

FORECASTING PERSEDIAAN KEMASAN FOLDING BOX UNTUK MITIGASI RISIKO STOCK OUT: PENDEKATAN SARIMA, PROPHET, XGBOOST, DAN RANDOM FOREST

Wiwi Prastiwinarti^{*1}, Sukma Ambar Muliati², Novi Purnama Sari³

^{1,2,3}Teknologi Industri Cetak Kemasan, Teknik Grafika Penerbitan, Politeknik Negeri Jakarta, Kota Depok
Email: ¹wiwi.prastiwinarti@grafika.pnj.ac.id, ²sukmaambar12@gmail.com, ³novi.purnamasari@grafika.pnj.ac.id
^{*}Penulis Korespondensi

(Naskah masuk: 24 Juni 2025, diterima untuk diterbitkan: 30 November 2025)

Abstrak

Ketepatan peramalan kebutuhan persediaan folding box menjadi faktor krusial dalam menjaga kelancaran produksi industri kosmetik, khususnya bagi perusahaan maklon dengan sistem produksi *Make to Order* (MTO). PT X sebagai salah satu perusahaan maklon menghadapi tantangan dalam pengelolaan persediaan kemasan folding box, yang selama ini masih dilakukan secara manual. Ketidakakuratan dalam perencanaan persediaan folding box berpotensi menimbulkan risiko *stock out* dan keterlambatan produksi. Penelitian ini bertujuan untuk membandingkan kinerja empat metode peramalan, yaitu SARIMA, Prophet, XGBoost, dan Random Forest, dalam memprediksi kebutuhan *folding box* berdasarkan data historis periode Januari 2023 hingga Desember 2024. Evaluasi kinerja model dilakukan menggunakan dua metrik utama, yaitu *Root Mean Squared Error* (RMSE) dan *Mean Absolute Percentage Error* (MAPE). Hasil penelitian menunjukkan bahwa model *Random Forest* memberikan performa terbaik dengan RMSE sebesar 14.375,29 dan MAPE sebesar 0,66%, diikuti oleh XGBoost dan Prophet. Temuan ini memperlihatkan bahwa pendekatan *machine learning* lebih unggul dalam menangani pola data persediaan yang fluktuatif dibandingkan model statistik. Penerapan model prediktif ini diharapkan dapat mendukung PT X dalam menyusun strategi pengadaan *folding box* secara lebih tepat guna meminimalkan risiko *stock out* dan meningkatkan efisiensi produksi. Penelitian ini juga membuka peluang pengembangan metode lanjutan berbasis *hybrid* atau *ensemble* untuk meningkatkan akurasi prediksi di masa mendatang.

Kata kunci: peramalan, SARIMA, Prophet, XGBoost, Random Forest

FORECASTING FOLDING BOX PACKAGING INVENTORY FOR STOCK OUT RISK MITIGATION: SARIMA, PROPHET, XGBOOST, AND RANDOM FOREST APPROACHES

Abstract

The accuracy of folding box inventory demand forecasting is a crucial factor in maintaining the smooth operation of the cosmetics industry, especially for contract manufacturing companies with a *Make to Order* (MTO) production system. PT X, as one of the contract manufacturing companies, faces challenges in managing folding box packaging inventory, which has been done manually until now. Inaccuracies in folding box inventory planning have the potential to cause stock-out risks and production delays. This study aims to compare the performance of four forecasting methods—SARIMA, Prophet, XGBoost, and Random Forest—in predicting folding box demand based on historical data from January 2023 to December 2024. Model performance evaluation was conducted using two primary metrics: *Root Mean Squared Error* (RMSE) and *Mean Absolute Percentage Error* (MAPE). The results indicate that the *Random Forest* model performed best with an RMSE of 14.375.29 and a MAPE of 0.66%, followed by XGBoost and Prophet. These findings indicate that machine learning approaches are more effective in handling fluctuating inventory data patterns compared to statistical models. The implementation of these predictive models is expected to support PT X in developing more effective procurement strategies for folding boxes, thereby minimizing the risk of stockouts and improving production efficiency. This research also opens up opportunities for the development of advanced hybrid or ensemble-based methods to enhance prediction accuracy in the future.

Keywords: forecasting, SARIMA, Prophet, XGBoost, Random Forest

1. PENDAHULUAN

Industri kosmetik di Indonesia terus menunjukkan pertumbuhan positif, dengan

peningkatan sebesar 21,9%, dari 913 perusahaan pada tahun 2022 menjadi 1.010 perusahaan pada pertengahan 2023 menurut data Badan Pusat Statistik (BPS) (BADAN PUSAT STATISTIK, 2023). Di

tengah pertumbuhan tersebut, menjaga kelancaran proses produksi menjadi salah satu tantangan utama bagi industri maklon kosmetik, termasuk yang dihadapi oleh PT X. Salah satu aspek krusial dalam proses produksi adalah pengelolaan persediaan bahan baku dan kemasan. Folding box, sebagai salah satu jenis kemasan utama, memegang peranan penting dalam mendukung kelancaran rantai pasok. Ketidakakuratan dalam peramalan kebutuhan folding box berpotensi menimbulkan risiko stock out, yang dapat menyebabkan terganggunya proses produksi hingga berujung pada kerugian finansial (BANANUKA, NAKIBUUKA, OROBIA, & AKISIMIRE, 2020). Oleh karena itu, diperlukan strategi peramalan persediaan yang akurat agar proses bisnis dapat berjalan secara optimal dan efisien.

Menjaga kelancaran proses produksi merupakan tantangan utama dalam industri maklon kosmetik, termasuk yang dihadapi oleh PT X, khususnya terkait pengelolaan persediaan kemasan folding box. PT X merupakan perusahaan maklon kosmetik yang menerapkan sistem produksi Make to Order (MTO), di mana proses produksi dilakukan berdasarkan pesanan dari pelanggan. Produk yang dihasilkan beragam, mulai dari body soap, lotion, serum, scrub, hingga parfum. Di antara berbagai produk tersebut, body soap, serum, dan scrub merupakan produk dengan volume produksi tertinggi. Ketiga produk ini secara umum menggunakan kemasan folding box, botol, dan pot sebagai media pengemasan utama.

Selama periode 2023–2024, total persediaan kemasan yang dikelola mencapai 38.889.489 pcs, dengan folding box sebagai jenis kemasan dominan, yaitu sebanyak 16.739.152 pcs atau setara 43,04% dari total persediaan. Dominasi penggunaan folding box ini menunjukkan bahwa pengelolaan dan peramalan kebutuhan folding box memiliki peranan strategis dalam mendukung kelancaran proses produksi. Oleh karena itu, peramalan persediaan folding box menjadi fokus utama dalam upaya mitigasi risiko stock out dan peningkatan efisiensi rantai pasok di PT X.

Berdasarkan data persediaan kemasan selama periode 2023–2024, folding box merupakan jenis kemasan dengan persentase persediaan tertinggi dari total persediaan. Namun, pengelolaan persediaan folding box di PT X hingga saat ini masih dilakukan secara manual, dengan pembelian bahan baku yang hanya dilakukan setelah adanya pesanan dari pelanggan. Tidak adanya sistem peramalan berbasis data historis menyebabkan sering terjadinya keterlambatan dalam proses pengemasan, terutama pada produk body soap yang menggunakan folding box sebagai kemasan sekundernya. Kekurangan folding box pada saat dibutuhkan berdampak langsung pada keterlambatan pengiriman produk ke konsumen. Oleh karena itu, diperlukan strategi pengelolaan persediaan folding box yang lebih terencana dan berbasis prediksi agar proses produksi

berjalan lebih lancar dan kepuasan pelanggan dapat terjaga.

Untuk mengatasi permasalahan tersebut, penelitian ini menerapkan empat metode peramalan, yaitu SARIMA, Prophet, XGBoost, dan Random Forest. SARIMA dipilih karena kemampuannya dalam memodelkan data deret waktu yang memiliki pola musiman (ASTARI & IHSAN, 2023), sedangkan Prophet dikenal efektif dalam menangkap tren dan musiman pada data dengan fluktuasi tinggi serta bersifat adaptif (WU, et al., 2021). Sementara itu, XGBoost dan Random Forest dipilih sebagai perwakilan dari pendekatan machine learning berbasis pohon keputusan yang unggul dalam menangani pola data non-linear dan kompleks (GEORGAKIS & DIAMANTOPOULOU, 2024). Dengan membandingkan keempat metode tersebut, penelitian ini diharapkan dapat menemukan model prediksi persediaan folding box yang paling akurat sehingga dapat mendukung perencanaan persediaan secara lebih optimal dan meminimalkan risiko stock out.

Pemilihan metode SARIMA, Prophet, XGBoost, dan Random Forest didasarkan pada keunggulan masing-masing dalam menangkap karakteristik data persediaan folding box yang fluktuatif dan memiliki kecenderungan musiman. SARIMA merupakan model statistik yang efektif untuk data deret waktu dengan pola musiman yang berulang secara periodik. Sementara itu, Prophet, yang dikembangkan oleh Facebook, dirancang khusus untuk memodelkan tren, pola musiman, serta pengaruh hari libur pada data time series (AL-HASANI & AL-QARAGULI, 2025). Berbeda dengan keduanya, XGBoost merupakan algoritma machine learning berbasis boosting yang terkenal akan efisiensi dan kemampuannya memodelkan pola data yang non-linear dan kompleks (AMIR, AHMED, HUSSAIN, FATIMA, & ASLAM, 2023). Di sisi lain, Random Forest menggunakan pendekatan bagging dengan membangun banyak pohon keputusan secara acak untuk menghasilkan prediksi yang stabil. Kombinasi keempat metode ini memberikan keragaman pendekatan, mulai dari model statistik konvensional hingga machine learning berbasis pohon keputusan, yang diharapkan mampu meningkatkan akurasi peramalan persediaan folding box.

Akurasi peramalan diukur menggunakan dua metrik utama, yaitu Root Mean Square Error (RMSE) dan Mean Absolute Percentage Error (MAPE). RMSE mengukur rata-rata kesalahan prediksi dengan memberikan bobot lebih besar pada kesalahan yang ekstrem (JURMAN, WARRENS, & CHICCO, 2021), sehingga cocok untuk menilai model pada data yang fluktuatif seperti kebutuhan folding box. Sementara itu, MAPE menyajikan tingkat kesalahan dalam bentuk persentase, sehingga lebih mudah dipahami dalam konteks bisnis (GU, LIN, & LIN, 2022). Kombinasi kedua metrik ini memberikan

gambaran yang lebih menyeluruh terkait tingkat akurasi model dalam memprediksi kebutuhan persediaan folding box.

Beberapa penelitian terdahulu telah membuktikan keefektifan metode SARIMA, Prophet, XGBoost, dan Random Forest dalam berbagai konteks peramalan. Beberapa penelitian terdahulu telah membuktikan efektivitas metode SARIMA, Prophet, XGBoost, dan Random Forest dalam berbagai konteks peramalan. (RAYADIN, MUSARUDDIN, SAPUTRA, & ISNAWATY, 2024) mengembangkan model prediksi penggantian baterai aki mobil menggunakan XGBoost dan Random Forest berbasis data historis 7.703 entri, dengan hasil bahwa model ensemble mampu meningkatkan akurasi prediksi, ditunjukkan oleh nilai MAPE terendah 11,56%.

Sementara itu (PRASTIYO & FEBRIANDIRZA, 2024) membandingkan XGBoost Regression dan Random Forest Regression untuk memprediksi tingkat kemiskinan di DKI Jakarta, dengan hasil Random Forest memberikan akurasi lebih baik (MSE 0,019578 dan MAPE 2,3381). (GUNAWAN & RAMADANI, 2023) membandingkan SARIMA dan Prophet untuk prediksi persediaan barang di PT XYZ, dengan SARIMA unggul (RMSE 3,61). Sementara itu, (SALSABIL, AZIZAH, & EVIYANTI, 2024) menggunakan Random Forest dan XGBoost untuk prediksi penyakit diabetes berbasis data Kaggle, dengan hasil XGBoost memberikan akurasi lebih tinggi sebesar 76% dibanding Random Forest sebesar 74%.

Berdasarkan berbagai penelitian terdahulu, metode SARIMA, Prophet, XGBoost, dan Random Forest telah terbukti efektif dalam peramalan pada berbagai bidang, mulai dari prediksi energi, kesehatan, hingga persediaan barang. Namun, dalam konteks peramalan persediaan kemasan folding box pada industri maklon kosmetik, penelitian yang secara khusus membandingkan kinerja metode SARIMA, Prophet, XGBoost, dan Random Forest secara bersamaan masih terbatas. Penelitian ini berfokus pada penerapan keempat metode tersebut untuk mengidentifikasi model paling akurat dalam memprediksi kebutuhan persediaan kemasan, yang secara langsung berdampak pada kelancaran proses produksi.

Selain itu, penelitian ini juga menggunakan evaluasi kuantitatif melalui parameter RMSE dan MAPE untuk menilai tingkat kedekatan antara hasil prediksi dan data aktual, sehingga memberikan gambaran yang lebih objektif terhadap kinerja model dibandingkan penelitian sebelumnya.

Penelitian ini menggabungkan metode SARIMA, Prophet, XGBoost, dan Random Forest berbasis Python dengan memanfaatkan data historis


persediaan kemasan folding box periode Januari 2023 hingga Desember 2024. Kebaruan dari penelitian ini terletak pada penerapan komparatif antara pendekatan time series dan machine learning dalam memprediksi kebutuhan kemasan folding box produk body soap di PT X, di mana sebelumnya perusahaan masih mengandalkan metode manual dalam perencanaan persediaannya. Salah satu aspek utama dari penelitian ini adalah fokus pada peramalan persediaan kemasan folding box sebagai upaya mitigasi risiko stock out, yang hingga saat ini masih jarang dieksplorasi dalam studi forecasting persediaan berbasis data historis di industri kosmetik.

Melalui pendekatan ini, perusahaan diharapkan dapat memperkirakan kebutuhan folding box secara lebih akurat, sehingga risiko keterlambatan produksi akibat kekurangan persediaan dapat diminimalkan. Selain itu, pengelolaan persediaan yang lebih tepat akan berdampak positif terhadap efisiensi biaya produksi dan meningkatkan daya saing perusahaan di tengah persaingan industri yang semakin ketat. Ke depan, penelitian lanjutan dapat mengembangkan pendekatan ini dengan menerapkan metode ensemble atau hybrid model, serta membandingkan efektivitas model statistik, machine learning, dan deep learning guna meningkatkan akurasi prediksi dan mendukung pengambilan keputusan dalam manajemen rantai pasok yang lebih optimal.

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan tahapan penelitian yang terdiri dari beberapa langkah utama, yaitu pengumpulan data, preprocessing data, penerapan metode peramalan, dan evaluasi kinerja model. Secara umum, metodologi penelitian ini dirancang untuk membandingkan performa empat metode peramalan, yakni SARIMA, Prophet, XGBoost, dan Random Forest, dalam memprediksi kebutuhan persediaan kemasan folding box. Alur penelitian ini dapat dilihat pada Gambar 1 untuk lebih jelasnya.

Penelitian ini dilakukan dengan mengikuti langkah-langkah yang sistematis agar proses peramalan kebutuhan persediaan kemasan folding box dapat dilakukan secara optimal dan akurat. Tahapan penelitian diawali dengan proses pengumpulan data, di mana data yang digunakan merupakan data historis persediaan kemasan folding box produk body soap dari PT X untuk periode Januari 2023 hingga Desember 2024. Data tersebut berupa jumlah penggunaan folding box harian yang diperoleh dari laporan internal perusahaan. Selanjutnya, dilakukan visualisasi data untuk memahami pola yang terdapat dalam data, seperti tren jangka panjang dan fluktuasi musiman penggunaan folding box.



Gambar 1 Alur metodologi penelitian

Visualisasi ini bertujuan untuk mengidentifikasi pola-pola penting yang akan menjadi dasar dalam proses peramalan.

Setelah itu, data melalui tahap preprocessing untuk memastikan kualitasnya, yang meliputi penggabungan data ke dalam format yang seragam, pengecekan missing value yang kemudian diselesaikan dengan metode interpolasi rata-rata, serta deteksi outlier atau nilai yang tidak wajar. Outlier yang ditemukan akan dievaluasi lebih lanjut apakah tetap digunakan atau dihapus, tergantung relevansi terhadap pola data keseluruhan. Setelah data dinyatakan bersih, dilakukan pembagian data menjadi dua bagian, yaitu 80% untuk data pelatihan (training) dan 20% untuk data pengujian (testing), agar model dapat diuji akurasi dengan data yang belum pernah dipelajari sebelumnya (MEMON, ZULFIQAR, USMANI, & QURESHI, 2024).

Proses peramalan dalam penelitian ini menggunakan empat metode, yaitu SARIMA, Prophet, XGBoost, dan Random Forest. SARIMA dan Prophet diterapkan untuk memodelkan data berdasarkan pola musiman dan tren jangka panjang, sedangkan XGBoost dan Random Forest digunakan untuk memodelkan pola data yang lebih kompleks dengan pendekatan machine learning berbasis pohon keputusan. Setelah seluruh model dijalankan, hasil prediksi dibandingkan dengan data aktual untuk mengukur tingkat akurasi menggunakan dua metrik evaluasi, yaitu Root Mean Squared Error (RMSE) dan Mean Absolute Percentage Error (MAPE). Semakin kecil nilai RMSE dan MAPE yang dihasilkan, semakin baik kualitas prediksi dari model tersebut. Pada tahap akhir, hasil peramalan ditampilkan untuk memproyeksikan kebutuhan folding box pada periode waktu tertentu di masa depan. Dengan adanya hasil prediksi ini, PT X diharapkan dapat menyusun strategi pengadaan folding box yang lebih tepat agar risiko stock out

dapat diminimalkan dan proses produksi dapat berjalan lebih lancar serta efisien.

2.1. PENGUMPULAN DATA

Data yang digunakan dalam penelitian ini merupakan data historis persediaan kemasan folding box produk body soap di PT X. Dataset yang digunakan mencakup periode Januari 2023 hingga Desember 2024 dengan frekuensi data harian. Data diperoleh dari catatan internal perusahaan terkait jumlah kemasan folding box yang tersedia dan digunakan dalam proses produksi.

2.2. PREPROCESSING DATA SERTA PEMBAGIAN DATA TRAINING DAN TESTING

Tahap preprocessing dilakukan untuk memastikan kualitas data sebelum memasuki proses pemodelan. Pada tahap ini, data yang hilang atau tidak lengkap diselesaikan menggunakan metode interpolasi agar tidak mengganggu proses analisis selanjutnya. Selain itu, dilakukan identifikasi dan penanganan outlier, di mana data yang terdeteksi sebagai outlier dievaluasi terlebih dahulu untuk menentukan apakah perlu dihapus atau tetap dipertahankan, tergantung relevansinya terhadap pola data secara keseluruhan. Selanjutnya, data juga melalui proses transformasi agar sesuai dengan format dan struktur input yang dibutuhkan oleh masing-masing model peramalan. Setelah data bersih dan siap digunakan, dilakukan pembagian dataset menjadi dua bagian, yaitu 80% digunakan sebagai data pelatihan (training) dan 20% sisanya sebagai data pengujian (testing), guna mengevaluasi performa prediksi dari setiap model secara objektif (SRILAKSHMI, SAHAY, VARDHAN, & GANTA, 2024).

2.3. PENERAPAN METODE PERAMALAN

Penelitian ini menerapkan empat metode peramalan, yaitu SARIMA, Prophet, XGBoost, dan Random Forest, yang dipilih berdasarkan kemampuan masing-masing dalam memodelkan karakteristik data historis persediaan folding box. SARIMA digunakan untuk menangkap pola musiman dalam data deret waktu, dengan penentuan parameter optimal melalui analisis grafik Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF), serta bantuan teknik grid search untuk memperoleh kombinasi parameter terbaik. SARIMA merupakan model deret waktu yang menggabungkan elemen Autoregressive (AR), Moving Average (MA), integrasi (I), serta komponen musiman. Secara umum, model SARIMA dilambangkan dengan notasi SARIMA(p, d, q)(P, D, Q, s), dengan persamaan umum (CHASE, et al., 2021):

$$\Phi_p(B^s)\theta_p(B)(1-B^s)^D(1-B)^d x_t = \theta_q(B^s)\theta_q(B)\omega_t \quad (1)$$

B adalah operator lag, Φ_p dan θ_p adalah parameter AR dan musiman AR, sedangkan θ_q dan θ_q merupakan parameter MA dan musiman MA, d dan D menunjukkan tingkat differencing, serta s adalah periode musiman.

Sementara itu, Prophet digunakan sebagai model berbasis aditif yang secara otomatis mendeteksi tren dan pola musiman dalam data time series, dengan konfigurasi default dan sedikit penyesuaian pada komponen musiman tahunan. Prophet menggunakan pendekatan aditif dengan rumus dasar (NAG, RANJAN, & KUMAR, 2022):

$$y(t) = g(t) + s(t) + h(t) + \varepsilon_t \quad (2)$$

$g(t)$ merepresentasikan tren, $s(t)$ adalah komponen musiman, $h(t)$ adalah pengaruh hari libur (jika ada), dan ε_t adalah error residual. Prophet memecah komponen tren dan musiman secara eksplisit untuk memudahkan interpretasi hasil peramalan.

Berbeda dengan kedua model tersebut, XGBoost dipilih sebagai representasi metode machine learning berbasis boosting yang membangun pohon keputusan secara bertahap untuk meminimalkan kesalahan prediksi, di mana pencarian parameter terbaik dilakukan dengan bantuan GridSearchCV. XGBoost sebagai model machine learning berbasis ensemble boosting memiliki fungsi prediksi sebagai berikut (SALSABIL, AZIZAH, & EVIYANTI, 2024):

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

$\hat{y}_i$ adalah prediksi akhir, f_k adalah fungsi pohon keputusan, dan F merupakan ruang fungsi semua pohon keputusan yang digunakan dalam boosting. Model ini bekerja dengan meminimalkan fungsi objektif yang terdiri atas fungsi loss dan regularisasi untuk menghindari overfitting.

Selanjutnya, Random Forest diterapkan sebagai metode berbasis bagging yang membangun banyak pohon keputusan secara acak dan menggabungkan hasil prediksinya untuk meningkatkan stabilitas dan akurasi. Pemilihan parameter optimal untuk Random Forest dilakukan melalui penyesuaian jumlah pohon keputusan dan kedalaman pohon, sehingga model yang dihasilkan mampu memberikan prediksi yang lebih akurat dan konsisten. Random Forest bekerja dengan membangun banyak pohon keputusan dan menghasilkan prediksi akhir dengan rata-rata dari seluruh prediksi pohon, yang secara matematis ditulis sebagai (PRASTIYO & FEBRIANDIRZA, 2024):

$$\hat{y} = \frac{1}{n} \sum_{i=1}^n T_i(x) \quad (4)$$

$\hat{y}$ adalah nilai prediksi, T_i adalah hasil prediksi dari pohon ke- i , dan n adalah jumlah total pohon.

2.4 EVALUASI MODEL

Evaluasi akurasi model dalam penelitian ini dilakukan menggunakan dua metrik utama, yaitu Root Mean Squared Error (RMSE) dan Mean Absolute Percentage Error (MAPE). RMSE digunakan untuk mengukur rata-rata besar kesalahan kuadrat antara nilai prediksi dan nilai aktual, di mana kesalahan yang lebih besar akan mendapat penalti lebih tinggi. Semakin kecil nilai RMSE, semakin baik kualitas prediksi yang dihasilkan oleh model. Rumus RMSE dituliskan sebagai berikut (JURMAN, WARRENS, & CHICCO, 2021):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (5)$$

y_i menunjukkan nilai aktual pada data ke- i , sedangkan $\hat{y}_i$ adalah nilai hasil prediksi pada data ke- i . Sementara itu, n menyatakan jumlah total data yang digunakan dalam perhitungan.

Selain itu, digunakan juga MAPE yang menyajikan tingkat kesalahan prediksi dalam bentuk persentase terhadap nilai aktual, sehingga lebih mudah diinterpretasikan dalam konteks bisnis. Nilai MAPE yang rendah menunjukkan bahwa model memiliki tingkat kesalahan yang kecil secara proporsional terhadap data aktual. Berikut adalah rumus perhitungan MAPE (JURMAN, WARRENS, & CHICCO, 2021):

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (6)$$

y_i adalah nilai aktual pada data ke- i , sedangkan $\hat{y}_i$ merupakan nilai hasil prediksi pada data ke- i . Simbol n menunjukkan jumlah total data. MAPE dihitung dengan cara mengambil rata-rata dari nilai absolut selisih antara nilai aktual dan prediksi, lalu dibagi dengan nilai aktual dan dikalikan 100%.

Nilai RMSE digunakan untuk melihat rata-rata besar kesalahan absolut kuadrat, sedangkan MAPE menyatakan persentase rata-rata kesalahan prediksi terhadap nilai aktual. Penggunaan kedua metrik ini memberikan gambaran yang menyeluruh terhadap tingkat akurasi prediksi model yang digunakan dalam penelitian ini. Menggunakan kedua metrik ini, kinerja setiap model dapat dinilai secara objektif untuk menentukan metode peramalan terbaik yang paling sesuai dalam memprediksi kebutuhan persediaan kemasan folding box di PT X.

3. HASIL DAN PEMBAHASAN

3.1. DESKRIPSI DAN VISUALISASI DATA


Data yang digunakan dalam penelitian ini merupakan data historis persediaan kemasan folding box untuk produk body soap di PT X. Dataset mencakup periode Januari 2023 hingga Desember 2024 dengan frekuensi pencatatan harian. Data ini diperoleh dari catatan internal perusahaan yang mendokumentasikan jumlah folding box yang tersedia dan digunakan dalam proses produksi setiap harinya. Folding box dipilih sebagai objek penelitian karena merupakan jenis kemasan dengan jumlah persediaan terbesar dibandingkan jenis kemasan lainnya, yaitu sebesar 43,04% dari total persediaan kemasan selama periode tersebut. Dominasi penggunaan folding box ini menjadikan kebutuhan akan prediksi persediaannya sangat penting untuk menjamin kelancaran proses produksi. Untuk memahami karakteristik data sebelum dilakukan proses peramalan, dilakukan tahap visualisasi data dalam bentuk grafik deret waktu (time series plot) pada Gambar 2.

Visualisasi ini memperlihatkan pola fluktuasi harian penggunaan folding box, termasuk tren jangka panjang dan kecenderungan musiman. Hasil visualisasi menunjukkan adanya pola musiman dengan kecenderungan peningkatan permintaan pada periode-periode tertentu, yang kemungkinan besar berkaitan dengan lonjakan pesanan produksi kosmetik dari pelanggan. Selain itu, ditemukan juga fluktuasi penggunaan folding box yang cukup signifikan. Pola musiman yang muncul ini mendukung penerapan metode peramalan berbasis time series seperti SARIMA dan Prophet, serta model machine learning berbasis pohon keputusan seperti XGBoost dan Random Forest untuk menangkap pola fluktuasi yang bersifat non-linear. Melalui visualisasi ini pula dapat diidentifikasi adanya nilai ekstrem (outlier) dan data hilang (missing value), yang kemudian ditangani pada tahap preprocessing agar data siap digunakan dalam proses pemodelan.


3.2. PREPROCESSING DATA SERTA PEMBAGIAN DATA TRAINING DAN TESTING

Sebelum proses peramalan dilakukan, data historis persediaan folding box melalui tahap preprocessing untuk memastikan kualitasnya. Langkah pertama adalah memeriksa adanya missing value. Nilai yang kosong diisi menggunakan interpolasi rata-rata agar pola data tetap stabil tanpa mengubah tren secara signifikan. Selanjutnya dilakukan identifikasi outlier, yaitu nilai yang terlalu rendah atau terlalu tinggi dibanding pola normal. Setiap outlier dievaluasi kembali apakah masih relevan atau perlu dihapus agar tidak menimbulkan bias pada hasil prediksi.

Setelah data bersih dan siap digunakan, dataset dibagi menjadi dua bagian, yaitu 80 persen untuk training dan 20 persen untuk testing. Pembagian ini divisualisasikan pada Gambar 3.



Gambar 2 Grafik persediaan bahan baku folding box Januari 2023 – Desember 2024



Gambar 3 Grafik pembagian data train dan data test

Data training digunakan untuk membangun model, sedangkan data testing digunakan untuk menilai kemampuan model dalam memprediksi data baru. Pembagian dilakukan secara berurutan sesuai waktu agar pola deret waktu tetap terjaga. Dengan preprocessing dan pembagian data yang tepat, model diharapkan mampu menghasilkan prediksi yang akurat dan mendukung perencanaan persediaan folding box di PT X.

3.3. PENGATURAN PERCOBAAN

Tabel 1 Konfigurasi hyperparameter model peramalan

Model	Hyperparameter	Abbreviation	Setting
Random Forest	Number of Trees	n-estimator	100
	Max Depth of Trees	max-depth	6
XGBoost	Number of Trees	n-estimator	50
	Max Depth of Trees	max-depth	3
	Learning Rate	lr	0.3
SARIMA	Number of Autoregressive Terms	p	1
	Number of Nonseasonal Differences for Stationarity	d	1
	Number of Lagged Forecast Errors	q	1
	Number of Seasonal Autoregressive Terms	P	1
	Number of Seasonal Differences	D	1
	Number of Lagged Seasonal Forecast Errors	Q	1
	Length of Seasonal Period	s	30
	Changeoint	CPS	default (0.05)
	Prior Scale		
	Seasonality Mode	SM	Additive (daily and weekly)
FB Prophet	Holidays	–	Not applied

Eksperimen pada penelitian ini dilakukan menggunakan Python dengan pustaka utama: statsmodels untuk SARIMA, Prophet untuk model aditif, serta scikit-learn dan xgboost untuk Random Forest dan XGBoost. Visualisasi dibuat menggunakan matplotlib dan seaborn, sedangkan evaluasi model memanfaatkan fungsi evaluasi dari scikit-learn.


Pemodelan dimulai dengan SARIMA, di mana pemilihan parameter (p , d , q) dan (P , D , Q , s) ditentukan melalui analisis ACF–PACF dan uji coba grid search. Model Prophet digunakan dengan parameter standar yang disesuaikan dengan musiman tahunan pada data persediaan folding box.

Untuk model machine learning, XGBoost dan Random Forest dioptimalkan menggunakan GridSearchCV. Parameter yang dituning mencakup `n_estimators`, `max_depth`, serta `learning_rate` untuk XGBoost. Pada Random Forest, fokus tuning pada `n_estimators` dan `max_depth`. Konfigurasi hyperparameter lengkap disajikan pada Tabel 1.

Setelah semua model diterapkan, hasil prediksi dari data testing dibandingkan dengan data aktual untuk mengukur tingkat akurasi menggunakan dua metrik utama, yaitu Root Mean Squared Error (RMSE) dan Mean Absolute Percentage Error (MAPE). Pengaturan eksperimen ini dilakukan secara sistematis agar setiap model diuji dalam kondisi yang seragam, sehingga hasil perbandingan dapat menjadi acuan dalam menentukan model terbaik untuk peramalan kebutuhan folding box di PT X.

3.4. PENERAPAN MODEL

Implementasi model peramalan dalam penelitian ini melibatkan empat metode utama, yaitu SARIMA, Prophet, XGBoost, dan Random Forest. Pemilihan keempat metode ini didasarkan pada kemampuan masing-masing dalam memodelkan pola deret waktu dan menangkap hubungan non-linear pada data persediaan folding box. Sebelum model diterapkan, dilakukan pengujian stasioneritas data menggunakan Augmented Dickey-Fuller (ADF) Test untuk memastikan bahwa data telah memenuhi asumsi stasioner.



Gambar 4 Grafik perbandingan nilai prediksi SARIMA dengan aktual (data test)


Berdasarkan hasil uji ADF diperoleh ADF Statistic sebesar -5.907 dengan p-value sebesar 0.000000268 , yang berada jauh di bawah batas signifikansi $0,05$. Hal ini menunjukkan bahwa data sudah bersifat stasioner dan dapat digunakan untuk proses pemodelan lebih lanjut, khususnya dengan metode SARIMA.

Model SARIMA yang digunakan memiliki konfigurasi parameter $(1,1,1)(1,1,1,30)$, yang dipilih berdasarkan hasil analisis Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF). Visualisasi hasil prediksi SARIMA dibandingkan dengan data aktual ditampilkan pada Gambar 4. Berdasarkan grafik tersebut, terlihat bahwa pola prediksi SARIMA mampu mengikuti tren musiman jangka panjang, tetapi masih menunjukkan deviasi yang cukup besar terhadap fluktuasi nilai aktual harian. Model SARIMA lebih baik dalam menangkap pola jangka panjang, namun kurang responsif terhadap fluktuasi mendadak yang terjadi dalam data aktual.


Selanjutnya, diterapkan model Prophet dengan konfigurasi standar menggunakan komponen musiman harian dan mingguan. Hasil prediksi Prophet ditampilkan pada Gambar 5. Berdasarkan grafik tersebut, Prophet memberikan prediksi yang lebih halus dan cenderung konservatif, mengikuti tren penurunan pada periode tertentu, namun juga masih

memiliki gap yang cukup besar terhadap nilai aktual harian. Hal ini menunjukkan bahwa Prophet lebih optimal dalam mendeteksi tren musiman, tetapi kurang mampu menangkap variasi mendadak dalam data persediaan folding box.


Implementasi model XGBoost dan Random Forest dilakukan dengan pendekatan machine learning, memanfaatkan hasil preprocessing sebelumnya sebagai fitur input. Hyperparameter untuk kedua model telah dioptimalkan menggunakan GridSearchCV agar menghasilkan performa prediksi yang optimal. Hasil prediksi model XGBoost terhadap data aktual ditampilkan pada Gambar 6. Secara visual, grafik menunjukkan bahwa prediksi XGBoost mampu mengikuti pola fluktuatif dari data aktual dengan cukup baik. Garis prediksi (berwarna merah) memperlihatkan kecenderungan mengikuti pergerakan naik-turun dari data aktual (berwarna biru), meskipun pada beberapa titik tertentu tampak sedikit lebih halus. Sifat boosting yang menjadi dasar algoritma XGBoost membuat model berfokus pada pengurangan kesalahan secara bertahap, sehingga cenderung memberikan prediksi yang stabil. Namun, hal ini juga menyebabkan XGBoost terkadang kurang responsif terhadap lonjakan mendadak yang terjadi dalam data aktual persediaan folding box.



Gambar 5 Grafik perbandingan nilai prediksi Prophet dengan aktual (data test)



Gambar 6 Grafik perbandingan nilai prediksi XGBoost dengan aktual (data test)



Gambar 7 Grafik perbandingan nilai prediksi Random Forest dengan aktual (data test)

Sementara itu, hasil prediksi model Random Forest dapat dilihat pada Gambar 7. Grafik memperlihatkan bahwa Random Forest mampu menangkap fluktuasi data aktual secara lebih konsisten dibandingkan XGBoost. Garis prediksi Random Forest cenderung lebih mengikuti pola naik-turun dari data aktual, terutama pada periode pertengahan hingga akhir tahun 2024. Hal ini menunjukkan kemampuan Random Forest dalam memodelkan variasi lokal dengan lebih baik berkat mekanisme bagging yang menghasilkan prediksi rata-rata dari banyak pohon keputusan. Secara keseluruhan, Random Forest menunjukkan kinerja yang lebih akurat dalam memprediksi kebutuhan folding box harian.

Dengan demikian, hasil visualisasi dari kedua model machine learning ini mendukung hasil evaluasi metrik yang menunjukkan bahwa Random Forest memiliki performa terbaik, diikuti oleh XGBoost, dalam memprediksi kebutuhan persediaan folding box. Temuan ini memperkuat keunggulan pendekatan ensemble learning berbasis pohon keputusan dalam menghadapi data dengan pola fluktuatif dan tidak beraturan seperti pada kebutuhan produksi di PT X.

3.5. PERBANDINGAN KINERJA MODEL PERALAMAN


Setelah seluruh model diterapkan, dilakukan evaluasi kinerja masing-masing metode

menggunakan dua metrik utama, yaitu Root Mean Squared Error (RMSE) dan Mean Absolute Percentage Error (MAPE). Penggunaan kedua metrik ini bertujuan untuk menilai seberapa dekat hasil prediksi model terhadap nilai aktual persediaan folding box, baik dari segi besar kesalahan absolut maupun dalam bentuk persentase. Semakin kecil nilai RMSE dan MAPE yang dihasilkan, maka semakin baik performa prediksi model tersebut. Tabel 2 berikut menyajikan perbandingan hasil evaluasi antara keempat model yang digunakan:

Tabel 2 Hasil Evaluasi Model Peramalan

Model	RMSE	MAPE
SARIMA	49.793,50	3,31%
Prophet	14.613,70	0,77%
XGBoost	15.715,28	0,75%
Random Forest	14.375,29	0,66%

Berdasarkan hasil evaluasi pada Tabel 4, terlihat bahwa model Random Forest menghasilkan performa terbaik dengan RMSE sebesar 14.375,29 dan MAPE sebesar 0,66%, lebih rendah dibandingkan ketiga model lainnya. Sementara itu, XGBoost dan Prophet juga menunjukkan akurasi yang cukup baik dengan selisih nilai yang tipis.



Gambar 8 Permalan persediaan folding box pada tahun 2025

Di sisi lain, model SARIMA menghasilkan kesalahan prediksi paling tinggi, baik dari segi RMSE maupun MAPE, yang menunjukkan bahwa model statistik kurang efektif dalam memprediksi fluktuasi persediaan folding box harian di PT X. Hasil ini menegaskan bahwa pendekatan machine learning, khususnya Random Forest, lebih adaptif dalam menangani pola data yang fluktuatif dan non-linear.

Pemanfaatan model prediksi terbaik memungkinkan perusahaan menyusun strategi pengadaan persediaan folding box secara lebih tepat, sehingga risiko kehabisan stok dapat ditekan dan proses produksi berlangsung lebih efisien.

3.6. MERAMALKAN DATA PERSEDIAAN FOLDING BOX MENGGUNAKAN MODEL TERBAIK

Hasil evaluasi menunjukkan bahwa Random Forest menjadi model terbaik dengan RMSE 14.375,29 dan MAPE 0,66%, sehingga digunakan untuk meramalkan kebutuhan persediaan folding box selama tahun 2025. Visualisasi peramalan dapat dilihat pada Gambar 8, di mana garis biru menunjukkan data aktual tahun 2023–2024 dan garis oranye menggambarkan prediksi tahun 2025. Grafik memperlihatkan pola prediksi yang tetap fluktuatif namun lebih stabil dibandingkan data historis, dengan kecenderungan nilai yang mendatar dan konsisten sesuai karakteristik hasil pemodelan Random Forest.

Prediksi ini dapat menjadi acuan bagi PT X dalam merencanakan pengadaan folding box secara lebih terstruktur. Dengan estimasi kebutuhan satu tahun ke depan, perusahaan dapat mengurangi risiko stock out, meningkatkan efisiensi operasional, serta menyesuaikan strategi jika terjadi perubahan tren atau permintaan pasar.

4. KESIMPULAN

Hasil penelitian menunjukkan bahwa metode SARIMA, Prophet, XGBoost, dan Random Forest

menghasilkan kinerja yang berbeda dalam peramalan persediaan folding box. Model Random Forest memberikan hasil terbaik dengan RMSE 14.375,29 dan MAPE 0,66%, menunjukkan bahwa pendekatan ensemble learning lebih efektif untuk data yang fluktuatif dan non-linear. Sementara itu, model time series seperti SARIMA kurang mampu menangkap variasi mendadak meskipun tetap menggambarkan tren musiman dengan baik.

Penerapan model prediktif ini dapat membantu PT X dalam menyusun strategi pengadaan folding box yang lebih terencana, sehingga risiko stock out dapat diminimalkan. Dengan prediksi kebutuhan persediaan yang lebih akurat, perusahaan dapat mengurangi pemborosan biaya akibat pembelian mendadak atau kelebihan stok, sekaligus meningkatkan efisiensi dalam proses produksi.

Penelitian selanjutnya dapat mengembangkan model hybrid yang menggabungkan keunggulan time series dan machine learning, atau mengeksplorasi metode berbasis deep learning untuk meningkatkan akurasi prediksi. Selain itu, integrasi variabel eksternal seperti tren penjualan, jadwal produksi, dan faktor musiman dapat memperkuat hasil peramalan, sehingga mendukung efisiensi operasional dan pengambilan keputusan dalam pengelolaan rantai pasok.

DAFTAR PUSTAKA

- AL-HASANI, A., & AL-QARAGULI, M. 2025. Seasonal Temperature Prediction in Niamey: A Prophet Model Approach. *EDRAAK*, 7-11. doi:<https://doi.org/10.70470/EDRAAK/2025/002>
- AMIR, S., AHMED, S., HUSSAIN, A., FATIMA, S., & ASLAM, S. 2023. XGBoost and Random Forest Algorithms: An in Depth Analysis. *Pakistan Journal of Scientific Research*, 3(1), 26–31.

- doi:<https://doi.org/10.57041/vol3iss1pp26-31>
- ASTARI, A., & IHSAN, T. 2023. Peramalan Persediaan Obat Flu Dan Batuk Merek Snf Untuk Tahun 2024 Di Gudang Pt Bcd Menggunakan Metode Dekomposisi. *Jurnal Lebesgue : Jurnal Ilmiah Pendidikan Matematika, Matematika dan Statistika*, 4(3), 1719-1726. doi:<https://doi.org/10.46306/lb.v4i3.511>
- BADAN PUSAT STATISTIK.2023. *Pertumbuhan produksi tahunan Y-on-Y industri skala mikro dan kecil menurut 2-digit KBLI [Statistik]*. Retrieved Juni 21, 2025, from Produk - Tabel Statistik: <https://www.bps.go.id/id/statistics-table/2/NDAwIzI=/pertumbuhan-produksi-tahunan-y-on-y-industri-skala-mikro-dan-kecil-menurut-2-digit-kbli.html>
- BANANUKA, J., NAKIBUUKA, J., OROBIA, L., & AKISIMIRE, R. 2020. Inventory management, managerial competence and financial performance of small businesses. *Journal of Accounting in Emerging Economies*, 10(3), 379-398. doi:<https://doi.org/10.1108/JAEE-07-2019-0147>
- CHASE, O., SANTOS, P., DA SILVA ROCHA, Y., FREITAS, D., MARQUES, G., BELTRÃO, P. SANTOS, D. 2021. Time-series forecasting models. *International Journal for Innovation Education and Research*, 9(8), 24-47. doi:<https://doi.org/10.31686/ijer.vol9.iss8.3239>
- GEORGAKIS, A., & DIAMANTOPOULOU, M. 2024. Improving European Black Pine Stem Volume Prediction Using Machine Learning Models with Easily Accessible Field Measurements. *Forests*, 15(12), 2251. doi:<https://doi.org/10.3390/f15122251>
- GU, D., LIN, A., & LIN, G. 2022. Using support vector regression and K-nearest neighbors for short-term traffic flow prediction based on maximal information coefficient. *Information Sciences*, 608, 517-531. doi:<https://doi.org/10.1016/j.ins.2022.06.090>
- GUNAWAN, W., & RAMADANI, M. 2023. Analisa Perbandingan Penerapan Metode SARIMA dan Prophet dalam Memprediksi Persediaan Barang PT XYZ. *Faktor Exacta*, 16(2), 88-97. doi:<http://dx.doi.org/10.30998/faktorexacta.v16i2.13803>
- JURMAN, G., WARRENS, M., & CHICCO, D. 2021. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7. doi:<https://doi.org/10.7717/peerj-cs.623>
- MEMON, Z., ZULFIQAR, A., USMANI, M., & QURESHI, R. 2024. Preptimize: Automation of Time Series Data Preprocessing and Forecasting. *Algorithms*, 17(8), 332. doi:<https://doi.org/10.3390/a17080332>
- NAG, A., RANJAN, R., & KUMAR, C. 2022. An Approach on Cyber Crime Prediction Using Prophet Time Series. *2022 IEEE 7th International conference for Convergence in Technology (I2CT)*. Mumbai, India: IEEE. doi:<https://doi.org/10.1109/I2CT54291.2022.9825386>
- PRASTIYO, I., & FEBRIANDIRZA, A. 2024. Analisis Perbandingan Prediksi Tingkat Kemiskinan Menggunakan Metode XGBoost dan Random Forest Regression. *Jurnal Media Informatika Budidarma*, 8(3), 1694-1705. doi:<https://doi.org/10.30865/mib.v8i3.7892>
- RAYADIN, M., MUSARUDDIN, M., SAPUTRA, R., & ISNAWATY, I. 2024. Implementasi Ensemble Learning Metode XGBoost dan Random Forest untuk Prediksi Waktu Penggantian Baterai Aki. *BIOS : Jurnal Teknologi Informasi Dan Rekayasa Komputer*, 5(2), 111-119. doi:<https://doi.org/10.37148/bios.v5i2.128>
- SALSABIL, M., AZIZAH, N., & EVIYANTI, A. 2024. Implementasi Data Mining Dalam Melakukan Prediksi Penyakit Diabetes Menggunakan Metode Random Forest Dan Xgboost. *Jurnal Ilmiah Komputasi*, 23(1), 51-58. doi:<https://doi.org/10.32409/jikstik.23.1.3507>
- SRILAKSHMI, K., SAHAY, M., VARDHAN, B., & GANTA, S. 2024. A Comprehensive Study on Improving Time Series Forecasting Precision. *Seminars in Medical Writing and Education*, 3. doi:<https://doi.org/10.56294/mw2024.588>
- WU, R., YANG, W., HUANG, S., LI, M., ZHANG, P., WEN, H., . . . CAI, J. 2021. Trend analysis and forecast of daily reported incidence of hand, foot and mouth disease in Hubei, China by Prophet model. *Scientific Reports*, 11, 144. doi:<https://doi.org/10.1038/s41598-021-81100-2>