



## *Predictive and Prescriptive Analytics Approach for Optimizing Campus Snack Sales Operations*

### **Pendekatan Analitik Prediktif dan Preskriptif untuk Optimasi Operasional Penjualan Snack di Lingkungan Kampus**

Lita Sari Muchlis<sup>1\*</sup>, Iswandi<sup>2</sup>, Zihnil Afif<sup>3</sup>, Adriyendi<sup>4</sup>, Lidya Rahmi<sup>5</sup>, Eva Rahmayanti Br Saragih<sup>6</sup>,  
Nindya Dwi Putri<sup>7</sup>

<sup>1,2,3,4,5,6,7</sup>Departemen Information Systems, Mahmud Yunus State Islamic University

E-Mail: [litasari.m@uinmybatusangkar.ac.id](mailto:litasari.m@uinmybatusangkar.ac.id)<sup>1</sup>, [iswandi@uinmybatusangkar.ac.id](mailto:iswandi@uinmybatusangkar.ac.id)<sup>2</sup>,  
[zihnilafif@uinmybatusangkar.ac.id](mailto:zihnilafif@uinmybatusangkar.ac.id)<sup>3</sup>, [adriyendi@uinmybatusangkar.ac.id](mailto:adriyendi@uinmybatusangkar.ac.id)<sup>4</sup>,  
[lidyarahmi@uinmybatusangkar.ac.id](mailto:lidyarahmi@uinmybatusangkar.ac.id)<sup>5</sup>, [Evarahmayanti@brsaragih03@gmail.com](mailto:Evarahmayanti@brsaragih03@gmail.com)<sup>6</sup>,  
[nindyaputri280505@gmail.com](mailto:nindyaputri280505@gmail.com)<sup>7</sup>

Makalah: Diterima 25 Januari 2026; Diperbaiki 20 Februari 2026; Disetujui 24 Maret 2026  
Corresponding Author: Lita Sari Muchlis

#### **Abstrak**

Penelitian ini bertujuan untuk mengoptimalkan penjualan snack mahasiswa di lingkungan kampus menggunakan pendekatan *Artificial Intelligence* (AI) prediktif dan preskriptif. Metode yang digunakan meliputi pengumpulan data penjualan dari lima kantin fakultas dengan variabel jenis produk, hari transaksi, cuaca, event kampus, dan promo. Model prediktif dalam penelitian ini dibangun menggunakan algoritma *Linear Regression*, *Random Forest*, *Gradient Boosting*, dan *XGBoost*. Selanjutnya, model preskriptif dikembangkan melalui pendekatan *What-If Analysis* untuk menghasilkan rekomendasi optimalisasi strategi penjualan dan pengelolaan stok berdasarkan berbagai kondisi penjualan. Hasil evaluasi menunjukkan bahwa seluruh model memiliki performa yang sangat baik dengan nilai koefisien determinasi ( $R^2$ ) dan *cross-validation* di atas 0,98. Model *Gradient Boosting* menghasilkan performa terbaik dengan nilai  $R^2$  sebesar 0,9917, MAE sebesar 0,8872, serta nilai *cross-validation*  $R^2$  sebesar 0,9875. Sementara itu, *Linear Regression*, *Random Forest*, dan *XGBoost* juga menunjukkan hasil prediksi yang kompetitif dan stabil. Analisis preskriptif menunjukkan bahwa jenis produk, hari transaksi, dan event kampus merupakan faktor utama yang memengaruhi penjualan, sedangkan promo dan cuaca memiliki pengaruh yang relatif lebih kecil. Penelitian ini menunjukkan bahwa integrasi AI prediktif dan preskriptif mampu membantu pengelola kantin dalam mengoptimalkan strategi penjualan, pengelolaan stok, serta pengambilan keputusan berbasis data secara lebih efektif di lingkungan kampus.

Keyword: Analisis Skenario, Gradient Boosting, *Machine Learning*, Penjualan Snack Kampus, *XGBoost*

#### **Abstract**

*This study aims to optimize snack sales among college students on campus using predictive and prescriptive Artificial Intelligence (AI) approaches. The methods employed include collecting sales data from five faculty cafeterias, with variables such as product type, transaction day, weather, campus events, and promotions. The predictive models in this study were built using Linear Regression, Random Forest, Gradient Boosting, and XGBoost. Furthermore, prescriptive models were developed using a What-If Analysis approach to generate recommendations for optimizing sales strategies and inventory management across various sales conditions. Evaluation results show that all models perform very well, with a coefficient of determination ( $R^2$ ) and cross-validation  $R^2$  values above 0.98. The Gradient Boosting model delivered the best performance, with an  $R^2$  of 0.9917, a Mean Absolute Error (MAE) of 0.8872, and a cross-validation  $R^2$  of 0.9875. Meanwhile, Linear Regression, Random Forest, and XGBoost also produced competitive, stable predictions. Prescriptive analysis indicates that product type, transaction day, and campus events are the primary factors influencing sales, while promotions and weather have relatively smaller effects. This study demonstrates that integrating predictive and prescriptive AI can help cafeteria managers optimize sales strategies, improve inventory management, and make data-driven decisions more effectively within a campus environment.*

Keyword: Campus Snack Sales, Gradient Boosting, *Machine Learning*, *XGBoost*, *What-If Analysis*

## 1. PENDAHULUAN

Usaha penjualan makanan ringan di lingkungan kampus merupakan salah satu sektor usaha mikro yang menunjukkan potensi pertumbuhan yang cukup menjanjikan. Kondisi ini dipengaruhi oleh gaya hidup mahasiswa yang cenderung praktis dan serba cepat, sehingga makanan ringan menjadi pilihan utama untuk memenuhi kebutuhan konsumsi di sela aktivitas kampus [1][2]. Selain itu, mahasiswa sebagai konsumen memiliki karakteristik konsumsi yang unik, seperti pembelian yang bersifat impulsif, waktu pembelian yang tidak teratur, serta preferensi yang beragam terhadap jenis, rasa, dan harga snack [3]. Karakteristik tersebut menjadikan permintaan snack di lingkungan kampus bersifat dinamis dan sulit diprediksi secara manual.

Walaupun permintaan pasar cukup tinggi, sebagian besar pelaku UMKM di bidang ini masih menentukan strategi bisnis berdasarkan perkiraan dan pengalaman pribadi. Penentuan jumlah stok, pemilihan jenis produk, serta strategi promosi umumnya dilakukan tanpa dukungan analisis data yang memadai. Kondisi ini sering menimbulkan ketidaksesuaian antara penawaran dan permintaan, yang berpotensi menyebabkan kerugian akibat kelebihan stok maupun kehilangan peluang penjualan ketika permintaan meningkat [4]. Permasalahan ini menunjukkan bahwa pelaku usaha snack di lingkungan kampus membutuhkan pendekatan yang lebih sistematis dan berbasis data dalam mengelola penjualan.

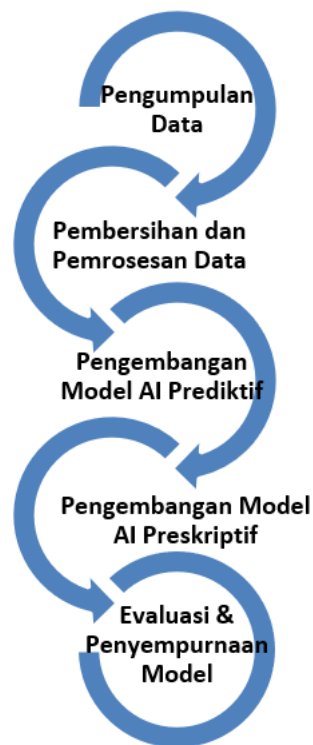
Perkembangan teknologi kecerdasan buatan (*Artificial Intelligence*) memberikan peluang baru dalam mengatasi permasalahan tersebut, khususnya melalui pendekatan analitik prediktif dan preskriptif. AI prediktif memungkinkan sistem untuk memproyeksikan permintaan di masa depan berdasarkan pola data historis, serta mempertimbangkan variabel kontekstual seperti jadwal kuliah, tren konsumsi, maupun kondisi tertentu yang memengaruhi perilaku pembelian [5][6]. Sementara itu, AI preskriptif dapat memberikan rekomendasi tindakan yang optimal berdasarkan hasil prediksi yang dihasilkan, seperti menentukan jumlah stok yang ideal, strategi promosi yang tepat, serta waktu terbaik untuk menjual produk tertentu [7].

Beberapa studi terdahulu menunjukkan bahwa penerapan *machine learning* mampu menghasilkan prediksi penjualan yang lebih akurat dibandingkan metode konvensional yang hanya mengandalkan intuisi [8]. Wijaya et al. (2024) juga melaporkan bahwa pendekatan *machine learning* dapat meningkatkan ketepatan prediksi penjualan secara signifikan pada sektor ritel. Penelitian lain oleh Yuniar dan Ambarwati (2023) memanfaatkan algoritma *neural network* untuk memprediksi tingkat penjualan pada toko ritel, dengan hasil berupa peningkatan akurasi estimasi permintaan berdasarkan data historis serta segmentasi pelanggan [9]. Selain itu, Hidayah et al. (2023) menemukan bahwa penerapan kecerdasan buatan preskriptif mampu meningkatkan efektivitas pengambilan keputusan bisnis, terutama dalam penyusunan strategi promosi berbasis data [10]. Selaras dengan temuan tersebut, Chaudhry et al. (2024) menyatakan bahwa penggunaan *prescriptive analytics* pada strategi promosi ritel dapat meningkatkan keuntungan melalui rekomendasi promosi yang lebih terarah [11]. Sementara itu, Sari et al. (2021) mengungkapkan bahwa preferensi konsumsi makanan ringan di kalangan mahasiswa sangat beragam dan dipengaruhi oleh faktor harga, cita rasa, serta kemudahan akses, sehingga semakin menegaskan pentingnya pendekatan berbasis data dalam pengelolaan penjualan snack mahasiswa [12]. Namun, sebagian besar penelitian terdahulu masih berfokus pada prediksi penjualan pada sektor ritel umum dan skala bisnis menengah hingga besar. Penelitian yang secara khusus membahas penerapan pendekatan prediktif dan preskriptif pada usaha mikro penjualan snack di lingkungan kampus masih relatif terbatas. Selain itu, sebagian besar penelitian sebelumnya hanya menitikberatkan pada akurasi prediksi tanpa mengintegrasikan rekomendasi strategi penjualan dan pengelolaan stok sebagai bagian dari pendekatan preskriptif. Oleh karena itu, diperlukan penelitian yang tidak hanya mampu menghasilkan prediksi penjualan yang akurat, tetapi juga memberikan rekomendasi pengambilan keputusan yang lebih praktis dan sesuai dengan karakteristik usaha mikro di lingkungan kampus.

Berdasarkan hal tersebut, penelitian ini berfokus pada optimalisasi penjualan snack mahasiswa dengan menggunakan pendekatan *Artificial Intelligence* prediktif dan preskriptif melalui algoritma *Linear Regression*, *Random Forest*, *Gradient Boosting*, dan *XGBoost*. Metode *Linear Regression* digunakan karena mampu menggambarkan hubungan antar variabel secara sederhana serta mudah dipahami dalam proses interpretasi hasil [13]. Beberapa penelitian terdahulu juga menunjukkan bahwa metode ini dapat menghasilkan nilai koefisien determinasi ( $R^2$ ) yang baik sehingga layak digunakan untuk kebutuhan prediksi [14]. Selanjutnya, *Random Forest* digunakan karena memiliki kemampuan membaca pola data berukuran besar, meningkatkan akurasi prediksi, serta membantu menekan risiko *overfitting* melalui pendekatan *ensemble learning* [15][16]. Sementara itu, *Gradient Boosting* dimanfaatkan karena model dibangun secara bertahap untuk memperbaiki kesalahan prediksi sebelumnya, sekaligus mengidentifikasi variabel penting melalui analisis *feature importance* [17][18]. Adapun *XGBoost* (*Extreme Gradient Boosting*) digunakan sebagai pengembangan dari metode *Gradient Boosting* berbasis *ensemble learning* yang mampu menangani data dalam skala lebih besar secara efisien. Metode ini memiliki keunggulan dalam kecepatan komputasi, efisiensi memori, serta performa prediksi yang tinggi dibandingkan metode *boosting* konvensional [19] [20]. Dengan demikian, penelitian ini tidak hanya berfokus pada penyusunan model prediksi, tetapi juga menggabungkannya dengan pendekatan preskriptif guna menghasilkan rekomendasi strategi penjualan yang lebih tepat. Pendekatan tersebut diharapkan dapat membantu pengelola usaha snack mahasiswa dalam meningkatkan kinerja penjualan serta mendukung proses pengambilan keputusan.

## 2. METODE DAN BAHAN

Penelitian ini disusun melalui beberapa tahapan utama yang berfokus pada pengembangan model prediktif dan preskriptif untuk meningkatkan penjualan snack di lingkungan kampus. Lokasi penelitian berada di kawasan Universitas Islam Negeri Mahmud Yunus Batusangkar, dengan kantin fakultas sebagai sumber data utama. Data penelitian dikumpulkan secara terstruktur dari sejumlah kantin yang mewakili variasi produk snack yang dipasarkan kepada mahasiswa. Proses pengumpulan data dilakukan selama satu bulan, yaitu pada periode Agustus sampai Oktober 2025. Tahap berikutnya, penelitian dilaksanakan melalui serangkaian langkah utama yang meliputi pengumpulan data, pembersihan dan pemrosesan data, pengembangan model prediktif, serta penyusunan rekomendasi strategi penjualan berdasarkan hasil analisis. Langkah-langkah penelitian dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Penelitian

### 2.1 Pengumpulan Data

Sumber data penelitian berasal dari lima kantin fakultas di lingkungan Universitas Islam Negeri Mahmud Yunus Batusangkar yang melayani penjualan berbagai jenis snack kepada mahasiswa. Informasi dikumpulkan melalui pengamatan langsung terhadap aktivitas transaksi harian serta wawancara dengan pengelola kantin untuk memahami faktor-faktor yang memengaruhi penjualan. Dataset penelitian terdiri atas 486 data transaksi penjualan dengan total 15 variabel. Variabel tersebut mencakup data kategorikal dan numerik. Variabel kategorikal meliputi hari transaksi, kondisi cuaca, jenis kegiatan kampus, promo, nama toko, nama produk, dan jenis produk. Sementara itu, variabel numerik terdiri atas harga produk, stok awal, stok akhir, dan jumlah produk terjual. Data yang telah dikumpulkan kemudian digunakan sebagai dasar dalam proses pengembangan model prediktif dan preskriptif untuk analisis penjualan snack.

### 2.2 Pembersihan dan Pemrosesan Data

Setelah data terkumpul, tahap berikutnya adalah menyeleksi kualitas data sebelum digunakan dalam analisis. Catatan yang tidak lengkap maupun data ganda dihapus agar tidak memengaruhi hasil pengolahan. Selanjutnya dilakukan normalisasi untuk menyamakan rentang nilai antarvariabel sehingga setiap variabel dapat diproses secara proporsional oleh model. Setelah seluruh tahapan tersebut selesai, data dinyatakan siap digunakan pada proses pemodelan. Setelah seluruh tahapan pembersihan dan pemrosesan data selesai, data dinyatakan siap digunakan pada proses pemodelan. Sebelum pelatihan model dilakukan, dataset dibagi menjadi data latih dan data uji menggunakan metode *hold-out validation* dengan rasio 80:20. Sebanyak 80% data digunakan untuk proses pelatihan model, sedangkan 20% sisanya digunakan untuk pengujian performa model. Pembagian data dilakukan secara acak untuk menjaga konsistensi hasil eksperimen.

### 2.3 Pengembangan Model AI Prediktif

Tahap pemodelan dilakukan untuk memperkirakan permintaan snack pada periode berikutnya. Empat algoritma digunakan dalam penelitian ini, yaitu *Linear Regression*, *Random Forest*, *Gradient Boosting*, dan *XGBoost*. *Linear Regression* digunakan sebagai model dasar untuk melihat hubungan antar variabel terhadap penjualan. *Random Forest* diterapkan melalui pembentukan sejumlah pohon keputusan dari sampel data yang berbeda, kemudian hasilnya digabungkan menjadi satu prediksi. Adapun *Gradient Boosting* bekerja secara bertahap dengan membangun model baru untuk memperbaiki kesalahan prediksi sebelumnya. Sementara itu, *XGBoost* digunakan sebagai model pembanding karena memiliki kemampuan boosting dan regularisasi yang mampu meningkatkan akurasi prediksi serta mengurangi risiko *overfitting*. Seluruh model dilatih menggunakan data historis penjualan yang telah diproses pada tahap sebelumnya.

### 2.4 Pengembangan Model AI Preskriptif

Model AI preskriptif dikembangkan menggunakan pendekatan *What-If Analysis* untuk mensimulasikan berbagai skenario penjualan berdasarkan kondisi yang berbeda, seperti cuaca, adanya event kampus, dan promosi. Skenario yang diuji meliputi kondisi normal tanpa event maupun promo dengan cuaca cerah, kondisi adanya event kampus seperti seminar atau ujian, kombinasi antara event kampus dan promo, serta kondisi cuaca hujan tanpa adanya event atau promo. Selain melakukan simulasi skenario, model preskriptif juga digunakan untuk memberikan rekomendasi keputusan berdasarkan hasil prediksi penjualan. Rekomendasi tersebut meliputi penentuan waktu penjualan produk, prioritas produk yang perlu disiapkan, serta estimasi jumlah stok yang optimal untuk mengurangi risiko kekurangan maupun kelebihan persediaan. Pendekatan ini membantu pengelola kantin dalam menentukan strategi penjualan yang lebih efektif berdasarkan kondisi yang diprediksi terjadi.

### 2.5 Evaluasi dan Penyempurnaan Model

Setelah model prediktif dan preskriptif dikembangkan, tahap berikutnya adalah melakukan evaluasi serta penyempurnaan model. Tahap evaluasi dilakukan dengan membandingkan nilai prediksi terhadap data penjualan aktual guna mengetahui tingkat ketepatan model yang telah dibangun. Selanjutnya, dilakukan penyesuaian terhadap parameter model guna meningkatkan performa prediksi. Evaluasi model prediktif dilakukan menggunakan metrik  $R^2$  (*coefficient of determination*) dan MAE (*Mean Absolute Error*) untuk menilai tingkat ketepatan dan kesalahan prediksi model.

Koefisien determinasi ( $R^2$ ) menunjukkan seberapa besar variasi data penjualan dapat dijelaskan oleh model. Nilainya berada pada rentang 0 sampai 1. Nilai yang semakin mendekati 1 menunjukkan bahwa model semakin baik dalam menjelaskan pola data, sedangkan nilai yang rendah menunjukkan kemampuan model yang masih terbatas. Namun demikian, penilaian model tidak hanya bergantung pada  $R^2$ , melainkan juga perlu mempertimbangkan ukuran sampel dan tingkat kesalahan prediksi [21] [22].

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

Keterangan :

$y_i$  = nilai aktual pada observasi ke-i,

$\hat{y}_i$  = nilai hasil prediksi,

$\bar{y}$  = rata-rata data aktual,

$n$  = jumlah observasi.

MAE digunakan untuk melihat rata-rata selisih absolut antara hasil prediksi dan nilai aktual. Semakin kecil nilai MAE, maka prediksi yang dihasilkan semakin dekat dengan data sebenarnya. Ukuran ini memberikan gambaran langsung mengenai besar kesalahan prediksi tanpa memperhatikan arah selisih.

$$MAE = \frac{1}{n} \sum_{i=1}^n |f_i - y_i| \quad (2)$$

Keterangan :

$f_i$  = hasil prediksi pada observasi ke-i,

$y_i$  = nilai aktual.

Selain menggunakan metrik  $R^2$  dan MAE, evaluasi model juga dilakukan menggunakan teknik *5-fold cross-validation* untuk menguji konsistensi performa model melalui beberapa skenario pembagian data. Pendekatan ini digunakan untuk mengurangi risiko *overfitting* serta memastikan bahwa model memiliki kemampuan generalisasi yang baik terhadap data yang berbeda [23].

### 3. HASIL DAN PEMBAHASAN

Bagian ini memaparkan hasil penerapan model prediktif dan preskriptif pada penjualan snack di lingkungan kampus UIN Mahmud Yunus Batusangkar. Model prediktif digunakan untuk memperkirakan permintaan berdasarkan data historis serta beberapa variabel pendukung, seperti hari transaksi, kondisi cuaca, dan kegiatan kampus. Selanjutnya, pendekatan preskriptif dimanfaatkan untuk menyusun rekomendasi strategi penjualan melalui simulasi berbagai kondisi. Tingkat kinerja model diukur menggunakan nilai  $R^2$  dan MAE sehingga ketepatan hasil prediksi dapat diketahui secara lebih jelas.

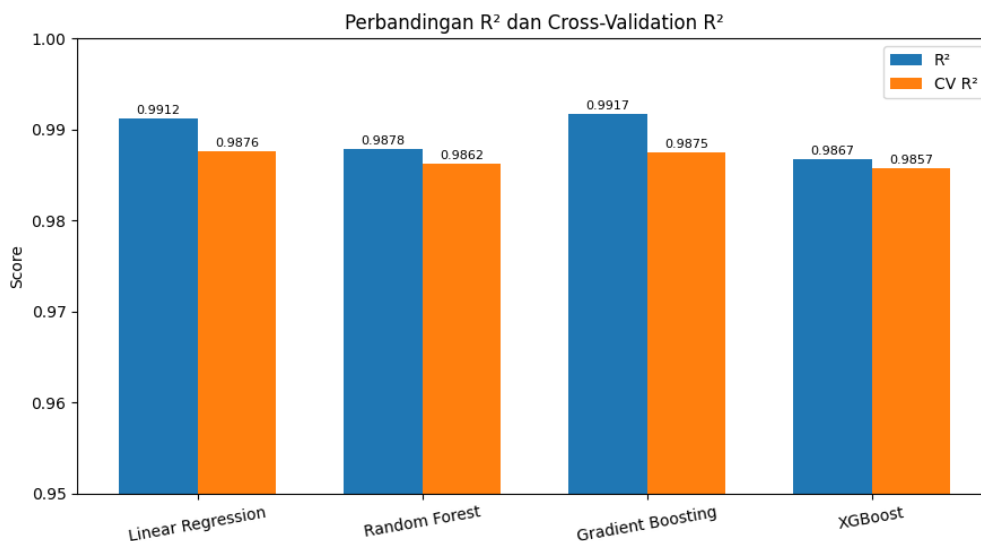
#### 3.1 Hasil Model Prediktif

Pengembangan model prediktif dilakukan untuk memperkirakan jumlah permintaan snack pada periode berikutnya. Empat algoritma yang diuji dalam penelitian ini adalah *Linear Regression*, *Random Forest*, *Gradient Boosting*, dan *XGBoost*. Setiap model dibandingkan berdasarkan hasil evaluasi menggunakan ukuran yang sama agar dapat diketahui model dengan performa terbaik. Ringkasan hasil pengujian keempat model disajikan pada bagian berikut.

##### 3.1.1 Hasil Model Evaluasi

Pengujian terhadap empat algoritma menunjukkan bahwa seluruh model mampu memberikan hasil prediksi yang sangat baik terhadap data penjualan snack. Evaluasi model dilakukan menggunakan nilai koefisien determinasi ( $R^2$ ), *Mean Absolute Error* (MAE), serta *5-fold cross-validation*  $R^2$  untuk mengukur tingkat akurasi dan konsistensi performa model.

Berdasarkan hasil pengujian, model *Gradient Boosting* menghasilkan performa terbaik dengan nilai  $R^2$  sebesar 0,9917, MAE sebesar 0,8872, dan rata-rata *cross-validation*  $R^2$  sebesar 0,9875. Hasil tersebut menunjukkan bahwa model memiliki tingkat akurasi yang tinggi serta kemampuan generalisasi yang baik terhadap data baru. Model *Linear Regression* juga memberikan hasil yang kompetitif dengan nilai  $R^2$  sebesar 0,9912, MAE sebesar 0,8807, dan *cross-validation*  $R^2$  sebesar 0,9876. Nilai MAE yang rendah menunjukkan bahwa selisih antara hasil prediksi dan data aktual relatif kecil. Sementara itu, model *Random Forest* memperoleh nilai  $R^2$  sebesar 0,9878, MAE sebesar 0,9395, dan *cross-validation*  $R^2$  sebesar 0,9862. Walaupun nilainya sedikit lebih rendah dibandingkan dua model sebelumnya, model ini tetap menunjukkan performa prediksi yang baik dan stabil. Adapun model *XGBoost* menghasilkan nilai  $R^2$  sebesar 0,9867, MAE sebesar 0,9908, dan *cross-validation*  $R^2$  sebesar 0,9857. Meskipun *XGBoost* dikenal sebagai algoritma *boosting* modern dengan performa tinggi pada berbagai kasus prediksi, pada penelitian ini performanya masih berada di bawah *Gradient Boosting*. Hal ini diduga disebabkan oleh ukuran dataset yang relatif terbatas dan pola data yang tidak terlalu kompleks. Secara umum, seluruh algoritma layak digunakan untuk memprediksi penjualan snack. Namun, berdasarkan hasil evaluasi menggunakan  $R^2$ , MAE, dan *cross-validation*, model *Gradient Boosting* menunjukkan performa yang paling optimal. Perbandingan performa keempat model ditunjukkan pada Gambar 2 dan Tabel 1.



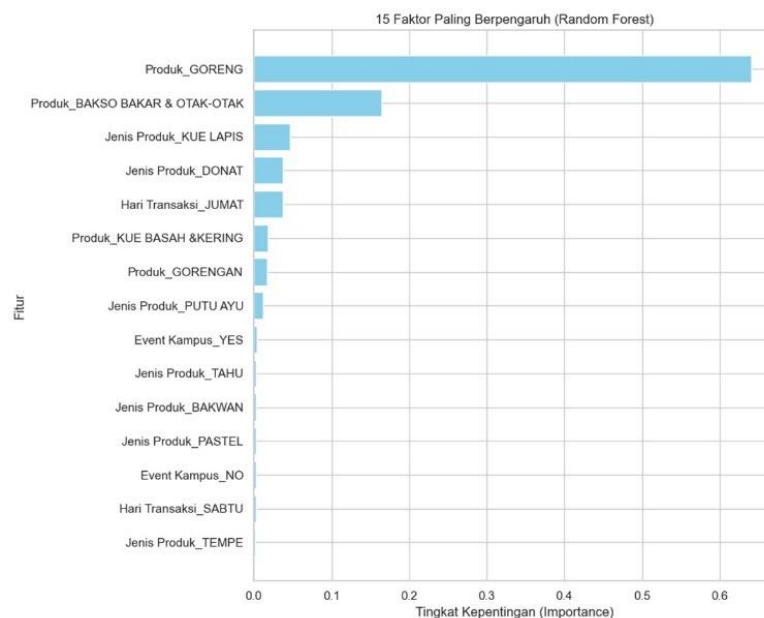
**Gambar 2.** Perbandingan Performa Model

**Tabel 1.** Perbandingan Evaluasi MAE

Algoritma	Hasil MAE
Linear Regression	0.8807
Random Forest	0.9395
Gradient Boosting	0.8872
XGBoost	0.9908

### 3.1.2 Faktor Paling Berpengaruh dalam Prediksi Penjualan

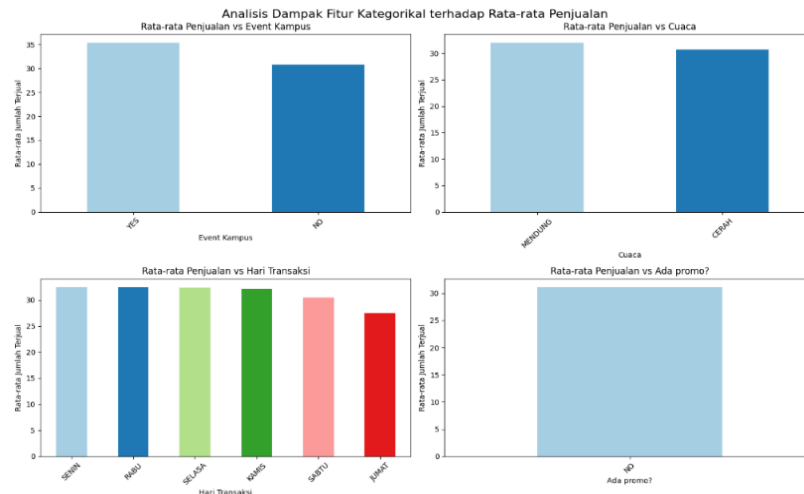
Penentuan variabel yang paling berpengaruh terhadap prediksi penjualan dilakukan melalui metode *feature importance* pada algoritma *Random Forest*. Metode ini digunakan untuk mengetahui seberapa besar kontribusi masing-masing variabel terhadap hasil prediksi yang dihasilkan model. Algoritma *Random Forest* dipilih karena mampu menilai tingkat kepentingan variabel secara otomatis melalui gabungan banyak pohon keputusan. Selain itu, metode ini juga efektif dalam menangani data dengan jumlah variabel yang cukup banyak serta cenderung memberikan hasil prediksi yang lebih stabil dibandingkan model pohon keputusan tunggal.

**Gambar 3.** Faktor Paling Berpengaruh

Gambar 3 menunjukkan bahwa fitur yang paling berpengaruh dalam memprediksi penjualan adalah *Produk\_GORENG* dengan tingkat kepentingan yang jauh lebih tinggi dibandingkan fitur lainnya. Faktor berikutnya adalah *Produk\_BAKSO BAKAR & OTAK-OTAK* yang juga memberikan kontribusi cukup besar. Selain itu, beberapa jenis produk lain seperti *KUE LAPIS*, *DONAT*, serta *Hari Transaksi\_JUMAT* turut memberikan kontribusi meskipun dengan tingkat kepentingan yang lebih kecil. Hasil ini menunjukkan bahwa jenis produk merupakan faktor dominan dalam menentukan permintaan snack, sementara faktor hari transaksi juga memiliki pengaruh namun tidak sebesar jenis produk.

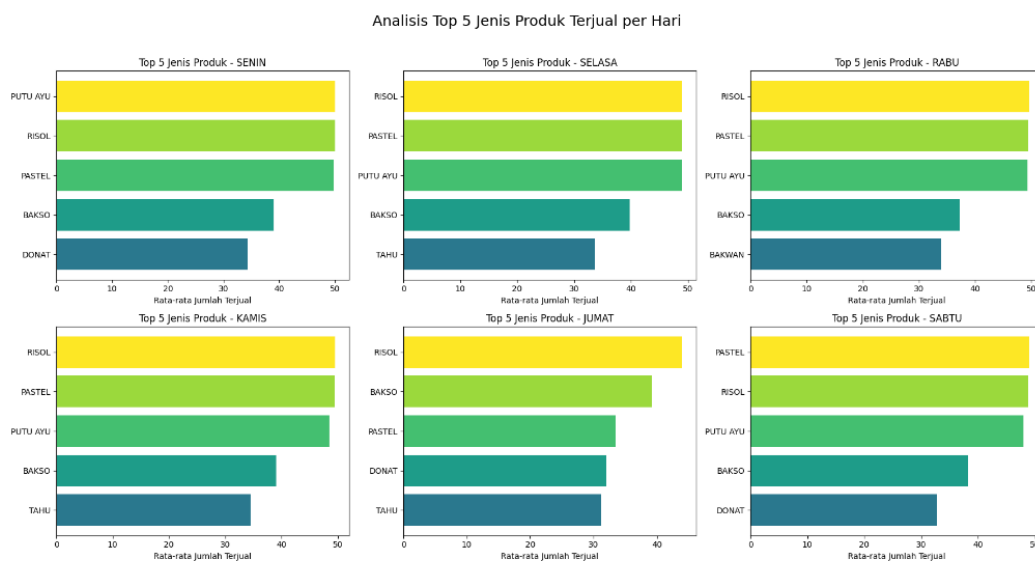
### 3.1.3 Hasil Model AI Preskriptif

Setelah mengembangkan model prediktif, tahap berikutnya adalah pengembangan model AI preskriptif menggunakan pendekatan *What-If Analysis* untuk memproyeksikan berbagai skenario yang dapat mempengaruhi penjualan snack. Skenario yang diuji meliputi kondisi normal dengan cuaca cerah tanpa adanya event maupun promo, kondisi ketika terdapat event kampus, kondisi kombinasi antara adanya event kampus dan promo, serta kondisi cuaca hujan tanpa adanya event atau promo. Melalui simulasi berbagai skenario tersebut, model preskriptif dapat memberikan rekomendasi optimalisasi strategi penjualan dan pengelolaan stok berdasarkan kondisi yang berbeda.



**Gambar 4.** Analisis Dampak Fitur Kategorikal Terhadap Rata-Rata Penjualan

Gambar 4 menunjukkan hasil analisis dampak fitur kategorikal terhadap rata-rata penjualan. Berdasarkan grafik tersebut, keberadaan event kampus menunjukkan peningkatan rata-rata penjualan dibandingkan kondisi tanpa event. Selain itu, faktor cuaca juga menunjukkan perbedaan rata-rata penjualan, meskipun tidak terlalu signifikan. Sementara itu, faktor hari transaksi menunjukkan variasi rata-rata penjualan pada setiap hari, di mana hari tertentu memiliki tingkat penjualan yang lebih tinggi dibandingkan hari lainnya. Sebaliknya, variabel promosi menunjukkan pengaruh yang relatif lebih kecil dibandingkan faktor event kampus dan hari transaksi. Hasil ini menunjukkan bahwa event kampus dan hari transaksi merupakan faktor yang lebih dominan dalam mempengaruhi penjualan snack dibandingkan faktor lainnya.

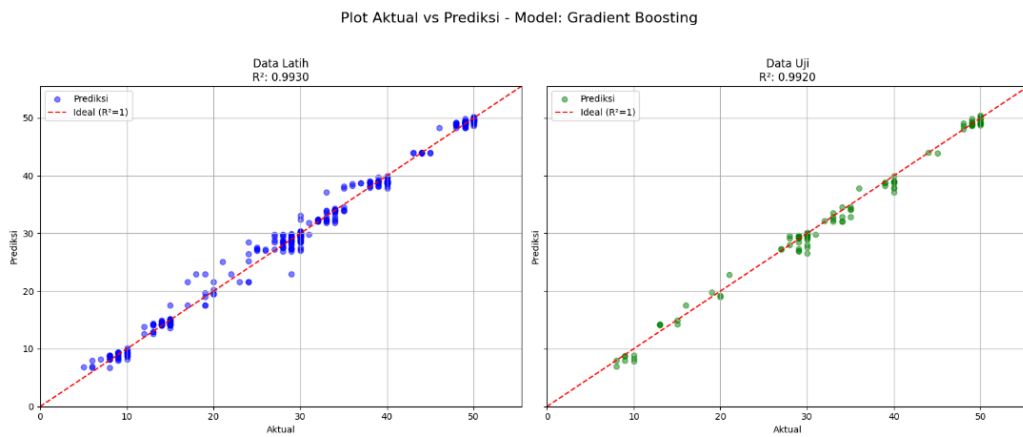


**Gambar 5.** Analisis Top 5 Jenis Produk Terjual per Hari

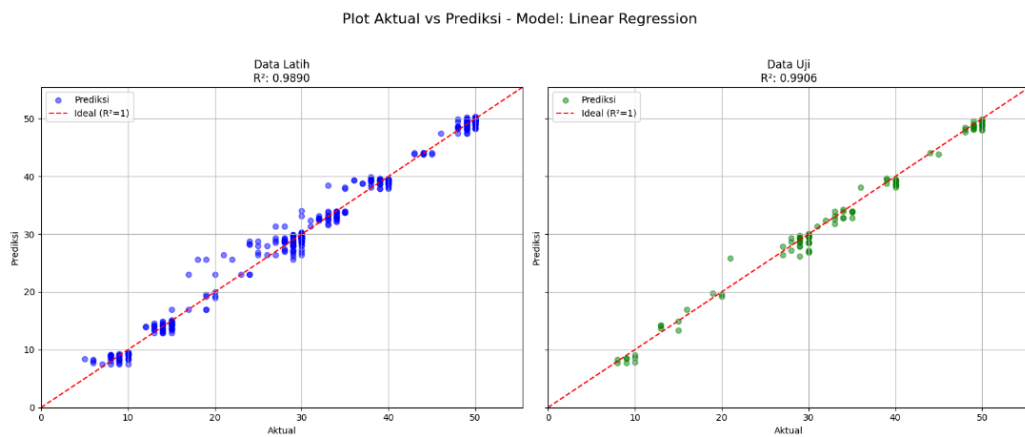
Gambar 5 menunjukkan hasil analisis Top 5 jenis produk terjual berdasarkan hari transaksi. Berdasarkan grafik tersebut, produk risol mendominasi penjualan pada hampir setiap hari dalam seminggu, diikuti oleh produk pastel dan putu ayu yang juga menunjukkan tingkat penjualan yang konsisten. Selain itu, produk seperti bakso dan donat muncul pada beberapa hari tertentu dengan tingkat penjualan yang cukup tinggi. Hasil ini menunjukkan bahwa preferensi mahasiswa terhadap jenis snack bervariasi berdasarkan hari transaksi. Temuan tersebut mengindikasikan bahwa strategi penjualan dapat disesuaikan dengan pola permintaan harian untuk mengoptimalkan penjualan snack. Dengan demikian, hasil analisis preskriptif tidak hanya digunakan untuk memprediksi penjualan, tetapi juga membantu menentukan prioritas produk dan strategi pengelolaan stok secara lebih optimal.

### 3.2 Perbandingan Model

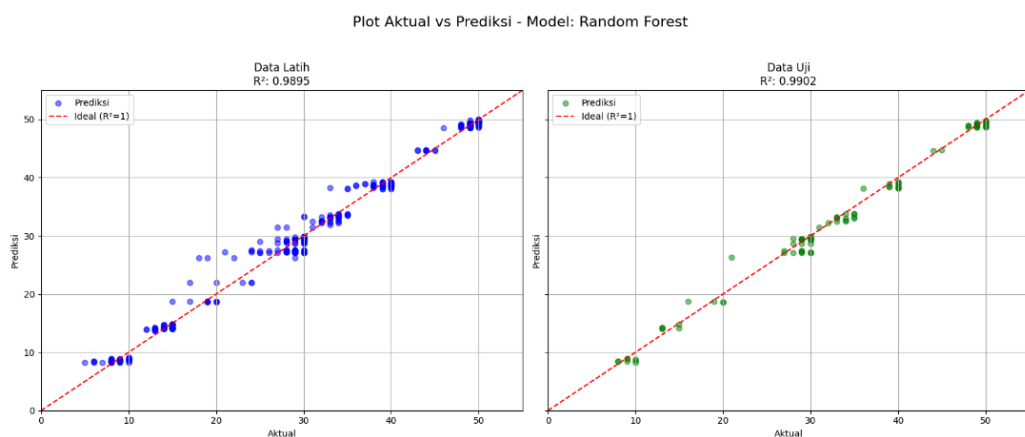
Untuk menilai kinerja model, dilakukan perbandingan hasil prediksi dari empat algoritma. Gambar 6, Gambar 7, dan Gambar 8 menampilkan hubungan antara nilai aktual dan nilai prediksi, baik pada data latih maupun data uji, untuk masing-masing model.



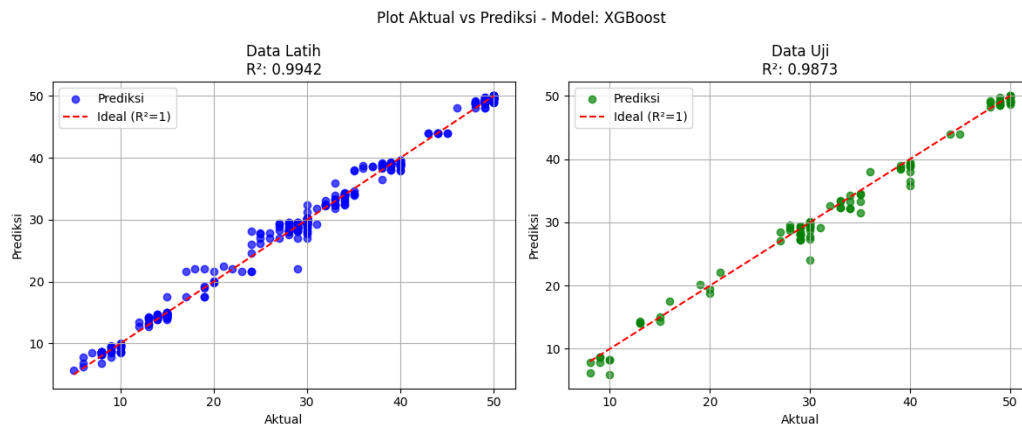
**Gambar 6.** Plot Aktual vs Prediksi Model *Gradient Boosting*



**Gambar 7.** Plot Aktual vs Prediksi Model *Linear Regression*



**Gambar 8.** Plot Aktual vs Prediksi Model *Random Forest*



**Gambar 9.** Plot Aktual vs Prediksi Model *XGBoost*

Pengujian terhadap empat model menunjukkan bahwa seluruh algoritma memiliki kemampuan yang sangat baik dalam memprediksi data penjualan snack. Hal ini terlihat dari nilai koefisien determinasi ( $R^2$ ) dan hasil *cross-validation* yang sama-sama berada di atas 0,98, sehingga sebagian besar variasi data penjualan dapat dijelaskan dengan baik oleh model. Model *Gradient Boosting* memberikan performa terbaik dengan nilai  $R^2$  sebesar 0,9930 pada data latih dan 0,9920 pada data uji, serta nilai rata-rata *cross-validation*  $R^2$  sebesar 0,9875. Hasil tersebut menunjukkan bahwa model memiliki tingkat akurasi dan konsistensi prediksi yang sangat baik terhadap data yang berbeda. Model *Linear Regression* juga menunjukkan performa yang kompetitif dengan nilai  $R^2$  sebesar 0,9890 pada data latih dan 0,9906 pada data uji, serta nilai *cross-validation*  $R^2$  sebesar 0,9876. Meskipun menggunakan pendekatan yang lebih sederhana dibandingkan model *ensemble*, model ini tetap mampu menghasilkan prediksi yang stabil dan akurat. Sementara itu, model *Random Forest* memperoleh nilai  $R^2$  sebesar 0,9895 pada data latih dan 0,9902 pada data uji, dengan nilai *cross-validation*  $R^2$  sebesar 0,9862. Hasil tersebut menunjukkan bahwa model masih memiliki kemampuan generalisasi yang baik meskipun performanya sedikit berada di bawah *Gradient Boosting* dan *Linear Regression*. Model *XGBoost* juga menghasilkan performa yang baik dengan nilai  $R^2$  sebesar 0,9942 pada data latih dan 0,9873 pada data uji, serta nilai rata-rata *cross-validation*  $R^2$  sebesar 0,9857. Walaupun performanya sedikit lebih rendah dibandingkan model lainnya pada data uji, *XGBoost* tetap menunjukkan kemampuan prediksi yang stabil terhadap data penjualan snack.

Secara keseluruhan, keempat model layak digunakan untuk memprediksi penjualan snack. Namun, berdasarkan hasil evaluasi yang diperoleh, *Gradient Boosting* menunjukkan performa terbaik dibandingkan model lainnya karena mampu memberikan kombinasi akurasi dan konsistensi prediksi yang paling optimal.

#### 4. Kesimpulan dan Saran

Hasil penelitian menunjukkan bahwa penerapan pendekatan prediktif dan preskriptif mampu mendukung pengelolaan penjualan snack di lingkungan kampus UIN Mahmud Yunus Batusangkar. Empat algoritma yang diuji, yaitu *Linear Regression*, *Random Forest*, *Gradient Boosting*, dan *XGBoost*, sama-sama menghasilkan tingkat akurasi prediksi yang tinggi. Berdasarkan hasil evaluasi menggunakan nilai  $R^2$ , MAE, dan *cross-validation*, model *Gradient Boosting* menunjukkan performa terbaik sehingga dinilai paling sesuai dalam memproyeksikan permintaan penjualan snack.

Penelitian ini juga menunjukkan bahwa pendekatan preskriptif melalui *What-If Analysis* dapat memberikan rekomendasi strategis bagi pengelola kantin. Variabel jenis produk, stok awal, hari transaksi, dan kegiatan kampus menjadi faktor yang paling memengaruhi perubahan penjualan. Beberapa produk seperti risol, pastel, dan putu ayu memiliki kecenderungan permintaan lebih tinggi pada hari tertentu, sehingga informasi tersebut dapat dimanfaatkan dalam pengaturan stok dan perencanaan produksi. Selain itu, aktivitas kampus terbukti berkontribusi terhadap peningkatan penjualan, terutama saat terdapat kegiatan akademik maupun organisasi mahasiswa. Sebaliknya, variabel promosi dan kondisi cuaca menunjukkan pengaruh yang relatif kecil dibandingkan variabel lainnya. Secara umum, hasil penelitian menegaskan bahwa analisis berbasis data dapat membantu pengelola kantin dalam menentukan strategi penjualan, mengelola persediaan, serta meningkatkan efektivitas pengambilan keputusan operasional.

Penelitian selanjutnya dapat dilakukan dengan periode pengumpulan data yang lebih panjang agar pola penjualan dapat dianalisis secara lebih komprehensif. Penambahan variabel seperti jumlah mahasiswa, jadwal perkuliahan, dan lokasi kantin juga berpotensi meningkatkan ketepatan prediksi. Selain itu, pendekatan preskriptif dapat dikembangkan melalui metode optimasi dan implementasi berbasis *dashboard* atau sistem informasi sehingga rekomendasi strategi penjualan dapat diperoleh secara *real-time*. Eksplorasi algoritma lain juga dapat dilakukan untuk memperluas penerapan model pada berbagai jenis usaha mikro di lingkungan kampus.

## REFERENSI

- [1] D. Puspasari and F. Farapti, "Hubungan Konsumsi Makanan Jajanan dengan Status Gizi pada Mahasiswa," *Media Gizi Indones.*, vol. 15, no. 1, p. 45, 2020.
- [2] W. Wahyudi, A. Nurfadilah, C. Fransisca, K. Fahrezi, M. F. Zulkadri, and J. Manik, "Pola Konsumsi Snack dan Minuman Kemasan pada Mahasiswa Kesehatan dan Non-Kesehatan: Studi Kasus UIN Sumatera Utara," *J. Syifa Sci. Clin. Res.*, vol. 6, no. 3, pp. 263–273, 2024, doi: 10.37311/jsscr.v6i3.28867.
- [3] F. A. Hasibuan, "Pengaruh Halal Awareness Quality dan Price Terhadap Impulse Buying Makanan Instan di Kalangan Mahasiswa," Universitas Islam Negeri Syekh Alihasan Ahmad Addary, 2021.
- [4] C. Heins, "Artificial intelligence in retail – a systematic literature review," *Emerald Publ.*, vol. 25, no. 2, 2023.
- [5] David Iyanuoluwa Ajiga, Ndubuisi Leonard Ndubuisi, Onyeka Franca Asuzu, Oluwaseyi Rita Owolabi, Tula Sunday Tubokirifuruar, and Rhoda Adura Adeleye, "AI-Driven Predictive Analytics in Retail: a Review of Emerging Trends and Customer Engagement Strategies," *Int. J. Manag. Entrep. Res.*, vol. 6, no. 2, pp. 307–321, 2024, doi: 10.51594/ijmer.v6i2.772.
- [6] P. Prasad and J. Mathew, "AI for Predictive Analytics in Retail: Enhancing Inventory Management and Customer Engagement," *Int. J. Sci. Res. Eng. Trends*, vol. 11, no. 2, pp. 2056–2060, 2025, doi: 10.61137/ijrsret.vol.11.issue2.393.
- [7] S. Ito and R. Fujimaki, "Optimization beyond prediction: Prescriptive price optimization," *Proc. ACM SIGKDD Int. Conf. Knowl. Discov. Data Min.*, vol. Part F1296, pp. 1833–1841, 2017, doi: 10.1145/3097983.3098188.
- [8] H. Wijaya, D. Pramana Hostiadi, and E. Triandini, "Meningkatkan Prediksi Penjualan Retail Xyz Dengan Teknik Optimasi Random Search Pada Model Xgboost," in *Prosiding Seminar Hasil Penelitian Informatika dan Komputer 2024*, Bali: SPINTER, 2024, p. 2024.
- [9] M. M. Yuniar and R. Ambarwati, "Prediction Analysis of Retail Store Sales Level using Neural Network Algorithm Method based on Customer Segments [ Analisis Prediksi Tingkat Penjualan Toko Ritel menggunakan Metode Algoritma Neural Network berbasis Segmen Pelanggan ]," pp. 1–11, 2023.
- [10] N. Hidayah, ; Agus, R. ; Puspo, D. Dirgantari, ; Lili, and A. Wibowo, "AI-Based Decision-Making on Business Strategy: A Review," *Int. J. Soc. Sci. Res. Rev.*, vol. 6, no. 11, pp. 26–36, 2023.
- [11] A. A. Chaudhry, C. P. Heilman, and P. B. Seetharaman, "Measuring the effects of customized targeted promotions on retail profit using prescriptive analytics," *J. Revenue Pricing Manag.*, vol. 23, no. 2, 2024.
- [12] E. Sari, S. Said, and D. Febrianti, "Faktor Lingkungan yang Berhubungan dengan Perilaku Pemilihan Jajanan Siswa SMPN 5 Panca Rijang Kabupaten Sidenreng Rappang," *MANUNJU Malhayati Nurs. J.*, vol. 7, no. 8, pp. 3745–3758, 2021.
- [13] A. T. Widiyatmoko, S. Butsianto, and A. Nugroho, "Penerapan Machine Learning untuk Prediksi Kenaikan Harga Beras Premium Menggunakan Algoritma Regresi Linier," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 5, no. 3, pp. 1125–1132, 2025, [Online]. Available: <https://journal.irpi.or.id/index.php/malcom/article/view/2123>
- [14] R. D. Sanjaya and R. Meilisa, "Analisis Prediksi Profit Pada Toko Eska Dengan Metode Regresi Linear," *JATISI (Jurnal Tek. Inform. dan Sist. Informasi)*, vol. 12, no. 3, 2025, doi: 10.35957/jatisi.v12i3.12563.
- [15] M. Schonlau and R. Y. Zou, "The Random Forest Algorithm for Statistical Learning The Random Forest algorithm," pp. 1–23, 2020.
- [16] S. N. N. Ikhda, N. A. Ramdhan, and A. Premana, "Penerapan Algoritma Random Forest Prediksi Penyakit Paru-Paru," *J. Teknol. Inf. dan Komput.*, vol. 9, no. 2, pp. 145–153, 2023.
- [17] R. Dahlia and C. I. Agustyaningrum, "Perbandingan Gradient Boosting dan Light Gradient Boosting Dalam Melakukan Klasifikasi Rumah Sewa," *J. Nas. Komputasi dan Teknol. Inf.*, vol. 5, no. 6, pp. 1016–1020, 2022, doi: 10.32672/jnkti.v5i6.5460.
- [18] Rizka Dahlia, Lady Agustin Fitriana, and Syarah Seimahuira, "Analisis Algoritma Gradient Boosting Dalam Pengaruh Masyarakat Memilih Rumah Sewa," *J. Manaj. Inform. dan Sist. Inf.*, vol. 8, no. 1, pp. 35–44, 2025, doi: 10.36595/misi.v8i1.1356.
- [19] S. E. H. Yulianti, O. Soesanto, and Y. Sukmawaty, "Penerapan Metode Extreme Gradient Boosting ( XGBOOST ) pada Klasifikasi Nasabah Kartu Kredit," *J. Math. Theory Appl.*, vol. 4, no. 1, pp. 21–26, 2022.
- [20] A. A. Saputra, B. N. Sari, and C. Rozikin, "Penerapan Algoritma Extreme Gradient Boosting (Xgboost) Untuk Analisis Risiko Kredit," *J. Ilm. Wahana Pendidik.*, vol. 10, no. April, pp. 27–36, 2024.
- [21] J. F. H. JR, W. C. BLack, B. J. Babin, and R. E. Anderson, "Multivariate Data Analysis.pdf," 2010, Prentice Hall.

- [22] D. N. Gujarati, *Dasar Dasar Ekonometrika*. Jakarta: Salemba Empat, 2012.
- [23] A. Géron, *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow*, 2nd Editio. Sebastopol: O'Reilly Media, 2019.