahan rata-rata langsung pada skala aktual, dan MAPE mengukur kesalahan relatif terhadap besarnya transaksi. Bagi pelaku usaha, pemilihan model dapat disesuaikan dengan toleransi risiko serta tujuan operasional.

TABEL V. PERBANDINGAN PENDEKATAN PADA MODEL DASAR $(1,1,1)(0,1,1)_{24}$

Pendekatan	RMSE	MAE	MAPE
SARIMAX tunggal	1,31	1,05	44,79%
XGBoost tunggal	1,24	**0,90**	**31,38%**
Skenario 1	1,34	1,08	47,25%
Skenario 2	**1,20**	0,92	37,16%

TABEL V menunjukkan perbandingan model dasar terbaik dengan urutan RMSE dari terendah Adalah Skenario 2, XGBoost tunggal, SARIMAX tunggal, lalu Skenario 1. Perbedaan kinerja antarpendekatan ini diduga berasal dari beberapa hal. Pertama, sumber informasi. XGBoost tunggal lebih akurat daripada SARIMAX tunggal, dan 97,6% kontribusinya berasal dari Jumlah Pengguna, yang mengindikasikan bahwa hubungan nonlinier antara Jumlah Pengguna dan Total Nilai Penjualan lebih berperan daripada struktur *autoregressive*. Skenario 2 membawa informasi ini langsung ke prediksi akhir. Pada Skenario 1, XGBoost hanya meramalkan residual setelah pengaruh linier kedua variabel eksogen dikeluarkan SARIMAX, sehingga informasi nonlinier yang tersisa kecil, dan informasi lainnya berupa *lag* residual yang pada periode *test* diisi secara rekursif.

Kedua, cara penggabungan. Skenario 1 bersifat sekuensial, di mana XGBoost memodelkan residual SARIMAX secara langsung tanpa mekanisme peredaman varians, sehingga ketepatan peramalan akhirnya sangat bergantung pada akurasi XGBoost dalam mengestimasi residual tersebut. Sebaliknya, Skenario 2 bersifat paralel, di mana mekanisme perata-rataan (averaging) mampu meredam varians galat selama kesalahan dari kedua model tidak berkorelasi sempurna. Berdasarkan hasil uji peramalan, kedua model tunggal (SARIMAX dan XGBoost) memiliki pendekatan pemodelan yang sangat berbeda, sehingga galat yang dihasilkan tidak saling berkorelasi secara sempurna. Kondisi ini memungkinkan mekanisme *ensemble* pada Skenario 2 bekerja dengan efektif dalam menetralkan kesalahan individual kedua model, sehingga performansinya mampu mengungguli masing-masing model penyusunnya.

Ketiga, aspek ketahanan pada horizon peramalan jangka panjang. Skenario 2 terbukti lebih stabil karena proses peramalannya tidak memiliki ketergantungan pada nilai *lag* residual rekursif. Sebaliknya, Skenario 1 sangat rentan terhadap akumulasi galat selama periode peramalan 2.208 jam. Hal ini disebabkan oleh pembentukan fitur *lag* residual pada Skenario 1 yang diisi secara rekursif menggunakan nilai prediksi sebelumnya.

Keempat, kualitas model dasar. Skenario 1 hanya mampu memberikan perbaikan terbatas ketika diterapkan pada model dasar yang relatif lemah (S=12). Sebaliknya, Skenario 2 memberikan perbaikan performasi pada seluruh variasi model dasar. Walaupun demikian, keberhasilan Skenario 2 dalam melampaui performansi XGBoost tunggal sangat bergantung pada kesetaraan kualitas antar-model penyusunnya. Dengan skema pembobotan seimbang, *ensemble* hanya akan efektif meningkatkan akurasi apabila selisih performa antara SARIMAX dan XGBoost tidak terlalu lebar. Pada basis musiman S=12, performa SARIMAX jauh lebih lemah dibandingkan XGBoost tunggal. Akibatnya, penggabungan rata-rata justru menarik hasil peramalan akhir menjauhi kinerja terbaik XGBoost. Sebaliknya, pada basis musiman S=24, selisih kualitas antara SARIMAX dan XGBoost relatif kecil, sehingga penggabungan kedua model mampu menghasilkan peredaman galat yang optimal dan sedikit mengungguli performa XGBoost tunggal.

Temuan ini memperluas hasil penelitian Nuraini dkk. [7] yang sebelumnya menunjukkan keunggulan SARIMAX atas model *deep learning* (LSTM) pada data *marketplace* sejenis, dengan memperlihatkan bahwa kinerja SARIMAX tunggal masih dapat dioptimalkan melalui integrasi *hybrid* dengan XGBoost, khususnya melalui skema *hybrid ensemble* (Skenario 2) dengan penentuan periode musiman yang tepat. Efektivitas pendekatan integrasi ini sejalan dengan keberhasilan *hybrid forecasting* pada domain peramalan pembangkit listrik tenaga surya [13]. Namun, residual seluruh model SARIMAX belum memenuhi asumsi *white noise*, sehingga kesimpulan penelitian ini bertumpu pada akurasi peramalan di data *test*, bukan pada inferensi terhadap parameter model.

4. KESIMPULAN DAN SARAN

Penelitian ini berhasil mengevaluasi skema integrasi *hybrid* SARIMAX-XGBoost untuk peramalan penjualan per jam pada platform *marketplace*. Hasil evaluasi menunjukkan bahwa efektivitas pemodelan *hybrid* sangat ditentukan oleh mekanisme penggabungan model dan pilihan metrik evaluasi. Skenario 2 berbasis SARIMAX $(1,1,1)(0,1,1)_{24}$ mencatatkan performa terbaik berdasarkan RMSE (1,20), melampaui kinerja XGBoost tunggal (1,24) dan SARIMAX terbaik (1,31). Sebaliknya, Skenario 1 belum mampu mengungguli model tunggal terbaik akibat perbedaan karakteristik galat serta akumulasi kesalahan pada peramalan rekursif jangka panjang. Meskipun demikian, penentuan model terbaik bersifat kontekstual terhadap tujuan bisnis: Skenario 2 berbasis S=24 unggul dalam meminimalkan lonjakan kesalahan besar (RMSE), XGBoost tunggal unggul pada efisiensi kesalahan rata-rata (MAE 0,90), sedangkan Skenario 2 berbasis S=12 memberikan presisi relatif terbaik (MAPE 22,54%). Dominasi fitur Jumlah Pengguna (97,6%) mengonfirmasi peran vital aktivitas pengguna harian, sementara belum terpenuhinya asumsi *white noise* mengindikasikan adanya dinamika transaksi bervolume besar yang tidak teratur.

Bagi pelaku usaha *marketplace*, model *hybrid* Skenario 2 berbasis S=24 direkomendasikan dalam pengambilan keputusan berbasis data untuk manajemen inventaris dan perencanaan operasional pada periode lonjakan permintaan tinggi guna meminimalkan risiko kesalahan peramalan ekstrem. Jika prioritas analisis berfokus pada kesalahan rata-rata atau presisi relatif, penggunaan XGBoost tunggal atau Skenario 2 berbasis S=12 dapat dijadikan alternatif. Mengingat penelitian ini mengasumsikan variabel eksogen telah diketahui selama periode peramalan, pengembangan selanjutnya disarankan untuk memodelkan peramalan Jumlah Pengguna secara mandiri agar sistem dapat berjalan secara *real-time*. Selain itu, eksplorasi variabel intervensi untuk menangani transaksi bervolume besar yang bersifat tidak regular, serta penerapan model volatilitas, dan atau kombinasi pembobotan alternatif selain rata-rata sederhana pada Skenario 2 menjadi arah penelitian yang relevan untuk meningkatkan keandalan model di masa depan.

5. UCAPAN TERIMA KASIH

Para penulis mengucapkan terima kasih atas dukungan yang diberikan oleh Laboratorium Big Data dan Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA) Universitas Negeri Surabaya (UNESA), termasuk fasilitas yang disediakan selama penelitian ini berlangsung. Penelitian ini didukung oleh Lembaga Penelitian dan Pengabdian kepada Masyarakat (LPPM) Universitas Negeri Surabaya dengan nomor hibah B/25025/UN38.III.1/TU.00.02/2025. Kami juga menyampaikan terima kasih yang tulus kepada PT. Sarana Mendulang Arta atas kontribusi data transaksional mereka.

DAFTAR PUSTAKA

[1] D. Mubarok, K. Adjani, B. D. Ridho Hutama, Muhamad Malik Mutoffar, dan Rina Indrayani, "BIG DATA ANALYTICS DAN MACHINE LEARNING UNTUK MEMPREDIKSI PERILAKU KONSUMEN DI E-COMMERCE," *Jurnal Informatika dan Rekayasa Elektronik*, vol. 8, no. 1, hlm. 159–167, Apr 2025, doi: 10.36595/jire.v8i1.1561.

[2] Z. Huo, "Sales Prediction based on Machine Learning," dalam *2021 2nd International Conference on E-Commerce and Internet Technology (ECIT)*, Hangzhou, China: IEEE, Mar 2021, hlm. 410–415. doi: 10.1109/ECIT52743.2021.00093.

[3] A. Gandhi, Aakanksha, S. Kaveri, dan V. Chaoji, "Spatio-Temporal Multi-graph Networks for Demand Forecasting in Online Marketplaces," dalam *Machine Learning and Knowledge Discovery in Databases. Applied Data Science Track*, Y. Dong, N. Kourtellis, B. Hammer, dan J. A. Lozano, Ed., Cham: Springer International Publishing, 2021, hlm. 187–203. doi: 10.1007/978-3-030-86514-6_12.

[4] Y. K. El Alem, "Optimizing Sales Forecasting, Inventory, Pricing and Sourcing Decisions," EPFL, 2023.

[5] R. J. Hyndman dan G. Athanasopoulos, *Forecasting: Principles and Practice*, 3rd ed. Australia: OTexts, 2021. [Daring]. Tersedia pada: https://books.google.co.id/books?id=gZB-zgEACAAJ

[6] M. Thejovathi *dkk.*, "Optimizing Product Demand Forecasting with Hybrid Machine Learning and Time Series Models: A Comparative Analysis of XGBoost and SARIMA," dalam *Proceedings of the 3rd*

International Conference on Optimization Techniques in the Field of Engineering (ICOFE-2024), SSRN, Jan 2025. doi: dx.doi.org/10.2139/ssrn.5076161.

[7] U. S. Nuraini, D. G. Guminta, I. F. Kurniawan, dan A. O. B. Puka, "Sales Forecasting with Hourly Transaction Data: Comparing SARIMAX and LSTM Models," dalam *2025 IEEE International Symposium on Consumer Technology (ISCT)*, Denpasar, Bali, Indonesia: IEEE, Des 2025, hlm. 37–43. doi: 10.1109/ISCT66099.2025.11297237.

[8] F. Juliyanto, L. Widyawati, K. Marzuki, dan I. Made Yadi Dharma, "IMPLEMENTASI CHATBOT PADA TELEGRAM UNTUK MENDETEKSI SPAM MENGGUNAKAN METODE XGBOOST," *Jurnal Manajemen Informatika & Sistem Informasi (MISI)*, vol. 8, no. 2, hlm. 335–346, 2025, doi: 10.36595/misi.v5i2.

[9] O. G. Atanda *dkk.*, "Intelligent Sales Forecasting System Using Arima, Sarima, and Xgboost Models," dalam *2024 International Conference on Science, Engineering and Business for Driving Sustainable Development Goals (SEB4SDG)*, Omu-Aran, Nigeria: IEEE, Agu 2024, hlm. 1–8. doi: 10.1109/SEB4SDG60871.2024.10629780.

[10] N. Yadav, A. Roushan, V. Singh, N. Kumari, dan Diksha, "Implementation of Models for Demand Forecasting for e-Commerce using Time Series Forecasting," dalam *2024 Second International Conference on Advanced Computing & Communication Technologies (ICACCTech)*, 2024, hlm. 56–62. doi: 10.1109/ICACCTech65084.2024.00020.

[11] M. Y. Malva, A. P. Sari, dan E. Y. Puspaningrum, "Application of SARIMA and XGBoost Models in Forecasting International Tourist Arrivals at Ngurah Rai," *Bit-Tech (Binary Digital - Technology)*, vol. 8, no. 2, hlm. 2735–2746, Des 2025, doi: 10.32877/bt.v8i2.3352.

[12] A. Kaushal, A. Gupta, dan V. Sehgal, "Exploiting the synergy of SARIMA and XGBoost for spatiotemporal earthquake time series forecasting," *Earth Surf. Process. Landf.*, vol. 49, no. 14, hlm. 4724–4742, Okt 2024, doi: 10.1002/esp.5992.

[13] M. AlKandari dan I. Ahmad, "Solar power generation forecasting using ensemble approach based on deep learning and statistical methods," *Applied Computing and Informatics*, vol. 20, no. 3/4, hlm. 231–250, Jun 2024, doi: 10.1016/j.aci.2019.11.002.

[14] F. Sheng dan L. Jia, "Short-Term Load Forecasting Based on SARIMAX-LSTM," dalam *2020 5th International Conference on Power and Renewable Energy (ICPRE)*, Shanghai, China: IEEE, Okt 2020, hlm. 90–94. doi: 10.1109/ICPRE51194.2020.9233117.

[15] Annisa, "Analisis Perbandingan Kinerja Algoritma Gradient Boosting dan Bootstrap Aggregating (BAGGING) Untuk Klasifikasi Ketepatan Waktu Sistem Pengiriman Produk E-Commerce," Thesis (Skripsi), Universitas Hasanuddin, 2025. Diakses: 29 September 2026. [Daring]. Tersedia pada: http://repository.unhas.ac.id:443/id/eprint/44624

[16] P. Dankorpho, "Sales Forecasting for Retail Business using XGBoost Algorithm," *Journal of Computer Science and Technology Studies*, vol. 6, no. 2, hlm. 136–141, Jun 2024, doi: 10.32996/jcsts.

[17] Z. Fang, S. Yang, C. Lv, S. An, dan W. Wu, "Application of a data-driven XGBoost model for the prediction of COVID-19 in the USA: a time-series study," *BMJ Open*, vol. 12, no. 7, hlm. e056685, Jul 2022, doi: 10.1136/bmjopen-2021-056685.

[18] T. Chen dan C. Guestrin, "XGBoost: A Scalable Tree Boosting System," dalam *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, dalam KDD '16. New York, NY, USA: Association for Computing Machinery, 2016, hlm. 785–794. doi: 10.1145/2939672.2939785.

[19] Sugiyanti dan M. Haris, "ANALYSIS OF THE APPLICATION OF HYPERPARAMETER TUNING IN MACHINE LEARNING TO INCREASE THE ACCURACY OF SALES-LEVEL PREDICTION," *Jurnal Informatika & Rekayasa Elektronika)*, vol. 7, no. 1, hlm. 98–106, Apr 2024, [Daring]. Tersedia pada: https://e-journal.stmiklombok.ac.id/index.php/jire/article/view/1130

[20] G. P. Zhang, "Time series forecasting using a hybrid ARIMA and neural network model," *Neurocomputing*, vol. 50, hlm. 159–175, 2003.

[21] J. Wang, J. Zhang, dan Y. Cai, "A Novel Residual Correction Approach Based on a Hybrid GARCH and XGBoost Model,"

Academic Journal of Computing & Information Science, vol. 7, no. 11, hlm. 127–134, 2024, doi: 10.25236/ajcis.2024.071117.

[22] A. Timmermann, "Chapter 4 Forecast Combinations," dalam *Handbook of Economic Forecasting*, vol. 1, G. Elliott, C. W. J. Granger, dan A. Timmermann, Ed., Elsevier, 2006, hlm. 135–196. doi: https://doi.org/10.1016/S1574-0706(05)01004-9.

[23] G. E. P. . Box, G. M. . Jenkins, G. C. . Reinsel, dan G. M. . Ljung, *Time series analysis : forecasting and control*, 5 ed., vol. 1. John Wiley & Sons, Inc., 2015.