



Analisis Faktor Kinerja Penjualan Harian UMKM Menggunakan Metode Feature Engineering dan XAI Berbasis Gradient Boosting Regressor

Nur Afif Raihan^{1,*}, Salman Fathy Shiroth²

¹ Program Studi Teknik Informatika, Sekolah Tinggi Teknologi Terpadu Nurul Fikri, Depok, Indonesia

² Program Studi Bisnis Digital, Sekolah Tinggi Teknologi Terpadu Nurul Fikri, Depok, Indonesia

Email: ^{1,*}nura22053ti@student.nurulfikri.ac.id, ²salman.fathy@nurulfikri.ac.id

Email Penulis korespondensi: nura22053ti@student.nurulfikri.ac.id

Abstrak—UMKM sektor makanan dan minuman umumnya memiliki data transaksi harian, namun pemanfaatannya masih terbatas pada pencatatan sehingga faktor pendorong fluktuasi penjualan belum teridentifikasi secara jelas dan keputusan operasional masih cenderung berbasis intuisi. Penelitian ini bertujuan menganalisis faktor kunci yang memengaruhi kinerja penjualan harian UMKM MW serta membangun model prediksi yang akurat dan dapat dijelaskan. Permasalahan yang dibahas mencakup pengolahan data deret waktu penjualan yang dipengaruhi pola musiman, variasi jumlah transaksi, perubahan perilaku pelanggan, serta pergeseran kanal digital, sehingga diperlukan pendekatan yang mampu menangkap hubungan non-linear sekaligus memberikan interpretasi kontribusi variabel. Solusi yang diusulkan mengintegrasikan proses *feature engineering* deret waktu untuk membentuk 21 fitur prediktif dari data POS dan kanal digital selama 19 bulan, pemodelan menggunakan *Gradient Boosting Regressor* untuk meningkatkan ketepatan prediksi, serta penerapan *Explainable AI* dengan metode *SHAP* guna menjelaskan kontribusi fitur secara global dan lokal terhadap keluaran model. Hasil sementara menunjukkan performa prediksi sangat tinggi dengan nilai R^2 sebesar 0,987265, MAE sebesar Rp33.194.014, dan RMSE sebesar Rp42.625,808, yang mengindikasikan kesesuaian kuat antara nilai prediksi dan penjualan aktual. Analisis *SHAP* menempatkan “Jumlah Menu Terjual” dan “ATV” sebagai faktor paling dominan yang mendorong kenaikan penjualan, sementara fitur lag penjualan memperlihatkan pola non-linear yang mengarah pada fenomena *mean reversion* setelah lonjakan ekstrem. Secara linguistik, temuan ini menunjukkan bahwa peningkatan pendapatan tidak hanya ditentukan oleh volume penjualan, tetapi juga oleh optimalisasi nilai transaksi rata-rata sebagai fokus strategi operasional berbasis data.

Kata Kunci: UMKM F&B; Feature Engineering; Gradient Boosting Regressor; Explainable AI; SHAP

Abstract—Micro, small, and medium enterprises (MSMEs) in the food and beverage sector typically possess daily transaction records, yet these data are often used only for bookkeeping. As a result, the drivers of sales fluctuations are not clearly identified and operational decisions tend to rely on intuition. This study aims to (1) analyze the key factors influencing daily sales performance of MSME MW and (2) develop an accurate and interpretable sales forecasting model. The main problem addressed is how to transform time series transaction data, which are affected by seasonality, changes in customer behavior, and shifts across digital channels, into informative predictors that can capture non-linear relationships while still providing actionable explanations. The proposed solution integrates time series feature engineering to construct 21 predictive features from POS and digital channel data spanning 19 months, applies a Gradient Boosting Regressor to model complex patterns and improve predictive accuracy, and employs Explainable AI using the SHAP method to quantify both global and local feature contributions to the model output. Preliminary results indicate strong forecasting performance, achieving an R^2 of 0.987265, an MAE of IDR 33,194.014, and an RMSE of IDR 42,625.808, suggesting a high level of agreement between predicted and actual daily sales. The SHAP analysis identifies “Total Items Sold” and “ATV” as the most dominant drivers of sales increases, while lag-based sales features exhibit non-linear behavior consistent with mean reversion following extreme spikes. Linguistically, these findings imply that revenue growth is driven not only by sales volume, but also by optimizing average transaction value, providing a clear direction for data-driven operational strategies.

Keywords: UMKM F&B; Feature Engineering; Gradient Boosting Regressor; Explainable AI; SHAP

1. PENDAHULUAN

Usaha Mikro, Kecil, dan Menengah (UMKM) merupakan salah satu pilar penting bagi pertumbuhan ekonomi di Indonesia [1]. Data dari Kementerian Koordinator Bidang Perekonomian Republik Indonesia (Kemkenko) bidang Perekonomian, menunjukkan bahwa UMKM memegang peran besar dalam perekonomian Indonesia. Sektor ini menyumbang sekitar 60% terhadap PDB dan hampir menyerap 90% tenaga kerja di Indonesia [1], [2]. Sektor makanan dan minuman (F&B) adalah salah satu yang bertumbuh cepat, hal ini bisa terjadi karena tingginya permintaan domestik dan adaptasi terhadap teknologi [3]. Adaptasi tersebut diwujudkan melalui sistem *Point of Sale* (POS) pada penggunaan teknologi digital, termasuk sistem *e-payment* dan *e-commerce*, telah terbukti memiliki pengaruh positif dan signifikan terhadap peningkatan kinerja penjualan [4], [5], [6].

Meskipun terjadi peningkatan yang cukup signifikan dalam permintaan adopsi teknologi digital, Usaha Mikro, Kecil, dan Menengah di sektor makanan dan minuman (F&B), khususnya pada skala mikro, masih menghadapi tantangan substansial dalam mengoptimalkan pemanfaatan data operasional yang mereka hasilkan [7]. Data transaksi yang diperoleh dari penjualan umumnya hanya digunakan untuk kebutuhan pencatatan akuntansi dasar, bukan dimanfaatkan sebagai sumber analisis untuk mengidentifikasi fluktuasi penjualan [8] [9]. Kesenjangan ini semakin terlihat pada UMKM yang masih bergantung pada operasional murni tanpa dukungan analisis data. Temuan Benediktus [10] menunjukkan bahwa peningkatan visibilitas dan penjualan merupakan aspek penting dalam strategi pemasaran. Dengan demikian, efisiensi operasional saja tidak memadai untuk mencapai tujuan tersebut. Kondisi tersebut menciptakan kebutuhan mendesak akan pengembangan metodologi yang mampu mengekstraksi wawasan dari data operasional murni guna menjelaskan kinerja penjualan harian [10].



Penelitian ini diarahkan untuk mengatasi kesenjangan tersebut melalui integrasi tiga pilar metodologi. Pertama, *Feature Engineering time-series* secara lebih dalam guna mengubah data transaksi mentah harian yang di peroleh dari POS menjadi 15 fitur prediktif yang bervariasi [11]. Langkah kedua, model *Gradient Boosting Regressor* yang digunakan untuk memprediksi kinerja penjualan harian, model ini dipilih karena memiliki kemampuan menangani data *non-linear* dan *time-series* [12]. Ketiga, menggunakan model *black-box* yang di interpretasikan menggunakan *Explainable AI* (XAI), khususnya dengan metode *Shapley Additive Explanations* (SHAP), guna memberikan transparansi [13]. Coussement, et al [14] menegaskan bahwasannya XAI sangat penting dalam sistem pendukung keputusan, karena dengan model ini kita mendapatkan pemahaman tentang bagaimana sistem AI mencapai hasil prediksi

Namun, pada konteks UMKM hasil prediksi saja belum cukup untuk menentukan keputusan, seringkali dalam melakukan analisis banyak yang menggunakan AI guna mempersingkat waktu yang di gunakan, tetapi kebanyakan AI tersebut tidak menjelaskan faktor operasional apa yang paling berkontribusi terhadap naik turunnya penjualan. Tanpa penjelasan tersebut, pelaku UMKM berisiko kesulitan menerjemahkan prediksi menjadi tindakan yang konkret, sehingga pemanfaatannya sebagai sistem pendukung kurang kuat. Oleh karena itu, XAI dengan SHAP digunakan untuk mengukur kontribusi tiap fitur yang sudah di tentukan, sehingga model tidak hanya akurat tetapi juga dapat di pahami dan di tindak lanjuti dalam konteks operasional. Kontribusi utama penelitian ini adalah menyajikan kerangka kerja yang mengintegrasikan *Feature Engineering* tingkat lanjut dengan XAI, sehingga mampu memberikan wawasan kinerja yang lebih transparan dan sepenuhnya berbasis pada data operasional, khususnya bagi UMKM yang berfokus pada efisiensi internal tanpa dukungan pemasaran digital aktif [15].

Sejumlah penelitian telah melakukan eksplorasi terhadap penerapan *machine learning* guna memprediksi penjualan, namun dengan fokus dan metodologi yang bervariasi. Penelitian yang dihasilkan oleh Winurputra & Ratnawati [16] berhasil menerapkan *Extreme Gradient Boosting* (XGBoost) untuk peramalan penjualan produk di UB Mart, namun fokus utamanya adalah pada akurasi model tanpa melakukan interpretasi mendalam terhadap faktor-faktor yang memengaruhi prediksi. Didukung oleh Sharma [17] yang membahas penggunaan XGBoost untuk memprediksi penjualan produk online, namun tidak secara spesifik membahas rekayasa fitur *Feature Engineering* dari data operasional mentah dan tidak menyertakan analisis *Explainable AI* (XAI). Guna memperluas validasi algoritma ini di luar sektor ritel, Khairi [18] mendemonstrasikan efektivitas *XGB Regressor* dalam memprediksi tarif jalan tol dengan tingkat kesalahan RMSE sebesar 3390.691, yang sekaligus mengonfirmasi stabilitas metode *boosting* dalam menangani data regresi yang kompleks. Di sisi lain, *deep learning* dengan model *hibrida* CNN-LSTM juga digunakan untuk peramalan penjualan ritel [19]. Meskipun kuat dalam menangkap pola temporal, model ini pada dasarnya bersifat *black-box* dan tidak dilengkapi dengan metode interpretasi seperti SHAP untuk menjelaskan hasil prediksinya.

Di ranah *Explainable AI*, beberapa studi telah menunjukkan potensinya. Menurut penelitian Iqbal [20] mekanisme prediksi *time-series* berbasis XAI, tetapi cakupannya masih berfokus pada data umum dan belum membahas tantangan rekayasa fitur pada data operasional UMKM. Sementara itu, Hartomo, et al. [21] mengintegrasikan XAI pada model *Tab Transformer* untuk analisis risiko kredit, yang menunjukkan bahwa XAI dapat memberikan wawasan berharga, tetapi dalam domain yang berbeda seperti risiko kredit, bukan penjualan dan dengan model yang berbeda yaitu *Tab Transformer*, bukan *Gradient Boosting*. Meskipun penelitian-penelitian terdahulu telah meletakkan dasar yang kuat, dari pembahasan tersebut teridentifikasi celah signifikan: belum ada studi yang berhasil menyatukan tiga aspek krusial secara terpadu. Aspek tersebut meliputi perumusan fitur prediktif yang mendalam dari data operasional harian UMKM, pembangunan model prediksi penjualan yang akurat dengan *Gradient Boosting*, dan yang paling penting, penyediaan penjelasan transparan (*Explainable AI*) mengenai faktor-faktor kunci yang mendorong atau menghambat penjualan. Penelitian ini bertujuan mengisi celah tersebut dengan menawarkan kerangka kerja diagnostik yang praktis dan mudah dipahami oleh pelaku usaha.

Berdasarkan kondisi dan kebutuhan penelitian yang telah dijelaskan, penelitian ini merumuskan permasalahan yang berfokus pada bagaimana merancang dan mengimplementasikan proses *feature engineering* untuk mengekstrak fitur *time-series* yang bersifat prediktif dari data POS dan platform penjualan digital UMKM MW, sejauh mana tingkat akurasi model *Gradient Boosting Regressor* dalam memprediksi kinerja penjualan harian, serta bagaimana pendekatan *Explainable AI* menggunakan metode *Shapley Additive Explanations* (SHAP) dapat dimanfaatkan untuk mengidentifikasi dan menganalisis kontribusi fitur operasional maupun transaksi yang paling signifikan terhadap kinerja penjualan harian.

Untuk menunjang keberhasilan analisis pada penelitian ini, diperlukan dataset yang relevan, konsisten, dan mampu merepresentasikan kondisi operasional secara nyata. Dataset yang digunakan diperoleh dari mitra industri yang disamakan sebagai MW, yaitu brand yang bergerak di bidang *food and beverages* (FnB) dengan produk utama berbahan dasar makaroni yang dipadukan dengan variasi rasa, topping, dan saus, serta mengusung nuansa cita rasa masakan lokal Nusantara. Per Februari 2025, MW telah memiliki legalitas resmi sebagai brand di bawah PT Lokal Bisa Mendunia, sehingga aktivitas operasional dan pencatatan data yang dimiliki dapat mendukung pelaksanaan penelitian secara lebih terstruktur. Pemanfaatan data dari MW memungkinkan penelitian menganalisis permasalahan berdasarkan kondisi bisnis yang sesungguhnya, bukan data simulasi, sehingga hasil analisis dan kesimpulan yang diperoleh lebih valid. Dengan dasar data yang nyata tersebut, penelitian diharapkan tidak hanya relevan secara akademik, tetapi juga memiliki potensi implementasi dalam mendukung pengambilan keputusan.

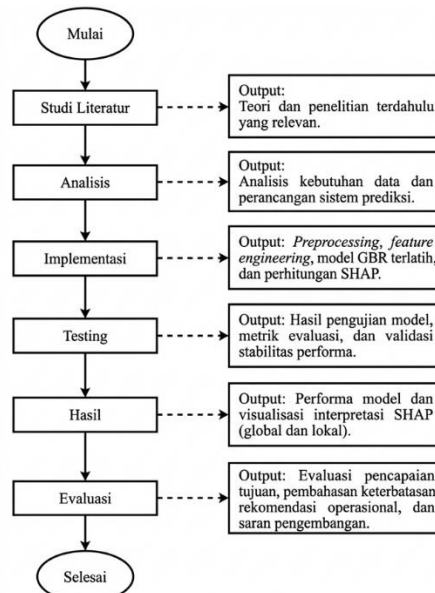
Kesenjangan penelitian (*research gap*) yang teridentifikasi akan menjadi fokus utama penelitian ini karena sebagian besar penelitian terdahulu masih berfokus pada aspek terbatas, seperti akurasi model prediktif, implementasi XAI di luar konteks UMKM, atau rekayasa fitur yang bersifat generik, sehingga belum ada yang mengintegrasikannya menjadi solusi diagnostik yang menyeluruh dan terapan bagi UMKM. Oleh karena itu, penelitian ini mengajukan

kerangka kerja yang tidak hanya mampu memprediksi performa penjualan harian dengan akurasi tinggi, tetapi juga memberikan penjelasan yang transparan mengenai faktor-faktor operasional yang paling signifikan memengaruhi hasil prediksi. Sejalan dengan rumusan masalah tersebut, tujuan penelitian ini adalah mengembangkan kerangka kerja *Feature Engineering* untuk mengekstrak fitur *time-series* dari data operasional UMKM MW, membangun dan mengevaluasi model *Gradient Boosting Regressor* untuk memprediksi kinerja penjualan harian, serta mengidentifikasi dan menganalisis kontribusi setiap fitur operasional dan transaksi terhadap prediksi penjualan harian menggunakan *Explainable AI*. Dengan tercapainya tujuan tersebut, penelitian ini diharapkan dapat memberikan manfaat yang signifikan, baik secara teoritis bagi pengembangan ilmu pengetahuan maupun secara praktis sebagai alat bantu pengambilan keputusan yang kuat, transparan, dan sepenuhnya berbasis data bagi pelaku UMKM MW.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif terapan untuk membangun model prediksi penjualan harian UMKM MW serta mengidentifikasi faktor yang paling berpengaruh terhadap perubahan penjualan [22]. Alur kerja penelitian meliputi pengumpulan dan integrasi data, *preprocessing*, pembentukan fitur deret waktu, pelatihan model *Gradient Boosting Regressor*, evaluasi kinerja model, serta interpretasi hasil menggunakan *SHAP*.



Gambar 1. Kerangka kerja penelitian

Tahapan penelitian ditunjukkan pada Gambar 1, dimulai dari studi literatur, analisis, implementasi, *testing*, hasil, dan evaluasi. Setiap tahap menghasilkan keluaran yang digunakan sebagai masukan pada tahap berikutnya.

a. Studi Literatur.

Tahap studi literatur dilakukan untuk mengkaji penelitian terkait prediksi penjualan, rekayasa fitur *time-series*, *Gradient Boosting Regressor*, serta *Explainable AI* (*SHAP*). Hasil kajian digunakan untuk membangun dasar teori, menentukan pendekatan yang digunakan, dan mengidentifikasi gap penelitian yang menjadi fokus penelitian ini.

b. Analisis

Tahap analisis digunakan untuk memetakan kebutuhan penelitian dan karakteristik data, termasuk penentuan target prediksi, definisi variabel, serta rancangan eksperimen. Pada tahap ini juga ditetapkan skema pembagian data berbasis urutan waktu agar proses pelatihan dan pengujian mencerminkan kondisi prediksi nyata serta menghindari kebocoran informasi.

c. Implementasi

Tahap implementasi mencakup proses *preprocessing*, *feature engineering*, pelatihan model *Gradient Boosting Regressor*, serta interpretasi menggunakan *SHAP*. Rincian implementasi.

1. Pengumpulan dan *preprocessing* sederhana

Data dikumpulkan dari sumber operasional penelitian (misalnya POS dan kanal digital) kemudian diintegrasikan pada tingkat harian. Setelah itu dilakukan *preprocessing* berupa penyeragaman format tanggal, pengecekan duplikasi, dan penanganan nilai hilang seperlunya agar dataset konsisten untuk pemodelan.

2. Feature Engineering

Rekayasa fitur merupakan pilar utama dalam penelitian ini, dengan tujuan mengekstrak 15 fitur prediktif dari data operasional harian. Justifikasi pemilihan rekayasa fitur adalah untuk menangkap pola *temporal*, musiman, serta



ketergantungan historis yang memengaruhi penjualan harian [23]. Fitur-fitur yang digunakan seperti fitur lag (*Lag Features*) yaitu nilai penjualan dari $t-1$, $t-7$, $t-30$ hari. Fitur ini penting untuk menangkap korelasi deret waktu, *Rolling Statistics* rata-rata penjualan (mean) dan standar deviasi (std) selama periode 3, 7, dan 30 hari sebelumnya. Fitur ini membantu menghaluskan noise dan mengidentifikasi tren jangka pendek/menengah, *Temporal Features* hari dalam seminggu (*Day of Week*), Bulan (*Month*), dan Hari Libur (*Holiday Flag*). Fitur ini dapat menangkap efek musiman dan kalender, dan *Trend Features* sebuah variabel penghitung sederhana untuk menangkap tren pertumbuhan atau penurunan jangka panjang.

3. Gradient Boosting Regressor

Dipilih karena memiliki kemampuan yang unggul dalam menangani hubungan non-linear, dan efektivitasnya telah terbukti dalam berbagai tugas prediksi *time-series*. *Gradient Boosting Regressor* bekerja dengan membangun model prediktif secara sekuensial, di mana setiap model baru dilatih untuk memperbaiki kesalahan (*residual*) dari model sebelumnya sehingga akurasi prediksi meningkat secara bertahap [24], [25]. Secara matematis, formulasi prediksi *Gradient Boosting Regressor* mengacu pada model aditif yang dirumuskan pada rumus (1)

$$\hat{y}(\mathbf{x}) = \sum_{m=1}^M \gamma_m h_m(\mathbf{x}) \quad (1)$$

Rumus tersebut menunjukkan bahwa prediksi pada metode *boosting* (termasuk *Gradient Boosting Regressor*) dibentuk secara aditif dari penjumlahan beberapa model dasar, di mana $\hat{y}(\mathbf{x})$ adalah nilai prediksi untuk masukan \mathbf{x} , M menyatakan jumlah model dasar (*estimators*) yang digunakan, $h_m(\mathbf{x})$ adalah model dasar ke- m yang menghasilkan keluaran berdasarkan fitur \mathbf{x} , sedangkan γ_m merupakan bobot yang mengatur besar kontribusi model dasar tersebut terhadap prediksi akhir melalui mekanisme ini, setiap iterasi menambahkan model baru untuk memperbaiki kesalahan prediksi sebelumnya sehingga model akhir mampu menangkap pola non-linear pada data, namun nilai M dan γ_m tetap perlu dikendalikan agar tidak memicu *overfitting*.

4. Model SHAP

Metode SHAP dipilih karena mampu memberikan interpretasi pada dua tingkat sekaligus, yaitu *global* (fitur paling berpengaruh secara keseluruhan) dan *local* (penjelasan untuk prediksi pada hari atau kasus tertentu). Keunggulan ini membuat SHAP sesuai untuk konteks prediksi penjualan harian, karena penyebab fluktuasi penjualan dapat berbeda antar waktu. Metode ini digunakan untuk mengukur kontribusi setiap fitur terhadap prediksi akhir berdasarkan konsep *Shapley value* dari teori permainan kooperatif. Definisi matematis nilai SHAP (ϕ_i) merujuk pada Persamaan (5). Pada penelitian ini, implementasi SHAP menggunakan *TreeExplainer* guna memastikan interpretasi yang efisien dan akurat terhadap model berbasis pohon [26]. Nilai ϕ_i menunjukkan besar dan arah kontribusi fitur terhadap prediksi, di mana $\phi_i > 0$ mengindikasikan fitur mendorong peningkatan nilai prediksi, sedangkan $\phi_i < 0$ menunjukkan fitur berkontribusi menurunkan nilai prediksi. Dengan demikian, interpretasi SHAP dapat meningkatkan transparansi model serta memperkuat kepercayaan terhadap model prediktif karena faktor-faktor yang memengaruhi prediksi dapat dijelaskan secara terukur dan lebih mudah ditindaklanjuti.

$$\phi_i = \sum_{S \subseteq F \setminus \{i\}} \frac{(|S|!(|F|-|S|-1)!)}{|F|!} [f_{S \cup \{i\}}(x_{S \cup \{i\}}) - f_S(x_S)] \quad (2)$$

Pada rumus tersebut F menyatakan himpunan seluruh fitur, sedangkan S adalah subset fitur yang tidak memuat fitur i . Notasi $f_S(x_S)$ merepresentasikan keluaran model ketika hanya fitur pada *subset* S yang digunakan, sementara $f_{S \cup \{i\}}(x_{S \cup \{i\}})$ adalah keluaran model ketika fitur i ditambahkan ke subset tersebut. Dengan demikian, nilai ϕ_i mencerminkan seberapa besar kontribusi fitur i dalam mendorong naik atau turunnya prediksi secara konsisten [27]. Metode ini memungkinkan peneliti dan pelaku UMKM untuk membedah model, melihat dengan jelas faktor mana yang paling mendorong kenaikan atau penurunan penjualan, tanpa harus menafsirkan struktur model yang rumit [28]. Dengan demikian, SHAP memberikan transparansi yang kuat sekaligus mendukung pengambilan keputusan yang lebih berbasis data dan terpercaya.

d. Testing

Tahap *testing* dilakukan untuk menilai performa model pada data uji menggunakan metrik evaluasi MAE, RMSE, dan R^2 .

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

RMSE (*Root Mean Squared Error*) mengukur rata-rata besar kesalahan prediksi dengan cara mengkuadratkan selisih antara nilai aktual dan prediksi, lalu dirata-ratakan dan diakar. Simbol y_i adalah nilai aktual pada data ke i , \hat{y}_i adalah nilai prediksi model pada data ke i , dan n adalah jumlah data evaluasi. Karena kesalahan dikuadratkan, RMSE memberi penalti lebih besar pada kesalahan yang besar. Semakin kecil RMSE, semakin baik akurasi model.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

MAE (*Mean Absolute Error*) mengukur rata-rata kesalahan absolut antara nilai aktual dan prediksi. Simbol y_i adalah nilai aktual, \hat{y}_i adalah nilai prediksi, dan n adalah jumlah data. Berbeda dari RMSE, MAE tidak mengkuadratkan



kesalahan, sehingga tidak terlalu sensitif terhadap *outlier* dibanding RMSE. Semakin kecil MAE, semakin dekat prediksi model terhadap nilai aktual dalam satuan yang sama dengan target (misalnya Rupiah).

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

R^2 (koefisien determinasi) mengukur seberapa besar variasi nilai aktual yang mampu dijelaskan oleh model. Pembilang $\sum_{i=1}^n (y_i - \hat{y}_i)^2$ adalah jumlah kuadrat galat prediksi (sering disebut SSE), sedangkan penyebut $\sum_{i=1}^n (y_i - \bar{y})^2$ adalah jumlah kuadrat variasi data terhadap rata-ratanya, dengan \bar{y} sebagai rata-rata nilai aktual. Nilai R^2 mendekati 1 berarti model menjelaskan variasi data dengan sangat baik, nilai mendekati 0 berarti tidak lebih baik dari memprediksi rata-rata, dan nilai bisa negatif jika model lebih buruk daripada prediksi rata-rata.

e. Hasil

Hasil yang sudah dilakukan oleh metode SHAP diharapkan dapat digunakan untuk mengidentifikasi 15 fitur rekayasa mana yang secara keseluruhan paling signifikan mempengaruhi prediksi penjualan harian, feature Dependence Plots: Menganalisis bagaimana perubahan nilai fitur tertentu memengaruhi output prediksi, individual *Prediction Explanation*: Memberikan contoh penjelasan transparan untuk prediksi penjualan pada hari-hari tertentu. Dengan tahapan metodologi yang terstruktur, penelitian ini tidak hanya menghasilkan model prediktif yang presisi atau akurat, tetapi juga memberikan wawasan transparan dan berbasis data mengenai faktor-faktor kunci yang mendorong kinerja penjualan UMKM MW.

f. Evaluasi

Tahap evaluasi dilakukan untuk menilai ketercapaian tujuan penelitian dan kesesuaian hasil dengan rumusan masalah. Pada tahap ini dibahas keterbatasan penelitian serta dirumuskan rekomendasi operasional dan saran pengembangan berdasarkan temuan yang diperoleh.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pengolahan Data dan Feature Engineering

Data transaksi mentah dari sistem POS dan platform digital UMKM MW berhasil ditransformasikan menjadi dataset harian yang siap pakai. Melalui proses feature engineering, dihasilkan 21 fitur prediktif yang mencakup variabel utama (Penjualan_Harian, Jumlah_Menu_Terjual, ATD, ATV) dan variabel pendukung (kanal digital, fitur lag, dan rolling statistics). Penggunaan fitur lag (t-1, t-7) dan rolling mean terbukti krusial untuk menangkap pola temporal dan ketergantungan historis penjualan harian, yang menjadi dasar bagi model untuk mempelajari fluktuasi data secara adaptif. Tahap awal dalam penelitian ini adalah pengolahan data transaksi operasional harian UMKM MW. Data mentah yang diperoleh dari sistem *Point of Sale* (POS) dan platform digital selama periode 19 bulan merupakan fondasi utama analisis. Proses ini krusial untuk mengubah data yang tersebar dan bervariasi menjadi format yang terstruktur dan siap untuk pemodelan. Langkah-langkah yang dilakukan meliputi:

3.1.1 Praproses dan Pembersihan Data

Integritas data mencakup penghapusan data ganda untuk memastikan tidak ada entri transaksi yang terduplikasi yang dapat menimbulkan bias dalam analisis, penanganan nilai hilang dengan mengidentifikasi serta mengisi missing values menggunakan metode yang sesuai untuk data deret waktu seperti *forward fill* atau interpolasi agar kontinuitas dan urutan waktu tetap terjaga sehingga pola temporal tidak terganggu, serta konversi tipe data dengan mengubah kolom tanggal ke format *datetime* yang benar dan kolom harga atau kuantitas menjadi tipe numerik guna mendukung operasi matematis dan analisis deret waktu yang akurat.

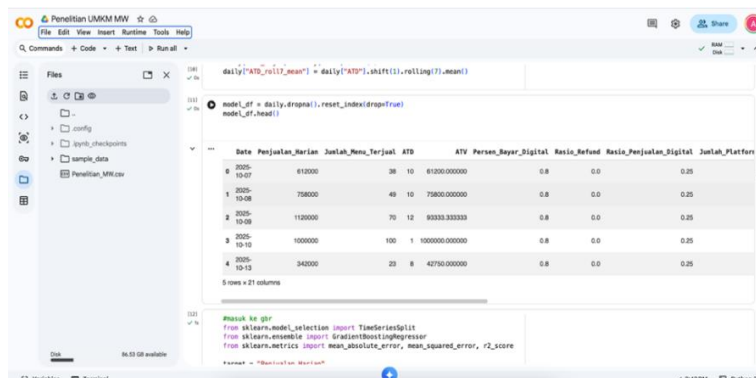
3.1.1 Agregasi Harian

Data transaksi individu, yang awalnya mencatat setiap item penjualan, kemudian diagregasi menjadi total penjualan per hari. Proses agregasi ini sangat vital karena tujuan penelitian adalah menganalisis kinerja penjualan dalam skala waktu harian. Dengan demikian, setiap baris data merepresentasikan ringkasan aktivitas penjualan untuk satu hari tertentu, mencakup total pendapatan, jumlah menu terjual, dan metrik relevan lainnya.

3.1.2 Implementasi Feature Engineering

Setelah data dibersihkan dan diagregasi secara harian, tahap berikutnya adalah *feature engineering* yang lebih mendalam dengan fokus utama penelitian ini pada ekstraksi 21 fitur prediktif dari data operasional harian. Pemilihan dan pembentukan fitur dilakukan untuk menangkap pola temporal, musiman, serta ketergantungan historis yang terbukti berpengaruh signifikan terhadap penjualan harian, sehingga data transaksi mentah dapat ditransformasikan menjadi representasi yang lebih kaya informasi dan memungkinkan model mempelajari hubungan yang kompleks. Fitur yang dibentuk meliputi *lag features* berupa nilai penjualan hari-hari sebelumnya seperti (t-1), (t-7), dan (t-30) untuk menangkap korelasi deret waktu—di mana penjualan saat ini sering bergantung pada penjualan masa lalu, baik karena momentum maupun kecenderungan *mean reversion* setelah lonjakan ekstrem; *rolling statistics* seperti rata-rata dan standar deviasi pada jendela 3, 7, dan 30 hari untuk menghaluskan *noise*, mengidentifikasi tren jangka pendek-menengah, serta mengukur volatilitas; *temporal features* yang merepresentasikan efek kalender dan musiman seperti hari dalam seminggu, bulan,

dan indikator hari libur karena penjualan cenderung berbeda antara hari kerja dan akhir pekan, meningkat pada periode tertentu, atau melonjak saat libur nasional; *trend features* berupa variabel penghitung untuk menangkap arah pertumbuhan atau penurunan jangka panjang; serta fitur operasional dan transaksional lainnya yang berkaitan langsung dengan aktivitas operasional dan karakteristik transaksi UMKM MW.



```

daily["ATD"] = daily["ATD"].shift(1).rolling(7).mean()
model_df = daily.dropna().reset_index(drop=True)
model_df.head()

```

Date	Penjualan_Harian	Jumlah_Menu_Terjual	ATD	ATV	Persen_Bayar_Digital	Rasio_Refund	Rasio_Penjualan_Digital	Jumlah_Platform
2025-10-07	610000	38	10	61000000000	0.8	0.0	0.25	
2025-10-08	758000	49	10	75800000000	0.8	0.0	0.25	
2025-10-09	1120000	70	12	89333333333	0.8	0.0	0.25	
2025-10-10	1000000	100	1	100000000000	0.8	0.0	0.25	
2025-10-12	342000	23	8	42750000000	0.8	0.0	0.25	

```

#Masuk ke GB
from sklearn.model_selection import TimeSeriesSplit
from sklearn.ensemble import GradientBoostingRegressor
from sklearn.metrics import mean_absolute_error, mean_squared_error, r2_score

```

Gambar 2. Output Feature Engineering

Gambar 2 menampilkan keluaran `model_df.head()` yang merupakan cuplikan lima baris pertama dari dataset akhir setelah proses feature engineering. Dataset ini dibentuk dari data harian *daily* yang kemudian ditambahkan fitur turunan, termasuk fitur *lag* dan *rolling*, misalnya ATD satu hari sebelumnya dan rata-rata bergerak tujuh hari yang dibangun dengan pergeseran satu hari agar tidak terjadi kebocoran informasi. Setelah fitur turunan terbentuk, dilakukan `dropna()` untuk menghapus baris yang masih memiliki nilai kosong akibat pembentukan fitur *lag* dan *rolling*, lalu *indeks* dirapikan menggunakan `reset_index(drop=True)`. Pada cuplikan terlihat variabel utama yang telah didefinisikan pada Tabel 4.1, yaitu Penjualan_Harian, Jumlah_Menu_Terjual, ATD, dan ATV, serta variabel pendukung kanal digital seperti Persen_Bayar_Digital, Rasio_Refund, dan Rasio_Penjualan_Digital, dengan total keseluruhan 21 kolom. Dengan demikian, gambar ini menjadi bukti bahwa variabel penelitian dan hasil *Feature Engineering* telah terintegrasi dalam dataset harian yang bersih dan siap digunakan pada tahap pelatihan model prediksi penjualan harian.

3.2 Pembangunan dan Evaluasi model prediktif

Setelah *dataset* pemodelan berhasil dibentuk melalui proses *feature engineering* yang cermat, tahapan selanjutnya adalah membangun model prediksi penjualan harian menggunakan algoritma *Gradient Boosting Regressor* (GBR). Pemilihan GBR didasarkan pada kemampuannya yang unggul dalam menangani hubungan non-linear dan efektivitasnya yang telah terbukti dalam berbagai tugas prediksi *time-series*. GBR bekerja dengan membangun model prediktif secara sekuensial, di mana setiap model baru dilatih untuk memperbaiki kesalahan (*residual*) dari model sebelumnya, sehingga akurasi prediksi meningkat secara bertahap. Dalam konteks penelitian ini, model dilatih menggunakan *dataset* fitur X hasil *feature engineering* dengan target Y berupa penjualan harian, memungkinkan model untuk mempelajari pola tren dan fluktuasi penjualan secara adaptif.

3.2.1 Proses Pelatihan dan Pengujian Model

Untuk memastikan validitas temporal dan menghindari *data leakage*, penelitian ini menerapkan skema *time-series split* atau *hold-out* secara kronologis. Data disusun secara berurutan berdasarkan waktu, kemudian dipisahkan menjadi *set* pelatihan sebesar 80% untuk fase pembelajaran pola, dan *set* pengujian sebesar 20% pada periode akhir sebagai simulasi operasional dunia nyata. Pendekatan ini krusial karena model hanya belajar dari data masa lalu tanpa terpapar informasi masa depan, yang merupakan praktik terbaik dalam pemodelan *time-series*.

3.2.2 Hasil Kinerja Model Gradient Boosting Regressor

Kekuatan prediksi model diukur secara komprehensif melalui tiga metrik evaluasi utama: *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), dan Koefisien Determinasi (R^2). Formulasi teknis dari ketiga metrik ini merujuk pada Persamaan (2.2) hingga Persamaan (2.4) yang telah dijabarkan pada Bab 2 dokumen asli. Hasil evaluasi model GBR disajikan dalam Tabel 1.

Tabel 1. Hasil Evaluasi Model GBR

Metrik	Nilai
MAE	33.194,014
RMSE	42.625,808
R^2	0,987265

Penjelasan Tabel 1 dapat diinterpretasikan bahwa nilai Mean Absolute Error (MAE) sebesar 33.194,014 menunjukkan rata-rata selisih absolut antara prediksi dan nilai aktual penjualan harian berada di kisaran sekitar tiga puluh tiga ribu rupiah per hari, sehingga memberikan gambaran kesalahan prediksi yang cukup intuitif dan relatif kecil

dibandingkan skala omzet harian UMKM MW, serta mengindikasikan tingkat kesalahan rata-rata yang masih dapat diterima untuk kebutuhan operasional. Sementara itu, nilai Root Mean Squared Error (RMSE) sebesar 42.625,808 menandakan adanya penalti yang lebih besar pada kesalahan tinggi sehingga metrik ini lebih sensitif terhadap *outliers* dibanding MAE; RMSE yang lebih tinggi daripada MAE mengisyaratkan bahwa terdapat beberapa prediksi yang meleset lebih besar dari rata-ratanya, yang dalam konteks UMKM F&B dapat dipengaruhi faktor eksternal yang tidak tercatat dalam dataset seperti cuaca ekstrem, promosi mendadak, atau adanya acara khusus di sekitar lokasi usaha yang memicu lonjakan atau penurunan penjualan secara tidak terduga, namun secara keseluruhan nilai tersebut tetap menunjukkan performa model yang kuat. Selain itu, koefisien determinasi (R^2) sebesar 0,987265 merupakan indikator yang sangat tinggi karena berarti model mampu menjelaskan 98,7% variansi penjualan harian pada data uji, sehingga membuktikan bahwa kombinasi algoritma boosting yang iteratif dengan fitur hasil *feature engineering* yang tepat berhasil menangkap pola kompleks dalam data transaksi operasional; dengan kata lain, hampir seluruh fluktuasi penjualan harian UMKM MW dapat dijelaskan oleh fitur-fitur yang digunakan, sekaligus mengonfirmasi bahwa model GBR memiliki tingkat kecocokan yang sangat tinggi terhadap data aktual.


Secara keseluruhan, hasil evaluasi ini mengindikasikan bahwa model *Gradient Boosting Regressor* yang dikembangkan memiliki performa yang sangat impresif dan akurat dalam memprediksi kinerja penjualan harian UMKM MW. Model ini tidak hanya mampu memberikan prediksi yang mendekati nilai aktual, tetapi juga menunjukkan stabilitas yang baik dalam menangani kompleksitas data penjualan harian. Performa yang tinggi ini menjadi dasar yang kuat untuk tahapan selanjutnya, yaitu interpretasi model menggunakan XAI untuk memahami faktor-faktor kunci di balik prediksi tersebut.

3.3 Interpretasi Faktor Kunci Menggunakan SHAP

Setelah model *Gradient Boosting Regressor* (GBR) menunjukkan performa prediksi yang sangat baik, tahapan krusial berikutnya adalah melakukan interpretasi model untuk memahami faktor-faktor apa saja yang paling memengaruhi prediksi penjualan harian. Dalam konteks model *black-box* seperti GBR, yang mampu memberikan akurasi tinggi namun sulit menjelaskan alasan di balik prediksinya, *Explainable AI* (XAI) menjadi sangat penting. XAI, khususnya dengan metode *Shapley Additive Explanations* (SHAP), diterapkan untuk memberikan transparansi, sehingga kontribusi setiap fitur dapat dijelaskan secara kuantitatif dan mudah dipahami oleh pelaku UMKM. Tanpa penjelasan ini, pelaku usaha berisiko kesulitan menerjemahkan hasil prediksi menjadi tindakan konkret, seperti penyesuaian produksi, pengendalian stok, atau strategi operasional harian, sehingga manfaat model sebagai sistem pendukung keputusan menjadi terbatas. Metode SHAP dipilih karena kemampuannya memberikan interpretasi pada dua tingkat sekaligus: global (fitur paling berpengaruh secara keseluruhan) dan lokal (penjelasan untuk prediksi pada hari atau kasus tertentu). Keunggulan ini menjadikan SHAP sangat sesuai untuk konteks prediksi penjualan harian, mengingat penyebab fluktuasi penjualan dapat berbeda antar waktu. Metode ini mengukur kontribusi setiap fitur terhadap prediksi akhir berdasarkan konsep *Shapley value* dari teori permainan kooperatif. Implementasi SHAP dalam penelitian ini menggunakan *TreeExplainer* untuk memastikan interpretasi yang efisien dan akurat terhadap model berbasis pohon. Nilai SHAP menunjukkan besar dan arah kontribusi fitur terhadap prediksi; nilai positif mengindikasikan fitur mendorong peningkatan prediksi, sementara nilai negatif menunjukkan fitur berkontribusi menurunkan prediksi. Dengan demikian, interpretasi SHAP meningkatkan transparansi model dan memperkuat kepercayaan terhadap model prediktif karena faktor-faktor yang memengaruhi prediksi dapat dijelaskan secara terukur dan lebih mudah ditindaklanjuti.

3.3.1 Analisis Kepentingan Fitur Global (*Global Importance*)


Analisis kepentingan fitur global bertujuan untuk mengidentifikasi fitur-fitur mana yang secara keseluruhan memiliki dampak paling signifikan terhadap prediksi penjualan harian.



Gambar 3. Summary Plot

Summary Plot pada Gambar 3 menampilkan sebaran pengaruh setiap fitur terhadap *output* model. Sumbu horizontal menunjukkan nilai SHAP, yang merepresentasikan besarnya kontribusi fitur dalam menaikkan atau menurunkan prediksi penjualan harian. Warna titik mengindikasikan nilai fitur: warna merah merepresentasikan nilai fitur yang tinggi, sedangkan warna biru merepresentasikan nilai fitur yang rendah. Dari *Summary Plot*, terlihat jelas bahwa *Jumlah Menu Terjual* adalah faktor paling dominan karena memiliki sebaran nilai SHAP paling lebar, diikuti oleh *ATV* (*Average Transaction Value*) dan *ATD* (*Average Transaction Daily*). Pola warna pada fitur-fitur utama ini memperlihatkan bahwa nilai yang lebih tinggi cenderung mendorong prediksi penjualan meningkat, sementara nilai yang lebih rendah cenderung menurunkan prediksi. Fitur lain seperti *Jumlah Pesanan Digital* dan *Day of Week* (DoW) masih berkontribusi, namun dengan rentang pengaruh yang lebih kecil, sementara fitur yang nilainya cenderung konstan atau variasinya kecil terlihat memiliki kontribusi yang mendekati nol.

Untuk mempertegas hasil interpretasi global, visualisasi SHAP juga disajikan dalam bentuk bar plot agar peringkat kepentingan fitur dapat terlihat lebih jelas berdasarkan rata-rata kontribusinya terhadap prediksi model.



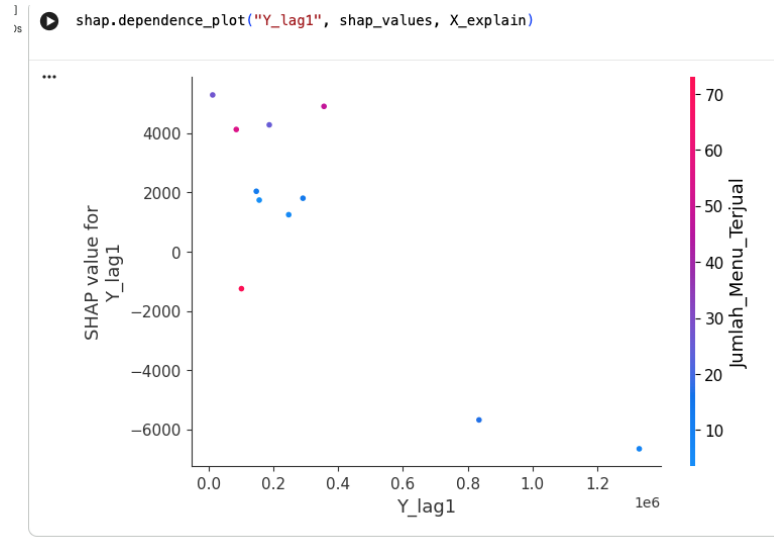
Gambar 4. Bar plot

Gambar 4.. mempertegas hasil interpretasi global dengan menyajikan urutan kepentingan fitur berdasarkan nilai rata-rata absolut SHAP. Ini adalah rata-rata besarnya kontribusi fitur tanpa memperhatikan arah naik atau turunnya prediksi. *Bar Plot* secara konsisten menunjukkan bahwa *Jumlah Menu Terjual* memiliki nilai kepentingan paling tinggi dan jauh melebihi fitur lainnya, menjadikannya fitur utama yang paling menentukan prediksi penjualan harian. Setelah itu, fitur *ATV* dan *ATD* menempati peringkat berikutnya, memperkuat argumen bahwa karakteristik transaksi harian, baik dari sisi nilai transaksi rata-rata maupun aktivitas transaksi, merupakan faktor penting dalam pembentukan prediksi. Fitur-fitur seperti *Jumlah Pesanan Digital*, *Day of Week*, serta fitur *lag* penjualan masih memiliki pengaruh, namun kontribusinya relatif lebih kecil dibandingkan tiga fitur teratas.

Temuan ini memberikan wawasan strategis yang sangat berharga bagi pemilik UMKM MW. Untuk meningkatkan pendapatan, fokus tidak hanya pada penambahan jumlah pelanggan (kuantitas transaksi), tetapi juga pada peningkatan nilai belanja per transaksi (*Average Transaction Value*). Strategi seperti *upselling* (menawarkan produk yang lebih mahal atau premium) atau *bundling* (menggabungkan beberapa produk menjadi satu paket dengan harga menarik) dapat diterapkan untuk mendorong peningkatan ATV. Selain itu, frekuensi transaksi harian (*ATD*) yang menempati posisi ketiga juga memperkuat argumen bahwa menjaga aktivitas transaksi yang stabil setiap hari sangat penting untuk stabilitas pendapatan.

3.3.2 Analisis Ketergantungan Fitur (*Feature Dependence*)

Selain interpretasi global, analisis SHAP juga memungkinkan pemeriksaan hubungan antara nilai fitur tertentu dan *output* model, serta kemungkinan interaksinya dengan fitur lain. *Dependence Plot* digunakan untuk tujuan ini, dan dalam penelitian ini, *Dependence Plot* untuk fitur *Y_lag_1* (penjualan hari sebelumnya).



Gambar 5. SHAP dependence plot untuk Y lag 1

Gambar 5 merupakan plot yang menampilkan hubungan antara nilai Y_{lag_1} (penjualan hari sebelumnya) pada sumbu horizontal dengan nilai SHAP untuk Y_{lag_1} pada sumbu vertikal. Nilai SHAP yang positif menunjukkan bahwa Y_{lag_1} cenderung menaikkan prediksi penjualan, sedangkan nilai SHAP yang negatif menunjukkan kecenderungan menurunkan prediksi. Pola yang menarik terlihat pada plot ini: ketika Y_{lag_1} berada pada nilai rendah hingga menengah, kontribusinya cenderung positif atau mendekati nol. Namun, pada nilai Y_{lag_1} yang sangat tinggi, terdapat titik-titik dengan kontribusi negatif yang cukup besar. Ini mengindikasikan bahwa model melakukan penyesuaian ketika terjadi nilai penjualan hari sebelumnya yang ekstrem. Fenomena ini dalam ilmu data sering disebut sebagai *mean reversion*, di mana setelah lonjakan penjualan yang sangat tinggi, ada kecenderungan penjualan akan kembali ke titik rata-rata pada hari berikutnya. Informasi ini sangat berguna bagi manajemen stok agar tidak melakukan *over-stocking* setelah hari yang sangat ramai, karena penjualan yang sangat tinggi pada satu hari mungkin tidak akan terulang pada hari berikutnya dengan intensitas yang sama.

Warna pada titik-titik dalam *Dependence Plot* merepresentasikan *Jumlah Menu Terjual*, menunjukkan adanya interaksi antara Y_{lag_1} dan *Jumlah Menu Terjual*. Artinya, pada kondisi jumlah item terjual yang tinggi, pengaruh Y_{lag_1} terhadap prediksi dapat berubah tergantung konteks hari tersebut. Hasil ini menegaskan bahwa penjualan hari sebelumnya memang berpengaruh, tetapi tidak selalu secara linear dan dapat bergantung pada kondisi volume penjualan pada hari yang bersangkutan. Pemahaman terhadap interaksi fitur ini memungkinkan pelaku UMKM untuk membuat keputusan yang lebih nuansa dan adaptif terhadap dinamika pasar harian.

3.4 Pembahasan Komprehensif dan Implikasi

Bagian ini menyintesis seluruh temuan yang telah dipaparkan, menghubungkannya kembali dengan pertanyaan penelitian, dan merumuskan implikasi praktis bagi UMKM MW. Integrasi antara *feature engineering* tingkat lanjut, model *Gradient Boosting Regressor* (GBR) yang akurat, dan interpretasi transparan melalui *Explainable AI* (XAI) berbasis SHAP terbukti berhasil mengubah data transaksi mentah menjadi wawasan strategis yang dapat ditindaklanjuti.

3.4.1 Sintesis Temuan dan Kontribusi Penelitian

Penelitian ini berhasil mengatasi kesenjangan yang seringkali dihadapi UMKM, yaitu pemanfaatan data operasional murni yang terbatas pada pencatatan akuntansi dasar. Melalui kerangka kerja yang diusulkan, data transaksi harian UMKM MW selama 19 bulan berhasil ditransformasikan menjadi 21 fitur prediktif yang kaya informasi. Model GBR yang dibangun di atas fitur-fitur ini menunjukkan performa prediksi yang sangat tinggi, dengan nilai R^2 sebesar 0,987 dan MAE sebesar Rp33.194,01. Angka ini mengindikasikan bahwa model mampu menjelaskan hampir seluruh variansi penjualan harian dan memberikan estimasi kesalahan yang sangat toleran dalam konteks bisnis UMKM. Kontribusi paling signifikan dari penelitian ini terletak pada penggunaan SHAP untuk menginterpretasikan model GBR yang bersifat *black-box*. Analisis SHAP secara jelas mengidentifikasi *Jumlah Menu Terjual* dan *Average Transaction Value* (ATV) sebagai faktor paling dominan yang memengaruhi prediksi penjualan. Temuan ini memberikan jawaban konkret atas pertanyaan mengenai "mengapa" penjualan harian berfluktuasi, yang sebelumnya sulit dijawab hanya dengan melihat data mentah. Selain itu, deteksi pola non-linear seperti *mean reversion* pada fitur Y_{lag_1} (penjualan hari sebelumnya) memberikan wawasan yang mendalam tentang dinamika pasar UMKM, yang sangat relevan untuk perencanaan strategis seperti manajemen stok.

3.4.2 Perbandingan dengan Penelitian Sejenis

Penelitian ini memperkuat dan memperkaya literatur prediksi penjualan, khususnya pada konteks UMKM, dengan mengintegrasikan akurasi model, *feature engineering* yang komprehensif, serta interpretasi model yang transparan.



Sejumlah studi terdahulu telah menerapkan *machine learning* untuk peramalan penjualan, namun dengan fokus yang berbeda-beda. Dari sisi akurasi dan metodologi, studi Winurputra dan Ratnawati [16] menunjukkan performa baik XGBoost untuk peramalan penjualan di UB Mart, sementara penelitian ini menegaskan bahwa Gradient Boosting Regressor (GBR) juga sangat stabil dan akurat (R^2 0,987) bahkan pada konteks UMKM mikro dengan data operasional murni. Jika dibandingkan dengan model yang lebih kompleks seperti hibrida CNN-LSTM yang digunakan Mansur et al. [29] pada peramalan ritel, pemanfaatan GBR pada penelitian ini menawarkan efisiensi komputasi yang lebih sesuai untuk data tabular UMKM tanpa kehilangan akurasi yang berarti, serta sejalan dengan pendekatan interpretasi berbasis SHAP seperti yang ditunjukkan Arboleda-Florez [28] pada *demand forecasting*.

Dari aspek transparansi (XAI), banyak penelitian prediksi penjualan, misalnya Sharma [17], lebih menitikberatkan pada hasil prediksi tanpa menggali faktor pendorongnya, sedangkan penelitian ini secara eksplisit mengisi celah tersebut melalui integrasi SHAP untuk memberikan penjelasan kuantitatif kontribusi tiap fitur, selaras dengan urgensi XAI dalam sistem pendukung keputusan yang ditekankan Coussement et al. [14], dan konsisten dengan arah riset lain seperti Wang et al. [30] yang menekankan interpretabilitas pada prediksi penjualan meskipun menggunakan pendekatan *deep learning*. Dari sisi efektivitas *feature engineering*, temuan studi ini menguatkan Li et al. [31] bahwa pembentukan fitur merupakan kunci peningkatan performa, di mana penggunaan fitur lag dan *rolling statistics* terbukti mampu menangkap pola temporal penting sebagaimana juga dibahas dalam pemetaan sistematis oleh Ahaggach et al. [32]. Kontribusi tambahannya adalah pengembangan 21 fitur prediktif dari data operasional murni UMKM, sehingga relevan untuk kondisi data yang terbatas dan tidak selalu terstruktur. Terakhir, fokus penelitian pada UMKM F&B menjadi pembeda penting karena karakteristik UMKM cenderung unik, seperti volume data lebih kecil, dipengaruhi faktor lokal, dan membutuhkan solusi yang mudah dipahami, sehingga kerangka kerja diagnostik yang transparan dan berbasis data operasional murni dalam penelitian ini menjadi lebih aplikatif bagi pelaku UMKM yang tidak selalu memiliki sumber daya analitik yang canggih.

4. KESIMPULAN

Kesimpulan yang ditarik merupakan jawaban atas rumusan masalah dan tujuan penelitian yang telah ditetapkan sebelumnya, yang didasarkan pada hasil evaluasi performa model serta analisis kontribusi fitur secara kuantitatif. Selain itu, bab ini juga memuat saran-saran strategis yang ditujukan bagi pengembangan penelitian di masa depan maupun bagi kepentingan operasional mitra UMKM MW guna meningkatkan efektivitas pengambilan keputusan berbasis data. Berdasarkan hasil penelitian, analisis, dan pembahasan yang telah dilakukan mengenai analisis faktor kinerja penjualan harian UMKM MW menggunakan metode *Feature Engineering* dan XAI berbasis *Gradient Boosting Regressor*, maka dapat ditarik kesimpulan jawaban terhadap Problem Statement: Penelitian ini berhasil mengatasi kesenjangan dalam pemanfaatan data operasional murni pada UMKM F&B. Melalui integrasi *feature engineering* dan *Explainable AI (XAI)*, data transaksi mentah yang sebelumnya hanya digunakan untuk pencatatan akuntansi dasar kini dapat ditransformasikan menjadi wawasan diagnostik yang transparan. Model yang dikembangkan mampu menjawab "mengapa" penjualan harian berfluktuasi dengan mengidentifikasi kontribusi spesifik dari setiap faktor operasional. Hasil Analisis Evaluasi: Implementasi algoritma *gradient boosting regressor (GBR)* menunjukkan performa yang sangat tinggi dengan nilai Koefisien Determinasi (R^2) sebesar 0,987. Hal ini membuktikan bahwa model mampu menjelaskan 98,7% variansi data penjualan harian. Meskipun terdapat selisih rata-rata (MAE) sebesar Rp33.194,01, nilai tersebut masih berada dalam batas toleransi operasional UMKM MW. Evaluasi ini mengonfirmasi bahwa kombinasi 21 fitur hasil rekayasa (*lagged* dan *rolling statistics*) sangat efektif dalam menangkap pola ketergantungan temporal penjualan. Identifikasi Faktor Kunci melalui XAI: Melalui metode SHAP, ditemukan bahwa Jumlah Menu Terjual merupakan faktor paling dominan yang memengaruhi prediksi penjualan, diikuti oleh *average transaction value (ATV)* dan *average transaction daily (ATD)*. Temuan penting lainnya adalah adanya *pola non-linear* pada fitur Y lag 1, di mana model mendeteksi kecenderungan penurunan penjualan setelah terjadinya lonjakan ekstrem pada hari sebelumnya (*mean reversion*). Hal ini memberikan transparansi yang sebelumnya tidak dimiliki oleh model black-box standar.

REFERENCES

- [1] "Pemerintah Dorong UMKM Naik Kelas, Tingkatkan Kontribusi terhadap Ekspor Indonesia - Kementerian Koordinator Bidang Perekonomian Republik Indonesia." Accessed: Nov. 07, 2025. [Online]. Available: <https://www.ekon.go.id/publikasi/detail/6152/pemerintah-dorong-umkm-naik-kelas-tingkatkan-kontribusi-terhadap-ekspor-indonesia>
- [2] "UMKM Indonesia - Kadin Indonesia." Accessed: Nov. 17, 2025. [Online]. Available: <https://kadin.id/data-dan-statistik/umkm-indonesia/>
- [3] E. N. Yunus, E. Ernawati, E. Nuraini, and K. Yuniarti, "Post-crisis growth: Resource orchestration, innovation, and diversification in MSMEs," *Journal of Open Innovation: Technology, Market, and Complexity*, vol. 11, no. 2, p. 100570, Jun. 2025, doi: 10.1016/j.joitmc.2025.100570.
- [4] D. Novianti and B. Baihaqi, "The Influence of E-Payment and E-Commerce Services on Supply Chain Performance MSMEs," *Asian Journal of Applied Business and Management*, vol. 4, no. 2, pp. 405–420, May 2025, doi: 10.55927/ajabm.v4i2.141.
- [5] A. L. Kilay, B. H. Simamora, and D. P. Putra, "The Influence of E-Payment and E-Commerce Services on Supply Chain Performance: Implications of Open Innovation and Solutions for the Digitalization of Micro, Small, and Medium Enterprises



- (MSMEs) in Indonesia,” *Journal of Open Innovation: Technology, Market, and Complexity*, vol. 8, no. 3, Sep. 2022, doi: 10.3390/joitmc8030119.
- [6] H. Aini Shafira, S. Informasi, and S. Tinggi Teknologi Terpadu Nurul Fikri Jakarta Selatan, “Penerapan Modul Point of Sale Odoo untuk Efisiensi Transaksi Penjualan Umkm Toko Tiga Saudara,” *Journal of Digital Business and Technology Innovation (DBESTI)*, vol. 2, no. 2, pp. 308–312, 2025, [Online]. Available: <https://journal.nurulfikri.ac.id/index.php/DBESTI>
- [7] S. A. Hendrawan, Afdhal Chatra, Nurul Iman, Soemarno Hidayatullah, and Degdo Suprayitno, “Digital Transformation in MSMEs: Challenges and Opportunities in Technology Management,” *Jurnal Informasi dan Teknologi*, pp. 141–149, Jun. 2024, doi: 10.60083/jidt.v6i2.551.
- [8] Y. Ceng Giap, “Penerapan Data Mining untuk Menganalisis Pola Transaksi Penjualan Dengan Metode Association Rule Algoritma Fp-Growth (Studi Kasus : Pt. Tumbakmas Niaga Sakti),” *Sains Terapan dan Teknologi*, vol. 4, no. 2, pp. 1–11, Oct. 2023.
- [9] E. D. Purnamasari and A. Asharie, “Digitalisasi Umkm, Literasi Keuangan Terhadap Kinerja Keuangan Umkm di Era New Normal Pandemi Covid 19,” *Jesya*, vol. 7, no. 1, pp. 348–361, Jan. 2024, doi: 10.36778/jesya.v7i1.1416.
- [10] B. Rolando *et al.*, “Digital Marketing Strategies for Sales Growth in Indonesian Home Industries,” *Journal of Trends Economics and Accounting Research*, vol. 5, no. 3, pp. 278–292, 2025, doi: 10.47065/jtear.v5i3.1852.
- [11] Y. A. Nugroho and H. A. Hutahaean, “Pengembangan Model Deep Learning LSTM dan CNN untuk Peramalan Penjualan Sepeda Motor di Indonesia,” *Jupiter: Publikasi Ilmu Keteknikan Industri, Teknik Elektro dan Informatika*, vol. 3, no. 2, pp. 94–104, Mar. 2025, doi: 10.61132/jupiter.v3i2.795.
- [12] F. A. Rangkuti, Khairunnisa, and S. Sundari, “Implementasi Gradient Boosting Machines untuk Prediksi Harga Rumah Pada Jakarta Selatan,” *Jurnal Kecerdasan Buatan dan Teknologi Informasi*, vol. 4, no. 2, pp. 164–172, May 2025, doi: 10.69916/jkbtii.v4i2.318.
- [13] A. S. Antonini *et al.*, “Machine Learning Model Interpretability Using SHAP Values: Application to Igneous Rock Classification Task,” Sep. 01, 2024, *Elsevier B.V.* doi: 10.1016/j.acags.2024.100178.
- [14] K. Coussement, M. Z. Abedin, M. Kraus, S. Maldonado, and K. Topuz, “Explainable AI for Enhanced Decision Making,” *Decis. Support Syst.*, vol. 184, p. 114276, Sep. 2024, doi: 10.1016/J.DSS.2024.114276.
- [15] P. Rozita, E. Saiful Subhan, and S. Tinggi Ilmu Ekonomi Yapis, “Analisis Strategi Pemasaran pada UMKM di Era Digital: Studi Kasus Pada Platform Shopee,” *Economics and Digital Business Review*, vol. 7, no. 1, pp. 2025–365, 2025.
- [16] R. Winurputra and D. E. Ratnawati, “Peramalan Penjualan Produk Menggunakan Extreme Gradient Boosting (XGBoost) dan Kerangka Kerja CRISP-DM untuk Pengoptimalan Manajemen Persediaan (Studi Kasus: UB Mart),” *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 12, no. 2, pp. 417–428, Apr. 2025, doi: 10.25126/jtiik.2025129451.
- [17] G. Sharma and S. Patil, “Extreme Gradient Boosting Model-based Forecasting of Big Data Online Sales Record,” *SAMRIDDHI : A Journal of Physical Sciences, Engineering and Technology*, vol. 14, no. 01, pp. 112–119, Mar. 2022, doi: 10.18090/samriddhi.v14i01.18.
- [18] S. A. Khairi, A. R. Ardiansyah, and L. Rosyidi, “Perbandingan XGB Regressor Dengan Algoritma Lain untuk Prediksi Tarif Tol,” *Journal of Digital Business and Technology Innovation (DBESTI)*, vol. 2, no. 1, pp. 127–132, 2025, [Online]. Available: <https://journal.nurulfikri.ac.id/index.php/DBESTI>
- [19] S. Mansur *et al.*, “Sales forecasting for retail stores using hybrid neural networks and sales-affecting variables,” *PeerJ Comput. Sci.*, vol. 11, p. e3058, Sep. 2025, doi: 10.7717/peerj-cs.3058.
- [20] A. Iqbal and R. Amin, “An Efficient Mechanism for Time Series Forecasting and Anomaly Detection Using Explainable Artificial Intelligence,” *J. Supercomput.*, vol. 81, no. 4, p. 523, Feb. 2025, doi: 10.1007/s11227-025-07040-0.
- [21] K. Dwi Hartomo, C. Arthur, and Y. Nataliani, “A Novel Weighted Loss TabTransformer Integrating Explainable AI for Imbalanced Credit Risk Datasets,” *IEEE Access*, vol. 13, pp. 31045–31056, 2025, doi: 10.1109/ACCESS.2025.3541878.
- [22] P. Slater and F. Hasson, “Quantitative Research Designs, Hierarchy of Evidence and Validity,” *J. Psychiatr. Ment. Health Nurs.*, vol. 32, no. 3, pp. 656–660, Jun. 2025, doi: 10.1111/jpm.13135.
- [23] S. Karmaker, “Feature Engineering in Time Series Forecasting: an Empirical Study Using German Electricity Load Data Feature Engineering in Time Series Forecasting,” *ScienceOpen Preprints*, Nov. 2025, doi: 10.25832/time_series/2020-10-06.
- [24] X. Long *et al.*, “Scalable Probabilistic Forecasting in Retail With Gradient Boosted Trees: a Practitioner’s Approach,” *Int. J. Prod. Econ.*, vol. 279, Jan. 2025, doi: 10.1016/j.ijpe.2024.109449.
- [25] C. Bentéjac, A. Csörgő, and G. Martínez-Muñoz, “A comparative analysis of gradient boosting algorithms,” *Artif. Intell. Rev.*, vol. 54, no. 3, pp. 1937–1967, Mar. 2019, doi: 10.1007/s10462-020-09896-5.
- [26] S. M. Lundberg and S. I. Lee, “A Unified Approach to Interpreting Model Predictions,” *Adv. Neural Inf. Process. Syst.*, vol. 2017-December, pp. 4766–4775, May 2017, Accessed: Dec. 12, 2025. [Online]. Available: <https://arxiv.org/pdf/1705.07874>
- [27] R. Rodríguez-Pérez and J. Bajorath, “Interpretation of machine learning models using shapley values: application to compound potency and multi-target activity predictions,” *J. Comput. Aided. Mol. Des.*, vol. 34, no. 10, pp. 1013–1026, Oct. 2020, doi: 10.1007/s10822-020-00314-0.
- [28] M. Arboleda-Florez and C. Castro-Zuluaga, “Interpreting Direct Sales’ Demand Forecasts Using SHAP Values,” *Production*, vol. 33, 2023, doi: 10.1590/0103-6513.20220035.
- [29] S. Mansur *et al.*, “Sales forecasting for retail stores using hybrid neural networks and sales-affecting variables,” *PeerJ Comput. Sci.*, vol. 11, p. e3058, Sep. 2025, doi: 10.7717/peerj-cs.3058.
- [30] L. Wang and X. Zhang, “Livestream sales prediction based on an interpretable deep-learning model,” *Sci. Rep.*, vol. 14, no. 1, p. 20594, Sep. 2024, doi: 10.1038/s41598-024-71379-2.
- [31] J. Li, Z. Zhang, S. Kang, Y. Lu, L. Gan, and Y. Xu, “Research on Future Sales Prediction Based on Feature Engineering,” in *Proceedings of the 4th International Conference on Artificial Intelligence and Computer Engineering*, New York, NY, USA: ACM, Nov. 2023, pp. 223–228. doi: 10.1145/3652628.3652666.
- [32] H. Ahaggach, L. Abrouk, and E. Lebon, “Systematic Mapping Study of Sales Forecasting: Methods, Trends, and Future Directions,” *Forecasting*, vol. 6, no. 3, pp. 502–532, Sep. 2024, doi: 10.3390/forecast6030028.