



Department of Digital Business

Journal of Artificial Intelligence and Digital Business (RIGGS)

Homepage: <https://journal.ilmudata.co.id/index.php/RIGGS>

Vol. 5 No. 1 (2026) pp: 4168-4177

P-ISSN: 2963-9298, e-ISSN: 2963-914X

Pengembangan *Dashboard* Prediksi Permintaan Berbasis SARIMAX-XGBoost untuk Mendukung Pengambilan Keputusan

Erly Ekayanti Rosyida¹, Nisa Isrofi², Regita Permata Puteri³, Lathifa Puteri Asy'ari⁴, Maria Faulina Puteri Tanasa⁵, Agustina Marito Simatupang⁶, Inez Rexana⁷

¹Program Studi Teknik Logistik, Direktorat Kampus Surabaya, Universitas Telkom, Indonesia

³Program Studi Sains Data, Direktorat Kampus Surabaya, Universitas Telkom, Indonesia

erlyekyantirosyida@telkomuniversity.ac.id

Abstrak

Peramalan permintaan yang akurat merupakan elemen penting dalam mendukung analisis dan perencanaan operasional, khususnya pada industri makanan yang memiliki karakteristik permintaan fluktuatif serta dipengaruhi faktor eksternal seperti harga dan promosi. Pendekatan peramalan konvensional yang hanya mengandalkan data historis seringkali belum mampu menangkap kompleksitas pola permintaan secara optimal, terutama ketika permintaan dipengaruhi kombinasi faktor musiman, tren jangka menengah, serta variabel eksternal yang bersifat dinamis. Kondisi ini mendorong perlunya pengembangan pendekatan peramalan yang lebih adaptif dan komprehensif dengan memanfaatkan integrasi metode statistik dan machine learning. Penelitian ini bertujuan untuk mengembangkan model prediksi permintaan berbasis integrasi metode statistik dan machine learning serta menyajikan hasilnya dalam dashboard visualisasi yang informatif. Metode Seasonal AutoRegressive Integrated Moving Average with Exogenous Variables (SARIMAX) digunakan untuk memodelkan pola tren dan musiman pada data deret waktu, algoritma Extreme Gradient Boosting (XGBoost) diterapkan untuk menangkap hubungan nonlinier dan interaksi kompleks antarvariabel. Data yang digunakan berupa data permintaan bulanan dilengkapi variabel harga dan promosi sebagai variabel eksogen. Kinerja model dievaluasi menggunakan metrik Mean Absolute Error (MAE), Root Mean Square Error (RMSE), dan Mean Absolute Percentage Error (MAPE). Hasil penelitian menunjukkan bahwa model XGBoost menghasilkan akurasi yang lebih baik dibandingkan SARIMAX, sementara model hybrid SARIMAX-XGBoost memberikan kinerja terbaik dengan nilai MAPE sebesar 4,61%. Selanjutnya, hasil prediksi divisualisasikan dalam dashboard prediksi permintaan menggunakan Google Looker Studio untuk memudahkan analisis pola permintaan, perbandingan hasil prediksi antar model, serta interpretasi pengaruh variabel harga dan promosi. Penelitian ini berkontribusi dalam pengembangan pendekatan prediksi permintaan terintegrasi dan penyajian visualisasi prediktif sebagai alat bantu analisis berbasis data.

Kata kunci: Peramalan Permintaan, SARIMAX, XGBoost, Dashboard Prediksi, Visualisasi Data

1. Latar Belakang

Dalam lingkungan bisnis yang semakin dinamis dan kompetitif, kemampuan perusahaan dalam melakukan prediksi permintaan secara akurat menjadi faktor kunci dalam mendukung pengambilan keputusan strategis, khususnya pada aspek pengelolaan persediaan dan perencanaan produksi (Made et al., 2023). Akurasi prediksi permintaan berperan penting dalam menjaga keseimbangan antara tingkat pelayanan pelanggan dan efisiensi biaya operasional. Ketidaktepatan dalam perencanaan berpotensi menyebabkan ketidakseimbangan antara ketersediaan dan kebutuhan pelanggan, yang pada akhirnya berdampak pada peningkatan biaya, penurunan kinerja operasional, serta berkurangnya daya saing perusahaan.

Tantangan tersebut menjadi semakin kompleks pada industri sektor makanan dan minuman yang memiliki karakteristik permintaan fluktuatif, umur simpan produk yang relatif pendek, serta sensitivitas tinggi terhadap kondisi penyimpanan dan distribusi. Dalam konteks ini, kesalahan dalam memprediksi permintaan tidak hanya menyebabkan kelebihan atau kekurangan stok, tetapi juga berimplikasi langsung pada peningkatan produk kedaluwarsa, pemborosan sumber daya, dan penurunan tingkat layanan kepada konsumen. Oleh karena itu, diperlukan alat bantu analitis yang mampu memberikan wawasan prediktif secara akurat dan adaptif guna mendukung efisiensi operasional serta daya saing perusahaan (Riza, 2022)

Seiring dengan perkembangan teknologi analitik dan kecerdasan buatan, pendekatan peramalan permintaan tidak lagi terbatas pada metode statistik konvensional yang hanya mengandalkan pola historis. Metode tradisional tersebut sering kali belum mampu menangkap kompleksitas dinamika pasar yang dipengaruhi oleh berbagai faktor eksternal, seperti fluktuasi harga, aktivitas promosi, serta perubahan preferensi konsumen, yang memiliki pengaruh signifikan terhadap perilaku permintaan (Tejhovati et al., 2020). Ketergantungan pada pola data permintaan historis saja menyebabkan model peramalan kurang adaptif terhadap perubahan kondisi pasar yang bersifat dinamis, khususnya pada sektor dengan tingkat ketidakpastian yang tinggi seperti industri makanan dan minuman.

Sejumlah penelitian terdahulu telah mengembangkan pendekatan peramalan berbasis statistik maupun machine learning untuk meningkatkan akurasi prediksi permintaan. Sejumlah penelitian terdahulu telah mengembangkan pendekatan peramalan berbasis statistik maupun machine learning untuk meningkatkan akurasi prediksi permintaan. Model statistik seperti ARIMA dan SARIMA banyak digunakan karena kemampuannya dalam menangkap pola tren dan musiman secara historis, namun memiliki keterbatasan dalam memodelkan hubungan nonlinier dan pengaruh faktor eksternal secara kompleks (Tejhovati et al., 2020). Di sisi lain, pendekatan machine learning seperti Random Forest dan XGBoost terbukti mampu menangkap hubungan nonlinier dan interaksi antarvariabel, tetapi sering kali kurang efektif dalam merepresentasikan struktur musiman jangka panjang apabila digunakan secara terpisah (Chen & Guestrin, 2026; Tejhovati et al., 2020)

Meskipun demikian, sebagian besar studi masih memodelkan permintaan secara parsial dengan mengandalkan salah satu pendekatan tersebut secara terpisah. Pendekatan semacam ini belum sepenuhnya mampu mengakomodasi dinamika permintaan yang dipengaruhi oleh kombinasi pola musiman, tren jangka panjang, serta variabel eksternal strategis seperti harga dan aktivitas promosi. Akibatnya, kemampuan model dalam merepresentasikan perilaku permintaan yang kompleks menjadi terbatas, khususnya pada sektor dengan tingkat sensitivitas harga yang tinggi seperti industri makanan dan minuman.

Lebih lanjut, sejumlah penelitian menunjukkan bahwa pengabaian variabel lain selain data permintaan dalam proses peramalan dapat menyebabkan penurunan akurasi prediksi dan meningkatkan risiko kesalahan pengambilan keputusan operasional. Kondisi ini memperkuat urgensi pengembangan pendekatan peramalan terintegrasi yang mampu mengombinasikan keunggulan model statistik dan machine learning dalam satu kerangka analisis yang komprehensif.

Berdasarkan hal tersebut, penelitian ini mengkaji integrasi dua metode prediksi yaitu metode SARIMAX dan XGBoost yang didasarkan pada keunggulan komplementer dari masing-masing pendekatan dalam menangkap karakteristik data permintaan yang kompleks. SARIMAX memiliki kemampuan yang kuat dalam memodelkan pola musiman, tren jangka panjang, serta pengaruh variabel eksogen secara linier, sehingga efektif digunakan untuk merepresentasikan struktur temporal permintaan. Namun, model ini memiliki keterbatasan dalam menangkap hubungan nonlinier dan interaksi kompleks antarvariabel yang sering muncul pada data permintaan actual. Pendekatan hibrida antara SARIMAX dan XGBoost diharapkan mampu menghasilkan prediksi permintaan yang lebih akurat dan robust dibandingkan penggunaan satu metode secara tunggal. Dalam kerangka ini, SARIMAX berperan dalam menangkap struktur dasar deret waktu dan pengaruh musiman, sementara XGBoost mempelajari pola residual dan pengaruh variabel eksternal yang bersifat nonlinier. Integrasi kedua metode tersebut memungkinkan pemodelan permintaan yang lebih adaptif terhadap perubahan kondisi aktual, sekaligus meningkatkan stabilitas dan keandalan hasil prediksi.

Selain integrasi metode prediksi, penelitian ini juga merancang sebuah *dashboard* prediksi permintaan sebagai media visualisasi dan sistem pendukung keputusan (Khaw et al., 2025; Samantha et al., 2024; Sunendar, 2025). *Dashboard* dirancang untuk menyajikan hasil peramalan secara informatif, interaktif, dan mudah dipahami oleh pengambil keputusan, sehingga dapat digunakan secara langsung dalam proses perencanaan produksi dan pengendalian persediaan. Melalui visualisasi tren permintaan, proyeksi jangka pendek, serta pengaruh variabel eksternal seperti harga dan promosi, *dashboard* ini diharapkan mampu membantu manajemen dalam merespons perubahan permintaan secara lebih cepat dan tepat. Dengan demikian, integrasi model prediksi dan *dashboard* tidak hanya berfungsi sebagai alat analisis, tetapi juga sebagai instrumen strategis dalam mendukung pengambilan keputusan berbasis data yang berorientasi pada efisiensi dan keberlanjutan operasional.

2. Metode Penelitian

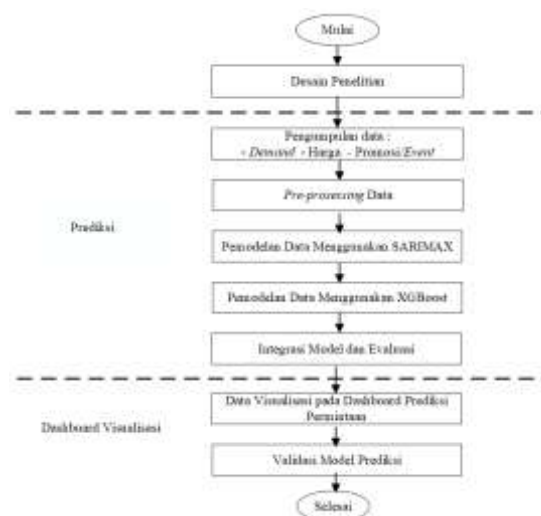
Menjelaskan metode penelitian dan teknik penelitian yang digunakan. Jelaskan secara ringkas, tetapi tetap akurat Penelitian ini dirancang untuk mengembangkan sistem prediksi permintaan berbasis integrasi metode statistik dan *machine learning* yang mampu mendukung pengambilan keputusan operasional secara efektif. Tahapan penelitian dijelaskan dalam Gambar 1.

Penelitian ini bertujuan untuk mengembangkan model prediksi permintaan dan menyajikan hasilnya dalam bentuk visualisasi yang informatif sebagai dasar analisis dan pengambilan keputusan berbasis data. Pendekatan penelitian yang digunakan adalah pendekatan kuantitatif dengan metode pemodelan prediktif berbasis data historis dan variabel pendukung.

Tahap awal penelitian difokuskan pada perancangan kerangka penelitian yang mencakup penentuan tujuan, ruang lingkup, serta pendekatan analisis yang digunakan. Penelitian ini dirancang untuk menghasilkan model prediksi permintaan dan visualisasi hasil prediksi. Pada tahap ini juga ditentukan variabel utama, sumber data, serta metode pemodelan yang digunakan.

Data yang digunakan dalam penelitian terdiri atas data historis permintaan dan data pendukung yang relevan terhadap pola permintaan. Data historis mencerminkan dinamika permintaan pada periode tertentu, sedangkan data pendukung berupa faktor musiman, promosi, dan harga produk yang berpotensi mempengaruhi fluktuasi permintaan. Seluruh data dikumpulkan dari perusahaan yang terdokumentasi.

Tahap selanjutnya adalah tahap preprocessing dilakukan untuk meningkatkan kualitas data sebelum proses pemodelan. Proses ini mencakup pembersihan data dan identifikasi dan penyesuaian *outlier*, serta transformasi data bila diperlukan. Preprocessing bertujuan untuk memastikan bahwa data yang digunakan memenuhi asumsi model dan mampu menghasilkan prediksi yang stabil dan reliabel.



Gambar 1. Tahapan Perancangan *Dashboard* Prediksi Permintaan

Untuk selanjutnya adalah Pemodelan Prediksi Menggunakan SARIMAX. Model *Seasonal AutoRegressive Integrated Moving Average with Exogenous Variables* (SARIMAX) digunakan untuk memodelkan pola deret waktu dengan mempertimbangkan efek musiman dan variabel eksternal. Model ini dipilih karena kemampuannya dalam menangkap karakteristik temporal data serta hubungan antara variabel eksogen dan variabel target. Hasil dari tahap ini berupa nilai prediksi permintaan berdasarkan pendekatan statistik.

Selain pendekatan statistik, penelitian ini juga menerapkan metode *Extreme Gradient Boosting* (XGBoost) sebagai pendekatan berbasis machine learning. Model ini digunakan untuk menangkap hubungan non-linear dan kompleks antar variabel yang tidak selalu dapat direpresentasikan oleh model deret waktu konvensional. XGBoost diharapkan mampu memberikan alternatif prediksi yang lebih adaptif terhadap variasi data.

Hasil prediksi dari model SARIMAX dan XGBoost dievaluasi menggunakan metrik kinerja seperti *Mean Absolute Error (MAE)*, *Root Mean Square Error (RMSE)*, dan *Mean Absolute Percentage Error (MAPE)*. Evaluasi ini bertujuan untuk membandingkan performa kedua model dan mengidentifikasi model yang paling representatif terhadap pola data aktual. Integrasi hasil dilakukan dalam bentuk analisis komparatif, bukan penggabungan model secara operasional.

Tahap akhir penelitian adalah visualisasi hasil prediksi dalam bentuk *dashboard* analitis. Visualisasi dirancang untuk menyajikan informasi secara intuitif, mencakup perbandingan antara data aktual dan hasil prediksi, pola tren permintaan, serta fluktuasi temporal. *Dashboard* ini berfungsi sebagai alat bantu analisis dan interpretasi hasil prediksi, sehingga memudahkan pengguna dalam memahami dinamika permintaan berdasarkan hasil pemodelan.

2.1. Pemodelan Prediksi Menggunakan SARIMAX

Tahap pemodelan SARIMAX (*Seasonal AutoRegressive Integrated Moving Average with Exogenous Variables*) bertujuan untuk membangun model prediksi berbasis deret waktu yang mampu menangkap pola tren, musiman, serta pengaruh variabel eksternal terhadap permintaan. Pada tahap ini, data historis permintaan dianalisis untuk mengidentifikasi karakteristik stasioneritas, tren, dan pola musiman. Proses identifikasi parameter model dilakukan melalui analisis komponen *autoregressive (AR)*, *differencing (I)*, dan *moving average (MA)*, serta penentuan orde musiman. Selain itu, variabel eksogen dimasukkan ke dalam model untuk merepresentasikan faktor eksternal yang mempengaruhi permintaan, seperti harga dan promosi.

Variabel input dalam pemodelan SARIMAX meliputi data permintaan y_t , variabel eksogen X_t , periode musiman s . Sementara itu, variabel output mencakup hasil prediksi permintaan \hat{y}_t dan metrik evaluasi kinerja model. Proses pemodelan diawali dengan pembagian data menjadi data latih dan data uji berdasarkan urutan waktu tanpa pengacakan untuk menjaga struktur kronologis deret waktu. Selanjutnya dilakukan pengujian karakteristik deret waktu guna mengidentifikasi keberadaan tren dan pola musiman, serta menentukan kebutuhan *differencing* sebagai transformasi untuk memastikan data memenuhi asumsi stasioneritas. *Orde differencing* non-musiman dan musiman yang diperoleh pada tahap ini masing-masing ditetapkan sebagai parameter d dan D . Berdasarkan hasil analisa tersebut, kandidat parameter non-musiman (p, d, q) dan musiman (P, D, Q, s) ditentukan menggunakan kombinasi grid sederhana atau pendekatan heuristik sebelum model diestimasi pada data latih.

(P, D, Q, s) ditentukan menggunakan kombinasi grid sederhana atau pendekatan heuristik. Model SARIMAX kemudian diestimasi pada data latih dengan mengintegrasikan komponen autoregresif, moving average, musiman, serta variabel eksogen, sehingga hubungan antara permintaan dan faktor eksternal dapat dimodelkan secara simultan.

Model SARIMAX kemudian diestimasi pada data latih dengan mengintegrasikan komponen autoregresif, *moving average*, musiman, serta variabel eksogen, sehingga hubungan antara permintaan dan faktor eksternal dapat dimodelkan secara simultan, persamaannya adalah $y_t = (p, d, q), (P, D, Q, s)_t + \beta_t + \varepsilon_t$. Setelah proses estimasi, dilakukan diagnostik residual untuk memastikan bahwa residual bersifat acak atau menyerupai *white noise*, yang mengindikasikan tidak adanya pola sistematis yang belum terjelaskan oleh model. Model yang telah tervalidasi selanjutnya digunakan untuk melakukan peramalan pada horizon data uji dengan memanfaatkan nilai variabel eksogen X_t yang sesuai pada periode prediksi. Kinerja peramalan dievaluasi menggunakan metrik MAE, RMSE, dan MAPE dengan membandingkan nilai aktual dan hasil prediksi. Seluruh keluaran pemodelan meliputi hasil prediksi per periode, *confidence interval* (jika digunakan), serta parameter model terbaik yang diperoleh.

2.2. Pemodelan Prediksi Menggunakan XGBoost

Tahap selanjutnya adalah pemodelan menggunakan algoritma *Extreme Gradient Boosting (XGBoost)*, yaitu metode pembelajaran mesin berbasis ensemble yang menggabungkan sejumlah pohon keputusan secara bertahap untuk meminimalkan kesalahan prediksi. Berbeda dengan pendekatan statistik pada SARIMAX, XGBoost mampu menangkap hubungan *non-linear* dan interaksi kompleks antar variabel.

Pada tahap ini, data yang telah melalui proses *preprocessing* digunakan sebagai input fitur (*features*) dan target (target variable). Fitur dapat mencakup nilai historis permintaan, variabel musiman, serta variabel tambahan lain yang relevan. Proses pelatihan model dilakukan dengan mengoptimalkan fungsi objektif melalui mekanisme *boosting*, di mana setiap model baru berfokus pada kesalahan yang dihasilkan oleh model sebelumnya.

Model XGBoost kemudian diuji menggunakan data validasi untuk mengevaluasi tingkat akurasi dan kestabilan prediksi. Hasil dari tahap ini berupa prediksi permintaan berbasis pembelajaran mesin yang bersifat fleksibel dan adaptif terhadap perubahan pola data. Pendekatan ini memberikan perspektif alternatif terhadap hasil prediksi berbasis statistik yang dihasilkan oleh model SARIMAX.

Variabel input adalah dataset (data permintaan, *tanggal*, harga, promo). Sementara variabel output adalah y_t (nilai prediksi), *feature importance*, metrik evaluasi. Tahapan pemodelan diawali dengan pembangunan fitur (*feature engineering*) dari data permintaan yang meliputi *lag features*, *rolling stats*, waktu dan variabel eksogen. *Lag features* dibentuk untuk merepresentasikan ketergantungan waktu, seperti nilai permintaan pada periode sebelumnya $y_{t-1}, y_{t-2}, \dots, y_{t-k}$. Selain itu, *rolling stats* berupa nilai rata-rata, median, dan standar deviasi pada jendela waktu tertentu digunakan untuk menangkap pola tren lokal dan tingkat volatilitas permintaan. Informasi waktu juga dimasukkan dalam bentuk variabel bulan guna merepresentasikan pola musiman. Untuk memperkaya konteks keputusan, variabel eksogen seperti promosi, harga, dan event tertentu diintegrasikan sebagai fitur tambahan yang dapat mempengaruhi fluktuasi permintaan.

Tahap selanjutnya adalah membagi data menggunakan pendekatan *time-based split* ke dalam data latih, validasi, dan uji tanpa proses pengacakan sehingga urutan kronologis data tetap terjaga dan menghindari kebocoran informasi antar periode. Pada tahap pemodelan, digunakan XGBoost Regressor yang diawali dengan penetapan parameter awal, meliputi jumlah estimator, kedalaman maksimum pohon, laju pembelajaran, serta rasio subsampling data dan fitur. Selanjutnya, model dilatih menggunakan data latih dengan objektif regresi untuk meminimalkan kesalahan prediksi antara nilai aktual dan nilai hasil estimasi. Proses pembelajaran dilakukan secara bertahap, di mana setiap pohon keputusan yang ditambahkan berperan dalam memperbaiki kesalahan prediksi pada iterasi sebelumnya. Dengan pendekatan ini, model secara progresif meningkatkan akurasi prediksi terhadap pola permintaan yang bersifat nonlinier dan dinamis.

Untuk meningkatkan kinerja model dan mencegah overfitting, dilakukan *tuning* ringan melalui penyesuaian parameter dan penerapan mekanisme *early stopping* berdasarkan performa pada data validasi. Setelah proses pelatihan selesai, model digunakan untuk melakukan prediksi pada data uji sehingga diperoleh vektor prediksi permintaan pada setiap periode pengujian. Kinerja model dievaluasi menggunakan metrik *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE) guna memberikan gambaran komprehensif mengenai tingkat akurasi dan stabilitas prediksi. Seluruh hasil pemodelan kemudian disimpan dalam bentuk keluaran yang mencakup nilai prediksi permintaan per periode serta ringkasan nilai evaluasi sebagai dasar analisis dan pengambilan keputusan lanjutan.

2.3. Perancangan Dashboard Prediksi Permintaan

Perancangan *dashboard* prediksi yang berfungsi sebagai media visualisasi dan interpretasi hasil pemodelan. *Dashboard* dirancang untuk menyajikan hasil prediksi secara informatif, ringkas, dan mudah dipahami (Hanifah et al., 2022). *Dashboard* dikembangkan dengan memanfaatkan *locker studio*.

Elemen visual yang ditampilkan meliputi perbandingan antara data aktual dan hasil prediksi, pola tren permintaan dari waktu ke waktu untuk setiap distributor, pola permintaan ketika dipengaruhi oleh variabel harga dan promosi serta ringkasan performa model berdasarkan metrik evaluasi seperti MAE, RMSE, dan MAPE. Visualisasi disusun secara interaktif agar pengguna dapat mengeksplorasi data berdasarkan periode waktu tertentu atau skenario yang berbeda.

Data input pada pengembangan *dashboard* meliputi dataset permintaan aktual, hasil prediksi yang dihasilkan oleh model SARIMAX dan XGBoost, serta metrik evaluasi kinerja model. Adapun data output berupa *dashboard* prediksi yang menyajikan visualisasi hasil peramalan beserta ringkasan performa model sebagai dasar pendukung pengambilan keputusan.

Tahapan pengembangan *dashboard* diawali dengan pendefinisian kebutuhan pengguna, termasuk identifikasi jenis pengguna, tujuan penggunaan *dashboard* (*monitoring* atau pelaporan), serta periode analisis yang relevan. Selanjutnya dilakukan perancangan struktur data yang mencakup tabel utama berisi informasi tanggal atau periode, data aktual, hasil prediksi, serta tabel ringkasan yang memuat nilai MAE, RMSE, dan MAPE. Setelah struktur data disiapkan, visual utama dirancang dalam bentuk grafik garis yang membandingkan data aktual dan hasil

prediksi sepanjang waktu serta *KPI cards* yang menampilkan nilai MAE, RMSE, dan MAPE. Tampilan *dashboard* juga disesuaikan agar dapat menampilkan informasi jika diperlukan.

Untuk meningkatkan interaktivitas, *dashboard* dilengkapi dengan fitur penyaring (*filter*) berdasarkan periode waktu (bulanan atau mingguan), produk atau SKU, serta area atau distributor, dan opsi *toggle* untuk membandingkan hasil prediksi dengan permintaan aktual. Tahap berikutnya adalah validasi tampilan *dashboard* guna memastikan konsistensi satuan dan skala, keterbacaan visual melalui label, judul, dan legenda yang jelas, serta kesesuaian nilai KPI yang ditampilkan dengan hasil perhitungan. *Dashboard* kemudian diuji menggunakan beberapa skenario data, seperti periode dengan permintaan tinggi dan rendah, untuk memastikan keandalan dan robustitas tampilan. Tahap akhir meliputi finalisasi *dashboard* yang disertai dokumentasi singkat mengenai sumber data, definisi metrik evaluasi, serta panduan interpretasi grafik dan indikator kinerja yang ditampilkan. *Dashboard* ini tidak digunakan untuk pengambilan keputusan operasional secara langsung, melainkan sebagai alat bantu analisis dan pemahaman terhadap perilaku permintaan. Dengan demikian, *dashboard* berperan sebagai sarana pendukung dalam proses interpretasi pola permintaan.

3. Hasil dan Diskusi

Hasil penelitian didasarkan pada urutan logis untuk membentuk sebuah cerita. Isinya menunjukkan fakta/data. Pengolahan data awal dilakukan menggunakan bahasa pemrograman *Python* pada *platform Google Colab*. *Dataset* dengan periode bulanan yang terdiri dari variabel permintaan, harga, dan promosi terlebih dahulu diproses untuk memastikan konsistensi format waktu dan kelengkapan data.


Hasil pengolahan awal menunjukkan bahwa permintaan bersifat fluktuatif dengan pola musiman ringan, sementara variasi harga relatif terbatas dan promosi hanya terjadi pada periode tertentu. Kondisi ini mengindikasikan perlunya pendekatan prediksi yang mampu menangkap pola historis sekaligus pengaruh faktor eksternal.

3.1. Prediksi Permintaan

Prediksi permintaan dilakukan untuk periode Desember 2025 hingga November 2026 dengan memasukkan skenario rencana harga dan promosi yang berbeda pada setiap bulan. Hasil prediksi menunjukkan adanya variasi permintaan yang dipengaruhi oleh kombinasi faktor musiman, harga, dan promosi. Hasil prediksi adalah sebagai berikut:

Tabel 1. Hasil Prediksi

Periode	SARIMAX	XGBoost	Hybrid
Des 2025	1.031,93	1.043,96	1.039,25
Jan-26	931,08	914,25	920,84
Feb-26	942,72	979,00	964,78
Mar-26	1.241,15	1.260,28	1.252,79
Apr-26	940,59	916,91	926,19
Mei 2026	940,42	1.057,47	1.011,60
Jun-26	940,46	786,20	846,65
Jul-26	940,45	1.035,24	998,09
Agu 2026	940,46	973,81	960,74
Sep-26	940,46	869,22	897,14
Okt 2026	940,46	1.019,25	988,37
Nov-26	940,46	923,70	930,26



Gambar 2. Visualisasi Perbandingan Hasil Prediksi dengan Permintaan Aktual pada Periode Sebelumnya

Pada periode Desember 2025, di mana harga diturunkan dan promosi dilakukan, permintaan diprediksi meningkat dengan nilai prediksi hybrid sebesar 1.039 unit. Hal ini mengindikasikan adanya respons positif konsumen terhadap kombinasi penurunan harga dan aktivitas promosi. Sebaliknya, pada periode Januari–Februari 2026 tanpa promosi dan dengan harga normal, permintaan diprediksi menurun ke kisaran 920–965 unit. Pola ini konsisten dengan perilaku permintaan yang lebih stabil pada periode non-promosi.

Lonjakan permintaan paling signifikan terjadi pada Maret 2026, ketika promosi kembali diterapkan. Model hybrid memprediksi permintaan mencapai 1.253 unit, yang merupakan nilai tertinggi dalam horizon prediksi. Hasil ini memperkuat indikasi bahwa promosi memiliki pengaruh yang signifikan terhadap peningkatan permintaan. Pada bulan-bulan berikutnya tanpa promosi, permintaan cenderung kembali ke tingkat normal dengan fluktuasi moderat. Variasi prediksi antar model menunjukkan bahwa SARIMAX menghasilkan nilai yang relatif konstan, sementara XGBoost lebih sensitif terhadap perubahan pola permintaan, dan model hybrid menghasilkan nilai kompromi yang lebih realistis.

3.2. Evaluasi Kinerja

Evaluasi kinerja model dilakukan menggunakan data validasi dengan tiga metrik, yaitu *Mean Absolute Error (MAE)*, *Root Mean Squared Error (RMSE)*, dan *Mean Absolute Percentage Error (MAPE)*. Hasil evaluasi ditunjukkan pada Tabel 2.

Tabel 2. Hasil Evaluasi Kinerja Forecast

Metode	MAE	RMSE	MAPE (%)
SARIMAX	71.728	93.0927	8.2728
XGBoost	48.1595	51.6844	5.331
Hybrid (val) alpha=0.39	42.8137	43.1258	4.6144

Berdasarkan hasil pengujian, model SARIMAX menghasilkan nilai MAPE sebesar 8,27%, sedangkan model XGBoost menunjukkan peningkatan kinerja dengan MAPE yang lebih rendah, yaitu 5,33%. Penurunan nilai kesalahan ini mengindikasikan bahwa model berbasis machine learning lebih mampu menangkap fluktuasi permintaan jangka pendek dan hubungan nonlinier antara permintaan dengan variabel harga dan promosi.

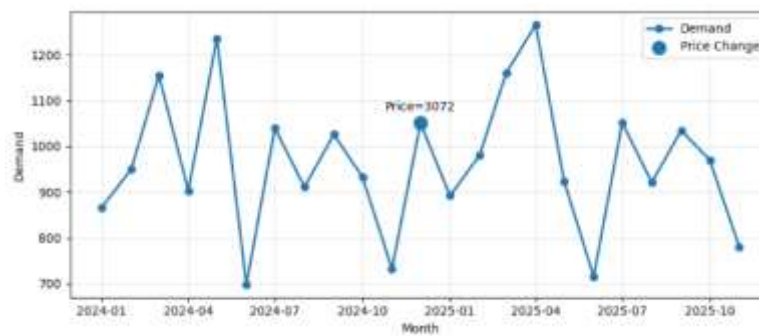
Model hybrid (ensemble) SARIMAX–XGBoost memberikan kinerja terbaik dengan nilai MAPE sebesar 4,61%, MAE 42,81, dan RMSE 43,13. Hasil ini menunjukkan bahwa pendekatan ensemble mampu mengkombinasikan keunggulan kedua model, di mana SARIMAX berperan dalam menangkap pola historis dan tren permintaan, sementara XGBoost meningkatkan responsivitas terhadap perubahan pola permintaan. Dengan nilai MAPE di bawah 5%, model hybrid dapat dikategorikan memiliki akurasi prediksi yang sangat baik untuk perencanaan operasional.

Bobot ensemble yang diperoleh sebesar $\alpha = 0,39$ menunjukkan bahwa kontribusi model XGBoost dalam prediksi akhir lebih dominan dibandingkan SARIMAX. Hal ini sejalan dengan hasil evaluasi individual model, di mana XGBoost memiliki nilai kesalahan yang lebih rendah pada data validasi. Namun demikian, kontribusi SARIMAX tetap signifikan karena membantu menjaga stabilitas prediksi, terutama pada periode tanpa promosi atau perubahan harga. Temuan ini menguatkan bahwa pendekatan hybrid tidak hanya meningkatkan akurasi, tetapi juga menghasilkan prediksi yang lebih stabil dibandingkan penggunaan satu model tunggal.


3.3. Sensitivitas Harga dan Promosi/event

Perbandingan hasil prediksi menunjukkan bahwa variabel promosi/event memberikan dampak yang lebih kuat terhadap permintaan dibandingkan variasi harga, terutama dalam kondisi di mana perubahan harga relatif terbatas. Pada bulan dengan promosi, baik SARIMAX maupun XGBoost memprediksi peningkatan permintaan, dengan XGBoost menunjukkan respons yang lebih agresif.

Hasil ini mengindikasikan bahwa promosi/event berperan sebagai *demand driver* utama, sementara harga berfungsi sebagai faktor pendukung. Oleh karena itu, integrasi variabel promosi dan harga dalam model prediksi terbukti meningkatkan akurasi dan relevansi hasil prediksi.



Gambar 3. Visualisasi Perbandingan Perubahan Permintaan dengan Adanya Program Diskon dan program lain



Gambar 4. Visualisasi Perbandingan Perubahan Permintaan dengan Perubahan Harga.

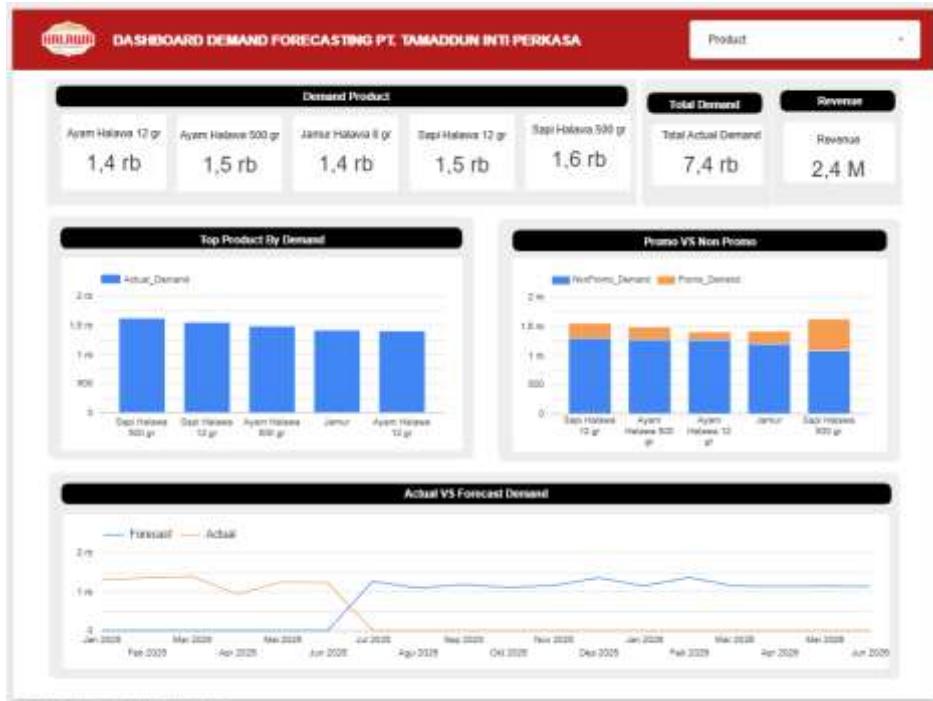
Hasil prediksi multi-periode yang dihasilkan model hybrid diintegrasikan ke dalam *dashboard* prediksi permintaan. *Dashboard* menampilkan hasil prediksi per bulan beserta penanda periode promosi dan perubahan harga, sehingga pengguna dapat dengan mudah mengidentifikasi periode dengan potensi lonjakan permintaan.

Dengan mekanisme pembaruan data yang dinamis, *dashboard* memungkinkan manajemen untuk melakukan pemantauan permintaan secara berkelanjutan dan melakukan penyesuaian rencana produksi maupun persediaan berdasarkan skenario harga dan promosi yang direncanakan.

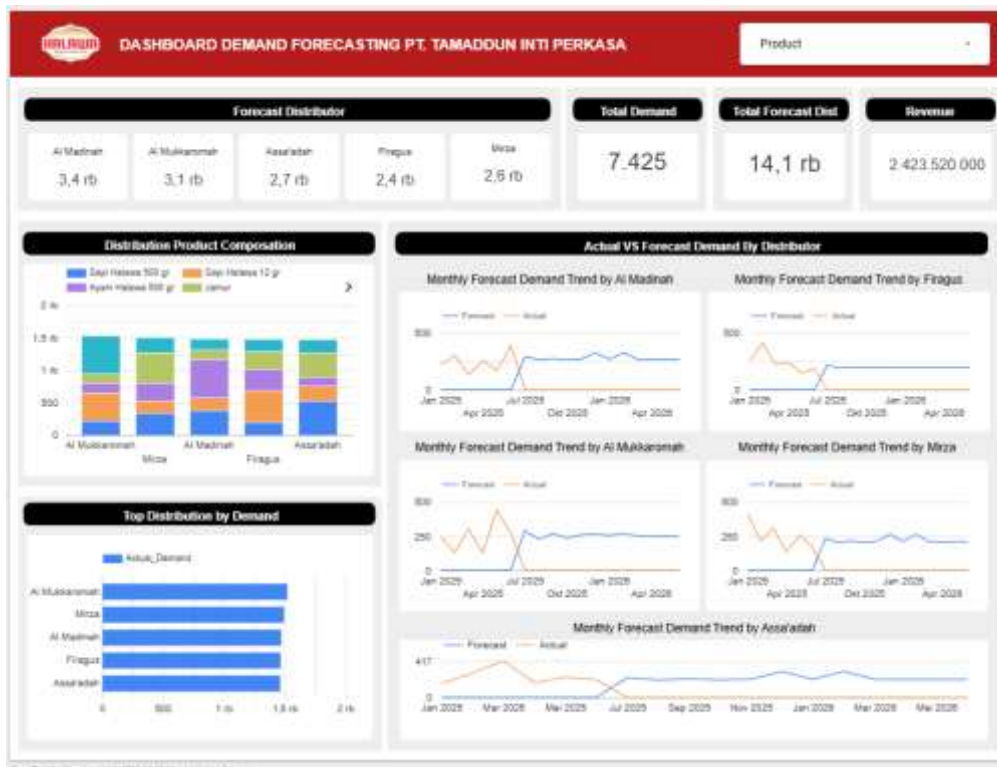
3.4. Dashboard Prediksi Permintaan

Hasil perancangan *dashboard* prediksi permintaan menunjukkan bahwa sistem visualisasi yang dikembangkan telah mampu menyajikan informasi permintaan dan hasil peramalan secara terstruktur, informatif, dan berorientasi untuk pengambilan keputusan. *Dashboard* dirancang dengan pendekatan hierarkis, dimulai dari ringkasan kinerja pada tingkat agregat hingga analisis yang lebih rinci pada level produk dan distributor, sehingga memudahkan pengguna dalam memahami kondisi permintaan secara menyeluruh maupun spesifik.

Pada tampilan utama, penyajian KPI ringkas seperti total permintaan aktual, total permintaan hasil peramalan, serta estimasi pendapatan memberikan gambaran cepat mengenai kinerja permintaan secara keseluruhan. Informasi ini berfungsi sebagai *early insight* bagi manajemen untuk memantau tren permintaan tanpa harus melakukan analisis mendalam pada tahap awal. Visualisasi produk teratas berdasarkan permintaan berhasil mengidentifikasi produk dengan kontribusi terbesar terhadap total permintaan, sehingga mendukung penentuan prioritas produksi dan distribusi (Gambar 4).



Gambar 4. Dashboard Prediksi Permintaan (Produk)



Gambar 5. Dashboard Prediksi Permintaan (Distributor)

Perbandingan antara permintaan aktual dan hasil peramalan yang ditampilkan dalam bentuk grafik deret waktu memperlihatkan kemampuan model dalam menangkap pola permintaan historis serta proyeksi permintaan ke depan. Visualisasi ini memungkinkan pengguna untuk mengamati deviasi antara nilai aktual dan prediksi pada periode tertentu, yang dapat menjadi dasar evaluasi akurasi model sekaligus bahan pertimbangan dalam penyesuaian kebijakan perencanaan. Selain itu, analisis perbandingan permintaan pada kondisi promosi dan non-

promosi memberikan wawasan mengenai dampak aktivitas promosi terhadap peningkatan permintaan, yang relevan untuk perencanaan strategi pemasaran dan pengendalian persediaan.

Pada tampilan tingkat distributor yang ditunjukkan Gambar 5, *dashboard* mampu menyajikan distribusi permintaan antar distributor secara komparatif melalui grafik komposisi produk dan peringkat distributor berdasarkan volume permintaan. Pendekatan ini mendukung analisis performa jaringan distribusi serta identifikasi distributor dengan kontribusi permintaan tertinggi maupun terendah. Penyajian tren peramalan dan realisasi permintaan secara terpisah untuk setiap distributor memperkuat kemampuan *dashboard* dalam mendukung analisis spasial dan segmentasi kinerja, sehingga keputusan alokasi stok dapat dilakukan secara lebih tepat sasaran.

Secara keseluruhan, keterpaduan antara *dashboard* pada tingkat produk (Gambar 1) dan tingkat distributor (Gambar 2) menunjukkan bahwa sistem yang dirancang mampu mendukung pengambilan keputusan baik pada level strategis maupun operasional. *Dashboard* tidak hanya menyajikan hasil peramalan secara visual, tetapi juga memfasilitasi evaluasi performa model dan analisis distribusi permintaan secara komprehensif.

4. Kesimpulan

Prediksi permintaan yang akurat adalah elemen krusial dalam mendukung keputusan untuk menentukan strategi dalam pengelolaan persediaan dan perencanaan produksi khususnya di industri makanan dan minuman yang memiliki karakteristik permintaan fluktuatif dan umur simpan yang relatif pendek. Peramalan permintaan baik secara tradisional maupun *machine learning* menunjukkan dinamika permintaan yang dipengaruhi beberapa pola musim, tren dan variabel eksternal lainnya seperti harga dan promosi. Integrasi metode SARIMAX dan XGBoost menunjukkan bahwa XGBoost berperan dalam memodelkan interaksi kompleks antarvariabel yang tidak dapat dipresentasikan secara optimal menggunakan model statistik konvensional dimana SARIMAX efektif dalam model deret waktu, dan pola musiman. Penggunaan kedua model ini menjadikan lebih adaptif, stabil dan robust terhadap perubahan kondisi pasar. Integrasi hasil prediksi tersebut divisualisasikan menggunakan *dashboard* untuk mendukung keputusan. *Dashboard* ini menyajikan informasi permintaan dan peramalan yang mudah dipahami sehingga membantu Perusahaan memperoleh Gambaran menyeluruh mengenai distributor dan penjualan tiap jenis produk sehingga mendukung perencanaan produksi, pengendalian persediaan, evaluasi strategi promosi dan juga optimalisasi jaringan distribusi secara lebih efektif dan berbasis data. Penelitian ini tidak hanya berkontribusi pada model prediksi permintaan tetapi juga visualisasi *dashboard* untuk mendukung operasional Perusahaan dan peningkatan daya saing perusahaan secara berkelanjutan.

Referensi

1. Chen, T., & Guestrin, C. (2026). *XGBoost : A Scalable Tree Boosting System*. August 2016. <https://doi.org/10.1145/2939672.2939785>
2. Hanifah, S., Akbar, F., & Santi, R. P. (2022). *Implementasi Business Intelligence dan Prediksi Menggunakan Regresi Linear pada Data Penjualan dan Breakage di PT XYZ* (pp. 144–152).
3. Karthik, B., Abbas, S. H., Pradesh, A., Pradesh, A., Engineering, C., Nadu, T., Nadu, T., & Pradesh, U. (n.d.). *Optimizing Product Demand Forecasting with Hybrid Machine Learning and Time Series Models : A Comparative Analysis of XGBoost and SARIMA*.
4. Khaw, B., Irwanto, R., Yunis, R., Mikroskil, U., Informatika, F., Informasi, S., & Mikroskil, U. (2025). *Analisis Time Series dan Perancangan Dashboard untuk Memprediksi Penjualan dengan Metode Prophet dan*. 25(2).
5. Made, I. D., Surya, W., & Widhiada, I. W. (2023). *Desain Optimalisasi Peramalan Suku Cadang Berbasis Machine Learning*. 9(2), 54–62.
6. Riza, F., & Riza, F. (2022). *Analisis dan Prediksi Data Penjualan Menggunakan Machine Learning dengan Pendekatan Ilmu Data*. 1(2), 62–68.
7. Samantha, V., Salsabila, T. M., Wijaya, A. C., Trisnawarman, D., Tji, J., Informasi, F. T., Studi, P., Informasi, S., & Tarumanagara, U. (2024). *Proses desain pada perancangan dashboard pemantauan penjualan produk pt. xyz the design process in developing a product sales monitoring dashboard for pt. xyz*. 7.
8. Sunendar, N. (2025). *Perancangan Business Intelligence Dashboard*. 2(2), 121–136.