



Model *Business Intelligence* Berbasis *Explainable AI* dan Analisis Ketidakpastian untuk Rekomendasi Strategi Penjualan UMKM

Karanita¹, Andi Rahma Nur Alam², Arwinda³

Program Studi Sistem Informasi, Universitas Lamappapoleonro¹

Program Studi Manajemen, Universitas Lamappapoleonro²

Program Studi Sistem Informasi, Universitas Lamappapoleonro³

Jl. Salotungo No. 62, Watansoppeng, 90811, Soppeng, Sulawesi Selatan, Indonesia^{1,2,3}

karanita@unipol.ac.id¹, andirahma@unipol.ac.id², arwinda@gmail.com³

Kata Kunci :

Business Intelligence;
Explainable AI;
Random Forest;
Conformal Prediction;
UMKM

ABSTRAK

Penelitian ini mengembangkan model Business Intelligence yang mengintegrasikan Explainable AI dan analisis ketidakpastian untuk mendukung keputusan penjualan UMKM Coppo Awi. Data observasi mencakup 809 catatan produk-harian pada Januari–Juni 2025; sebanyak 739 observasi memenuhi kebutuhan fitur historis. Data dipisahkan secara kronologis menjadi 495 pelatihan, 120 kalibrasi, dan 124 pengujian. Random Forest dan XGBoost dibandingkan dengan tiga metode dasar. Random Forest menghasilkan MAE 2,361 unit, RMSE 3,130 unit, dan WAPE 25,11% pada data uji. SHAP mengidentifikasi rerata penjualan 14 hari sebelumnya sebagai fitur dominan. Conformal Prediction dengan target cakupan 90% menghasilkan cakupan empiris 94,35% dan lebar interval rata-rata 11,51 unit. Rekomendasi yang dihasilkan berupa indikasi peninjauan kebutuhan restok, bukan klaim peningkatan keuntungan. Hasil menunjukkan kelayakan awal integrasi prediksi, interpretabilitas, dan ketidakpastian dalam analitik penjualan UMKM, dengan kebutuhan validasi lanjutan atas catatan stok dan pendapatan.

Keywords:

Business Intelligence;
Explainable AI;
Random Forest;
Conformal Prediction;
Microenterpr

ABSTRACT

This study develops a Business Intelligence model integrating explainable artificial intelligence and uncertainty analysis to support sales decisions at Coppo Awi, an Indonesian microenterprise. The field-observation dataset contains 809 daily product records from January to June 2025, of which 739 have complete historical predictors. Chronological partitions comprise 495 training, 120 calibration, and 124 testing records. Random Forest and XGBoost are evaluated against three simple forecasting baselines. On the test partition, Random Forest achieves an MAE of 2.361 units, RMSE of 3.130 units, and WAPE of 25.11%. SHAP identifies the previous 14-day mean sales as the strongest predictor. At 90% nominal coverage, conformal intervals achieve 94.35% empirical coverage and 11.51 units of average width. The resulting output provides stock-review indications, not demonstrated profit improvements. Findings support preliminary feasibility while highlighting the need for further inventory and revenue reconciliation.

---Jurnal JISTI @2026---

PENDAHULUAN

Usaha mikro, kecil, dan menengah (UMKM) menghadapi tuntutan keputusan yang makin berbasis data, sedangkan keterbatasan sumber daya sering menghambat penerapan analitik terintegrasi. Business Intelligence (BI) menawarkan proses transformasi data operasional menjadi informasi yang mendukung pemantauan kinerja, antisipasi kebutuhan, dan evaluasi tindakan. Ragazou et al. (2023) menekankan relevansi model BI bagi daya saing usaha kecil, sedangkan Alsibhawi et al. (2023) menunjukkan bahwa



kualitas informasi dan kemudahan adopsi menjadi faktor penting. Tinjauan Tsiu et al. (2025) serta Champa dan Segall (2026) menunjukkan perlunya arsitektur BI yang praktis, dapat ditelusuri, dan sensitif terhadap keterbatasan data UMKM.

Pada konteks penjualan ritel, laporan pendapatan historis tidak selalu memadai untuk menentukan prioritas produk dan kebutuhan persediaan. Prediksi permintaan berperan dalam perencanaan pembelian, alokasi modal, dan pengendalian ketersediaan barang. Kajian pemetaan Ahaggach et al. (2024) memperlihatkan perkembangan penggunaan model pembelajaran mesin dalam peramalan penjualan; Nasseri et al. (2023) membandingkan model ensemble pohon dan jaringan sekuensial menggunakan data permintaan ritel. Studi lain mengembangkan pendekatan ensemble bagi produk baru (Hwang et al., 2025), prediksi ritel multi-saluran (Guruvaya et al., 2024), pemodelan kebutuhan konsumsi cepat (Ma et al., 2025), serta metode hibrida yang disesuaikan dengan karakter pola permintaan (Kim & Cho, 2026).

Walaupun algoritma kompleks dapat meningkatkan fleksibilitas prediksi, kemampuan tersebut tidak otomatis menghasilkan rekomendasi yang dapat dipahami pengelola usaha. Pendekatan ensemble perlu dinilai terhadap baseline sederhana serta protokol validasi yang realistis agar peningkatan kinerja tidak berasal dari kebocoran informasi masa depan. Oliveira dan Ramos (2024) mengingatkan pentingnya perbandingan model canggih dengan benchmark peramalan yang sesuai, sedangkan Albassam et al. (2026) menunjukkan pengaruh besar konfigurasi praproses dan fitur yang benar-benar tersedia saat prediksi. Teixeira et al. (2024) juga memperlihatkan pentingnya informasi promosi dalam peramalan hierarkis, tetapi informasi tersebut tidak selalu dicatat oleh UMKM.

Kemampuan menjelaskan keluaran model menjadi unsur kedua dalam BI yang dapat dipertanggungjawabkan. Explainable Artificial Intelligence (XAI) memungkinkan pembacaan kontribusi relatif prediktor tanpa harus menyederhanakan relasi nonlinier menjadi asumsi linear. Qaffas et al. (2023) memanfaatkan SHAP untuk menjelaskan kategori prioritas persediaan, sementara Bastos dan Bernardes (2024) menggunakannya dalam analisis perilaku pembelian digital. Zhao et al. (2025) memperlihatkan nilai interpretasi berbasis SHAP untuk peramalan pendapatan, dan Shaheryar et al. (2026) menekankan bahwa pemilihan fitur historis serta informasi eksternal menentukan makna penjelasan model. Penting dicatat bahwa nilai SHAP menjelaskan perilaku prediktif model, bukan hubungan kausal.

Komponen ketiga adalah ketidakpastian prediksi. Prediksi titik dapat menyembunyikan besarnya kemungkinan deviasi, yang justru relevan ketika usaha menentukan keputusan stok. Conformal Prediction membentuk interval prediksi berbasis residual kalibrasi dan dapat digunakan di atas berbagai algoritma dasar. Xu dan Xie (2023) mengembangkan kerangka konformal untuk runtun waktu, sedangkan Schlembach et al. (2025) membahas tantangan ramalan multistep dengan data tidak saling bebas. Borrotti (2024), Yu et al. (2025), dan Shang (2026) memperlihatkan variasi penerapan prediksi interval pada data berurutan. Karena dependensi temporal dapat melanggar asumsi pertukaran data, tingkat cakupan yang ditargetkan tetap harus diperiksa secara empiris.

Penelitian terbaru mulai mengarah pada integrasi antara prediksi dan diagnosis operasional. Huan dan Sarvghadi (2026) menghubungkan peramalan permintaan dengan penilaian risiko persediaan, sedangkan Zhu et al. (2025) menunjukkan kontribusi struktur data terhadap prediksi penjualan teragregasi. Penguatan kapabilitas BI melalui keputusan berbasis data juga dilaporkan oleh Alshareef dan Emeagwali (2026). Meski demikian, kombinasi prediksi yang dapat dijelaskan, interval ketidakpastian, dan aturan keputusan yang transparan masih perlu diuji dalam lingkungan usaha kecil dengan rekaman penjualan terbatas. Kesimpulan tersebut menjadi celah penerapan kontekstual, bukan klaim bahwa integrasi ketiga pendekatan belum pernah dilakukan.




UMKM Coppo Awi dijadikan studi kasus menggunakan data observasi penjualan harian untuk lima jenis produk pada 1 Januari–11 Juni 2025. Data mentah memuat 809 catatan produk-harian; pemeriksaan awal menemukan 48 catatan dengan selisih antara pendapatan tercatat dan hasil kali harga–kuantitas, satu kombinasi tanggal–produk yang tidak tersedia, serta perbedaan stok antahari yang belum dilengkapi catatan mutasi. Situasi tersebut menuntut penyajian hasil secara transparan: nilai asli dipertahankan, kesenjangan kualitas data didokumentasikan, dan model dibatasi pada prediksi kuantitas penjualan, bukan estimasi keuntungan atau efek promosi.

Berdasarkan persoalan tersebut, penelitian bertujuan (1) mengukur kinerja peramalan kuantitas penjualan Random Forest dan XGBoost terhadap baseline sederhana; (2) mengidentifikasi karakteristik historis yang berpengaruh pada keluaran model melalui SHAP; (3) mengevaluasi interval ketidakpastian berbasis Conformal Prediction; dan (4) menghasilkan indikasi peninjauan kebutuhan restok yang mengikuti hasil prediksi dan kapasitas persediaan yang tercatat. Kontribusi penelitian terletak pada alur BI terukur dan dapat direproduksi untuk pengambilan keputusan operasional pada data UMKM yang terbatas, disertai pengungkapan keterbatasannya.

METODE PENELITIAN

Penelitian menggunakan pendekatan kuantitatif eksperimental berbasis observasi produk-harian untuk mengembangkan dan mengevaluasi prototipe analitik BI. Alur penelitian meliputi audit data, pembentukan fitur historis, pemisahan data berbasis waktu, pengujian model, interpretasi SHAP, kalibrasi konformal, dan penurunan indikasi keputusan. Sumber data dinyatakan peneliti sebagai Data Observasi Lapangan di UMKM Coppo Awi. Diagram pada Gambar 1 memperlihatkan keterkaitan masing-masing tahap:



Gambar 1. Arsitektur penelitian

Sumber: Hasil pengolahan Data Observasi Lapangan

a. Dataset, pemeriksaan kualitas, dan fitur

Unit analisis adalah observasi per produk per tanggal. Target y merupakan jumlah unit terjual pada hari t . Dataset terdiri atas 809 baris dan 11 variabel asal; setelah syarat panjang riwayat 14 hari dipenuhi, 739 baris dipakai untuk pemodelan. Tidak dilakukan imputasi nilai target pada catatan hilang. Setiap perubahan nilai sumber perlu didukung bukti catatan lapangan. Sebanyak 48 selisih pendapatan ditandai sebagai isu rekonsiliasi dan tidak digunakan untuk menurunkan target prediksi.

Tabel 1. Variabel yang Digunakan pada Model Peramalan

Komponen	Operasionalisasi	Keterangan
Target	Jumlah unit terjual pada hari t	Regresi unit produk
Temporal	Bulan dan akhir pekan	Diketahui sebelum hari t
Produk	One-hot kode produk (P001–P005)	Identitas produk
Historis	Penjualan lag 1, 7, dan 14 hari	Nilai hari sebelumnya
Historis	Rerata bergerak 7 dan 14 hari	Tidak mencakup target t
Persediaan	Stok akhir hari $t-1$	Memerlukan validasi mutasi stok
Harga	Harga satuan produk	Konstan selama observasi

Sumber: Hasil pengolahan Data Observasi Lapangan di UMKM Coppo Awi (2025).



b. Pembagian data dan pemodelan

Pembagian dilakukan secara kronologis tanpa pengacakan: TRAIN sebanyak 495 observasi (15 Januari–23 April 2025), CALIBRATION 120 (24 April–17 Mei 2025), serta TEST 124 (18 Mei–11 Juni 2025). Di dalam TRAIN, 20% tanggal terakhir digunakan sebagai validasi internal untuk menentukan model dasar; setelah pemilihan, model dilatih ulang pada keseluruhan TRAIN. CALIBRATION dikhususkan untuk residual konformal dan TEST hanya untuk evaluasi akhir. Algoritma Random Forest (300 pohon, minimum 3 sampel daun, `random_state=42`) dan XGBoost (280 pohon, kedalaman 3, learning rate 0,045, `random_state=42`) dibandingkan dengan prediksi naïf lag-1, naïf lag-7, dan rerata tujuh hari.

Metrik yang digunakan adalah mean absolute error (MAE), root mean squared error (RMSE), dan weighted absolute percentage error (WAPE). Ketiganya dihitung pada unit observasi produk-harian. Secara matematis, $MAE = (1/n) \sum |y_i - \hat{y}_i|$; $RMSE = \sqrt{[(1/n) \sum (y_i - \hat{y}_i)^2]}$; dan $WAPE = 100 \times \sum |y_i - \hat{y}_i| / \sum y_i$. Prediksi negatif dibatasi minimum nol karena penjualan tidak dapat bernilai negatif. Pengaturan evaluasi ini konsisten dengan perhatian metodologis pada ketersediaan fitur waktu prediksi (Albassam et al., 2026; Nasser et al., 2023).

c. Explainable AI dan analisis ketidakpastian

Penjelasan prediksi dilakukan menggunakan TreeExplainer-SHAP pada 124 observasi TEST. Kepentingan global dinilai melalui mean absolute SHAP; hasilnya diinterpretasikan sebagai kontribusi dalam model. Untuk interval prediksi, residual absolut $|y - \hat{y}|$ pada CALIBRATION diurutkan; nilai kuantil split-conformal pada $\alpha = 0,10$ dipakai sebagai batas $\pm q$ terhadap prediksi model terpilih. Batas bawah dipotong ke nol. Prediction Interval Coverage Probability (PICP) dan Mean Prediction Interval Width (MPIW) dihitung pada TEST. Data runtun waktu tidak menjamin validitas distribusi-bebas secara otomatis sehingga cakupan 90% ditafsirkan sebagai target nominal, bukan jaminan untuk masa depan (Xu & Xie, 2023; Schlembach et al., 2025).

d. Aturan indikasi keputusan penjualan

Indikasi prioritas restok dirumuskan secara eksplisit sebagai aturan pemantauan: jika stok akhir hari sebelumnya lebih kecil dibanding batas atas interval prediksi hari target, sistem memberikan label “Tinjau restok”; jika tidak, label “Pantau stok”. Aturan ini bersifat heuristik dan tidak memperhitungkan lead time, ukuran kemasan, tingkat layanan, biaya simpan, maupun ketersediaan pasokan. Oleh karena itu, luaran penelitian diposisikan sebagai dukungan penilaian, belum sebagai rekomendasi jumlah pesanan optimum atau efektivitas strategi penjualan yang teruji.

HASIL DAN PEMBAHASAN

1. Profil Dataset dan Audit Kualitas Data

File observasi mencakup 809 catatan untuk Beras, Minyak Goreng, Tepung Terigu, Gula Pasir, dan Mi Instan selama 162 tanggal berturut-turut. Total unit terjual tercatat sebanyak 7.234 unit dan jumlah pendapatan pada kolom sumber sebesar Rp92.560.650. Kedua angka merupakan agregasi deskriptif observasi, bukan metrik keuntungan. Beras menyumbang pendapatan terbesar, diikuti Minyak Goreng; konsentrasi kedua komoditas ini menunjukkan pentingnya perhatian pada alur stok produk utama.

Tabel 2. Ringkasan Observasi dan Hasil Pemeriksaan Kualitas

Indikator audit	Hasil pemeriksaan
Observasi asal	809 baris; lima produk; 162 hari
Periode observasi	1 Januari–11 Juni 2025
Target prediksi	Jumlah unit terjual per hari dan produk



Indikator audit	Hasil pemeriksaan
Kelengkapan nilai di 809 baris	Tidak terdapat sel kosong
Konsistensi stok dalam satu hari	809/809 memenuhi stok awal – penjualan = stok akhir
Selisih nominal pendapatan	48 baris; selisih bruto–tercatat Rp661.850
Kombinasi produk–tanggal hilang	1 kombinasi: Mi Instan, 11 Juni 2025
Mutasi stok antarhari	Perlu konfirmasi restok/retur/penyesuaian

Sumber: Hasil pengolahan Data Observasi Lapangan di UMKM Coppo Awi (2025).

Sebanyak 48 baris memiliki nilai pendapatan berbeda dari hasil kali harga satuan dan jumlah terjual, dengan selisih yang setara potongan 5%, 10%, atau 15%. Besarnya selisih tersebut belum membuktikan bahwa transaksi mendapatkan diskon karena kolom diskon tidak tersedia. Selain itu, stok awal antarhari tidak selalu dapat direkonsiliasi dari stok akhir hari sebelumnya, sehingga evaluasi keputusan restok belum dapat diterjemahkan menjadi kebutuhan pembelian aktual. Pemisahan permasalahan audit dari nilai observasi inti mencegah perubahan angka tanpa bukti.

2. Pembentukan Fitur dan Desain Pengujian

Feature engineering menghasilkan atribut lag-1, lag-7, lag-14, rerata penjualan tujuh dan 14 hari sebelum target, informasi akhir pekan, bulan, harga, identitas produk, dan stok hari sebelumnya. Fitur pendapatan hari target, stok akhir hari target, serta penanda habis stok pada hari target sengaja dikecualikan karena nilainya belum diketahui ketika peramalan dilakukan. Sebanyak 70 baris pertama tidak memenuhi riwayat 14 hari dan tidak dimasukkan dalam dataset siap-model. Total 739 baris yang tersisa dibagi menjadi tiga partisi berdasarkan tanggal.

Tabel 3. Pembagian Data Eksperimen Secara Kronologis

Partisi	Periode	Jumlah	Peran
Train	15 Jan–23 Apr 2025	495	Pemodelan dan validasi internal
Calibration	24 Apr–17 Mei 2025	120	Kalibrasi residual konformal
Test	18 Mei–11 Jun 2025	124	Evaluasi akhir tanpa pelatihan
Total		739	Data siap-model

Sumber: Hasil pengolahan Data Observasi Lapangan di UMKM Coppo Awi (2025).

Dalam validasi internal blok waktu yang hanya mengambil bagian TRAIN, Random Forest memiliki MAE 2,642 unit dibanding XGBoost 2,802 unit. Karena itu Random Forest dipilih sebelum residual CALIBRATION dihitung. Prosedur ini mencegah penggunaan data TEST untuk optimasi model dan menjaga pemisahan antara pemilihan model dengan proses estimasi interval.

3. Perbandingan Kinerja Peramalan Penjualan

Tabel 4. Kinerja Model Pada Data TEST (n = 124)


Model	MAE	RMSE	WAPE
Naif t-1	3,137	4,270	33,36%
Naif t-7	3,065	4,337	32,59%
Rata 7 hari	2,423	3,289	25,77%
XGBoost	2,375	3,170	25,25%
Random Forest	2,361	3,130	25,11%

Sumber: Hasil pengolahan Data dengan Python Google Colab

Random Forest menunjukkan galat uji terendah, yaitu MAE 2,361 unit, RMSE 3,130 unit, dan WAPE 25,11%. XGBoost memperoleh MAE 2,375 unit, RMSE 3,170 unit, dan WAPE 25,25%. Selisih kedua algoritma relatif kecil sehingga hasil ini tidak cukup untuk menyatakan keunggulan universal Random Forest. Dibanding baseline naïf lag-7 (MAE 3,065), Random Forest menurunkan MAE sebesar



sekitar 22,94%. Namun dibanding baseline rerata tujuh hari (MAE 2,423), penurunan hanya sekitar 2,53%, yang menegaskan pentingnya pembandingan sederhana.



Gambar 2. Perbandingan galat MAE lima pendekatan pada data uji

Sumber: Hasil pengolahan Data dengan Python Google Colab.

Penggunaan observasi produk-harian memperbesar jumlah pasangan evaluasi, tetapi tidak menambah jumlah hari kalender yang tersedia. Karena itu, interpretasi kemampuan generalisasi perlu mempertimbangkan bahwa pengujian berlangsung hanya 25 hari, sedangkan hasil pada horizon dan musim berbeda belum tersedia.

4. Evaluasi Kinerja Berdasarkan Produk


Tabel 5. Kinerja Random Forest dan Interval Menurut Produk

Produk	n TEST	MAE	PICP	MPIW
Beras	25	3,644	84,00%	11,65
Minyak Goreng	25	2,490	100,00%	11,65
Tepung Terigu	25	1,735	96,00%	11,54
Gula Pasir	25	1,557	100,00%	11,05
Mi Instan	24	2,382	91,67%	11,65

Sumber: Hasil pengolahan Data dengan Python Google Colab.

Beras memiliki MAE terbesar (3,644 unit) dibanding Gula Pasir (1,557 unit) dan Tepung Terigu (1,735 unit). Perbedaan tidak otomatis menunjukkan model lebih buruk secara proporsional karena skala permintaan masing-masing produk juga berbeda. Selanjutnya, cakupan interval Beras sebesar 84,00%, lebih rendah dari tingkat nominal 90%; produk lain mencapai 91,67% hingga 100%. Temuan ini memperlihatkan bahwa cakupan gabungan yang baik tidak berarti setiap kelompok produk telah memiliki cakupan setara. Hasil per produk bersifat eksploratif karena jumlah observasi uji hanya 24–25 tiap produk.

5. Interpretasi Model Menggunakan Explainable AI



Gambar 3. Kepentingan global prediktor berdasarkan mean absolute SHAP

Sumber: Hasil pengolahan Data dengan Python Google Colab



Analisis TreeExplainer menunjukkan bahwa rerata historis penjualan 14 hari sebelumnya merupakan prediktor paling dominan dengan mean absolute SHAP 2,429 unit; berikutnya rerata tujuh hari sebesar 0,555 unit dan indikator akhir pekan sebesar 0,453 unit. Identitas produk Beras juga berkontribusi terhadap variasi keluaran model. Pola tersebut konsisten dengan struktur masalah peramalan yang mengandalkan riwayat penjualan pendek dan indikator kalender. Pentingnya fitur tidak berarti peningkatan atau penurunan penjualan disebabkan oleh fitur tersebut.

Dominasi penjualan 14 hari sebelumnya memperlihatkan bahwa model terutama mengekstrak tingkat penjualan yang relatif stabil, bukan mempelajari akibat kegiatan promosi. Hal itu juga disebabkan tidak adanya fitur perubahan harga, promosi, lokasi pelanggan, serta cuaca dalam data. Qaffas et al. (2023) dan Bastos dan Bernardes (2024) memperlihatkan fungsi XAI untuk mendukung pembacaan model bisnis; pada penelitian ini penjelasan ditempatkan sebagai dasar diskusi dengan pengelola, bukan pengganti pembuktian kausal atau eksperimen pemasaran.


6. Analisis Ketidakpastian Menggunakan Conformal Prediction

Tabel 6. Evaluasi Interval Prediksi Konformal

Ukuran evaluasi	Nilai	Interpretasi
Tingkat nominal	90,00%	Target cakupan
Observasi CALIBRATION	120	Dasar estimasi residual
Kuantil residual absolut (q)	5,825 unit	Lebar setengah interval sebelum clipping
Observasi TEST	124	Evaluasi akhir
PICP gabungan	94,35%	Persentase target masuk interval
MPIW gabungan	11,51 unit	Lebar interval rata-rata

Sumber: Hasil pengolahan Data dengan Python Google Colab

Kuantil residual absolut dari 120 observasi CALIBRATION menghasilkan $q = 5,825$ unit. Interval uji dibentuk melalui $[\max(0, \hat{y}-q), \hat{y}+q]$. Dari 124 catatan TEST, sebanyak 117 masuk dalam interval, sehingga PICP sebesar 94,35% dan MPIW sebesar 11,51 unit. Tingkat cakupan aktual lebih tinggi daripada target nominal 90%, namun lebar interval yang relatif besar dapat membatasi ketepatan keputusan stok. Selain itu, dependensi serial serta potensi pergeseran pola penjualan membatasi penerapan jaminan teoretis konformal standar (Xu & Xie, 2023; Borrotti, 2024; Yu et al., 2025).



Gambar 4. Prediksi, realisasi, dan interval konformal untuk produk Beras

Sumber: Hasil pengolahan Data dengan Python Google Colab.



Gambar 4 menampilkan kasus Beras sepanjang tanggal uji. Selubung interval membentang cukup lebar pada hari dengan prediksi tidak pasti, dan beberapa nilai aktual berada di luar cakupan. Pengamatan ini relevan karena persediaan barang tidak boleh ditetapkan hanya dari prediksi titik. Akan tetapi, interval tidak boleh dianggap sebagai rentang peluang individual 90% untuk setiap hari; kualitas cakupan harus dievaluasi pada urutan waktu yang lebih panjang dan kondisi permintaan berbeda (Schlembach et al., 2025; Shang, 2026).

7. Luaran Business Intelligence dan Indikasi Peninjauan Stok

Model mengintegrasikan keluaran prediksi, SHAP, dan interval ketidakpastian ke dalam rancangan keputusan operasional. Pada 124 observasi uji, aturan sederhana perbandingan stok hari sebelumnya terhadap batas atas interval menghasilkan 101 catatan berlabel “Tinjau restok” dan 23 berlabel “Pantau stok”. Angka tersebut menggambarkan frekuensi sinyal sistem, bukan jumlah transaksi restok yang terjadi atau bukti penurunan kehilangan penjualan. Pengguna masih perlu memeriksa suplai aktual, persediaan berjalan, dan kebutuhan operasional sebelum mengambil keputusan.

Tabel 7. Contoh Keluaran Model BI pada Data TEST

Produk	Tanggal	Pred.	Batas atas	Stok t-1	Indikasi
Beras	2025-05-18	15,7	21,5	29	Pantau stok
Minyak Goreng	2025-05-18	11,2	17,0	12	Tinjau restok
Tepung Terigu	2025-05-18	6,5	12,3	10	Tinjau restok
Gula Pasir	2025-05-18	5,0	10,8	4	Tinjau restok
Mi Instan	2025-05-18	14,0	19,8	12	Tinjau restok

Sumber: Hasil pengolahan Data Observasi Lapangan di UMKM Coppo Awi (2025).

Tabel 7 memperlihatkan bentuk informasi yang dapat ditampilkan dalam antarmuka BI: ringkasan prediksi unit, batas atas yang menggambarkan ketidakpastian, data stok yang tersedia sebelum hari prediksi, dan indikasi tindakan. Keterkaitan keluaran ini ditujukan untuk memudahkan penelusuran alasan keputusan. Pendekatan dapat memperluas fungsi laporan BI konvensional menuju dukungan penilaian operasional (Ragazou et al., 2023; Champa & Segall, 2026), tetapi belum dapat dinyatakan meningkatkan profitabilitas tanpa uji implementasi serta data biaya yang memadai.

8. Pembahasan

Hasil menunjukkan bahwa arsitektur BI yang tidak terlalu kompleks dapat menghasilkan prediksi kuantitas penjualan yang melampaui baseline sederhana, interpretasi faktor prediktif yang terbaca, dan ukuran ketidakpastian yang dapat dievaluasi. Secara konseptual, ketiga keluaran tersebut mendukung siklus informasi–penilaian–tindakan yang relevan bagi UMKM. Perbedaan kecil antara Random Forest dan XGBoost juga menunjukkan bahwa kebaruan penelitian lebih tepat diposisikan pada integrasi dan evaluasi dukungan keputusan yang transparan, bukan penemuan algoritma baru. Temuan Huan dan Sarvghadi (2026), Majlatow et al. (2025), dan Alshareef dan Emeagwali (2026) memberi konteks bahwa ketidakpastian, penjelasan, dan tata kelola data sama pentingnya dengan metrik galat. Penelitian memiliki keterbatasan mendasar. Periode hanya mencakup sekitar lima bulan, sehingga pola musiman tahunan tidak dapat diuji. Satu kombinasi tanggal–produk tidak tercatat dan 48 nilai pendapatan belum direkonsiliasi; penyebab mutasi stok antarhari juga belum terdokumentasi. Data mencatat jumlah terjual, bukan permintaan pelanggan yang tidak terpenuhi saat stok habis. Harga produk konstan dan tidak tersedia variabel promosi maupun biaya, sehingga efektivitas strategi harga, iklan, diskon, dan laba tidak dapat diuji. Validasi prospektif, penambahan rekaman transaksi, dokumentasi restok, serta studi keputusan sebelum–sesudah penerapan sistem menjadi prioritas untuk pengembangan berikutnya.



SIMPULAN DAN SARAN

Penelitian ini menghasilkan rancangan model Business Intelligence terintegrasi untuk mendukung pemantauan keputusan penjualan UMKM Coppo Awi melalui peramalan kuantitas, penjelasan SHAP, dan interval ketidakpastian berbasis Conformal Prediction. Berdasarkan 739 observasi siap-model dari 809 catatan observasi produk-harian, Random Forest memperoleh MAE 2,361 unit, RMSE 3,130 unit, serta WAPE 25,11% pada 124 data uji dan sedikit mengungguli XGBoost. Analisis SHAP menunjukkan dominasi rerata penjualan historis 14 hari, sedangkan interval konformal dengan cakupan nominal 90% menghasilkan PICP empiris 94,35% dan MPIW 11,51 unit. Aturan indikasi stok memberikan 101 sinyal peninjauan restok dan 23 sinyal pemantauan, tetapi luaran tersebut belum membuktikan peningkatan pendapatan atau efisiensi persediaan. Dengan demikian, integrasi prediksi, interpretabilitas, dan pengukuran ketidakpastian layak sebagai prototipe analitik penjualan, dengan keterbatasan penting berupa periode singkat, catatan mutasi stok yang belum terverifikasi, serta absennya informasi promosi dan biaya. Penelitian lanjutan disarankan melaksanakan rekonsiliasi observasi lapangan, evaluasi prospektif lintas musim, dan pengujian dampak keputusan restok melalui ukuran operasional nyata.

DAFTAR PUSTAKA

- Ahaggach, H., Abrouk, L., & Lebon, E. (2024). Systematic mapping study of sales forecasting: Methods, trends, and future directions. *Forecasting*, 6(3), 502–532. <https://doi.org/10.3390/forecast6030028>
- Albassam, S., Alqahtani, A., & Alazba, A. (2026). Retail sales forecasting using tree-based machine learning models: An empirical study of preprocessing configurations and feature ablation. *Applied Sciences*, 16(15), 7556. <https://doi.org/10.3390/app16157556>
- Alshareef, H. R., & Emeagwali, O. L. (2026). Business intelligence capabilities and SME innovation: The mediating role of knowledge management capability and the moderating effect of data-driven decision making. *Systems*, 14(4), 339. <https://doi.org/10.3390/systems14040339>
- Alsibhawi, I. A. A., Yahaya, J. B., & Mohamed, H. B. (2023). Business intelligence adoption for small and medium enterprises: Conceptual framework. *Applied Sciences*, 13(7), 4121. <https://doi.org/10.3390/app13074121>
- Bastos, J. A., & Bernardes, M. I. (2024). Understanding online purchases with explainable machine learning. *Information*, 15(10), 587. <https://doi.org/10.3390/info15100587>
- Borrotti, M. (2024). Quantifying uncertainty with conformal prediction for heating and cooling load forecasting in building performance simulation. *Energies*, 17(17), 4348. <https://doi.org/10.3390/en17174348>
- Champa, S. S., & Segall, R. S. (2026). Integrated data analytics, business intelligence, and machine learning architecture for SMEs: Framework for small and medium enterprises. *International Journal of Business Analytics*, 13(1), 1–38. <https://doi.org/10.4018/IJBAN.409371>
- Guruvaya, A. M., Kollu, A., Divakarachari, P. B., Falkowski-Gilski, P., & Praveena, H. D. (2024). Bi-GRU-APSO: Bi-directional gated recurrent unit with adaptive particle swarm optimization algorithm for sales forecasting in multi-channel retail. *Telecom*, 5(3), 537–555. <https://doi.org/10.3390/telecom5030028>
- Huan, G., & Sarvghadi, M.-A. (2026). From prediction to diagnostic support: A data-driven system for retail demand forecasting and inventory risk assessment. *Information*, 17(9), 909. <https://doi.org/10.3390/info17090909>



- Hwang, S., Lee, Y., Jeon, B.-K., & Oh, S. H. (2025). Sales forecasting for new products using homogeneity-based clustering and ensemble method. *Electronics*, 14(3), 520. <https://doi.org/10.3390/electronics14030520>
- Kim, J.-H., & Cho, N.-W. (2026). Hybrid clustering for retail demand forecasting: Combining rule-based and machine learning methods. *Forecasting*, 8(3), 37. <https://doi.org/10.3390/forecast8030037>
- Ma, Y., He, L., & Zheng, J. (2025). STL-DCSInformer-ETS: A hybrid model for medium- and long-term sales forecasting of fast-moving consumer goods. *Applied Sciences*, 15(3), 1516. <https://doi.org/10.3390/app15031516>
- Majlatow, M., Shakil, F. A., Emrich, A., & Mehdiyev, N. (2025). Uncertainty-aware predictive process monitoring in healthcare: Explainable insights into probability calibration for conformal prediction. *Applied Sciences*, 15(14), 7925. <https://doi.org/10.3390/app15147925>
- Nasseri, M., Falatouri, T., Brandtner, P., & Darbanian, F. (2023). Applying machine learning in retail demand prediction—A comparison of tree-based ensembles and long short-term memory-based deep learning. *Applied Sciences*, 13(19), 11112. <https://doi.org/10.3390/app131911112>
- Oliveira, J. M., & Ramos, P. (2024). Evaluating the effectiveness of time series transformers for demand forecasting in retail. *Mathematics*, 12(17), 2728. <https://doi.org/10.3390/math12172728>
- Qaffas, A. A., Ben HajKacem, M.-A., Ben Ncir, C.-E., & Nasraoui, O. (2023). An explainable artificial intelligence approach for multi-criteria ABC item classification. *Journal of Theoretical and Applied Electronic Commerce Research*, 18(2), 848–866. <https://doi.org/10.3390/jtaer18020044>
- Ragazou, K., Passas, I., Garefalakis, A., & Zopounidis, C. (2023). Business intelligence model empowering SMEs to make better decisions and enhance their competitive advantage. *Discover Analytics*, 1, Article 2. <https://doi.org/10.1007/s44257-022-00002-3>
- Schlembach, F., Smirnov, E., Koprinska, I., & Winands, M. H. M. (2025). Conformal multistep-ahead multivariate time-series forecasting. *Machine Learning*, 114, Article 165. <https://doi.org/10.1007/s10994-024-06722-9>
- Shaheryar, M. Z., Alharairi, M., Amin, S. H., & Zolfaghari, S. (2026). A machine learning framework: E-commerce retail sales forecasting with external weather features. *Logistics*, 10(9), 214. <https://doi.org/10.3390/logistics10090214>
- Shang, H. L. (2026). Conformal prediction for functional time series: Application to age-specific mortality rates. *Journal of Population Research*, 43, Article 14. <https://doi.org/10.1007/s12546-026-09422-4>
- Teixeira, M., Oliveira, J. M., & Ramos, P. (2024). Enhancing hierarchical sales forecasting with promotional data: A comparative study using ARIMA and deep neural networks. *Machine Learning and Knowledge Extraction*, 6(4), 2659–2687. <https://doi.org/10.3390/make6040128>
- Tsiu, S. V., Ngoben, M., Mathabela, L., & Thango, B. (2025). Applications and competitive advantages of data mining and business intelligence in SMEs performance: A systematic review. *Businesses*, 5(2), 22. <https://doi.org/10.3390/businesses5020022>
- Xu, C., & Xie, Y. (2023). Conformal prediction for time series. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45(10), 11575–11587. <https://doi.org/10.1109/TPAMI.2023.3272339>
- Yu, Q., Cao, Z., Wang, R., Yang, Z., Deng, L., Hu, M., Luo, Y., & Zhou, X. (2025). Dual-splitting conformal prediction for multi-step time series forecasting. *Applied Soft Computing*, 184, 113825. <https://doi.org/10.1016/j.asoc.2025.113825>



-
- Zhao, Z., Wang, M., Wei, J., Cen, X., Du, S., Wu, Z., Liu, H., & Wang, W. (2025). Interpretable machine learning for multi-energy supply station revenue forecasting: A SHAP-driven framework to accelerate urban carbon neutrality. *Energies*, 18(7), 1624. <https://doi.org/10.3390/en18071624>
- Zhu, B., Sun, Z., van den Broucke, S., Lan, K., & Xiao, D. (2025). Aggregate sales forecasting based on spatial correlation in retail. *Journal of Theoretical and Applied Electronic Commerce Research*, 20(4), 334. <https://doi.org/10.3390/jtaer20040334>