JURNAL ILMIAH SISTEM INFORMASI (JUSI)
VOL 5, No. 1, January 2026, pp. 96 - 106
p-ISSN : 2803-1507 (media cetak) | e-ISSN : 2803-1531 (media online)
Link Publikasi: https://ejurnal.provisi.ac.id/index.php/JUISI/issue/view/169

Prediction of Unselling Menu Items for Bundling and Promotion Strategies in Cafés Using Decision Tree Algorithm

Fheisyach Artianshal Karubun*[1], Didaktus Baptista Kluman[2], Rahul Febriansyah[3], Putra Emanuel Pali[4], Aldo Yunus Lazarus Satia[5], Heru Sutejo[6]
[1,2,3,4,5,6] Sistem Informasi, Universitas Sepuluh Nopember Papua
Jl. Ardipura Raya No.22B, 99222, Distrik Jayapura Selatan, Kota Jayapura, Papua, Indonesia
e-mail: fhesya09@gmail.com*[1], dikybstistha@gmail.com[2], rahulgenstop12@gmail.com[3], putrajr431@gmail.com[4], aldosatia888@gmail.com[5], heru.sutejo01@gmail.com[6]

ARTICLE INFO

Article History:

Received: 12-10-2025
Revised: 07-11-2025
Accepted: 20-12-2025
Published: 21-01-2026

ABSTRACT

The café industry in Indonesia faces challenges in managing unselling menu items, which can lead to losses due to raw material accumulation and operational inefficiency. This study aims to predict unselling menu items using the Decision Tree algorithm as a basis for developing effective bundling and promotion strategies in cafés. The research employs the Knowledge Discovery in Database (KDD) approach, encompassing data selection, preprocessing, transformation, data mining, and pattern evaluation stages. The research dataset consists of 500 café transaction records divided into 80% training data (400 records) and 20% testing data (100 records). Variables used include promotion type, menu name, price, price category, weather, and selling label. The results show that the Decision Tree model can predict unselling menu items with 84% accuracy, 87.50% precision for the Selling class, and 77.78% for the Non-Selling class. Decision tree analysis identifies that promotion type is the most dominant factor in determining menu popularity, followed by menu name, price, and weather conditions. Buy 1 get 1 promotions prove most effective in consistently increasing sales, while menus without promotions tend to be unselling. Menus such as Coconut Steezy and Steezy Coffee demonstrate stable performance even with light discounts. These findings provide strategic recommendations for café managers to optimize promotions, reduce raw material waste, and increase profitability through a data-driven approach that can be practically implemented.

Keywords: *Decision Tree, Data Mining, Menu Prediction, Bundling Strategy, Café.*

Abstrak

Industri *café* di Indonesia menghadapi tantangan dalam mengelola menu yang tidak laris, yang dapat menimbulkan kerugian akibat penumpukan bahan baku dan inefisiensi operasional. Penelitian ini bertujuan untuk memprediksi menu tidak laris menggunakan algoritma Decision Tree sebagai dasar penyusunan strategi *bundling* dan promosi yang efektif di *café*. Metode penelitian menggunakan pendekatan *Knowledge Discovery in Database (KDD)* yang mencakup tahapan seleksi data, pra-pemrosesan, transformasi, *data mining*, dan evaluasi pola. *Dataset* penelitian terdiri dari 500 record transaksi *café* yang dibagi menjadi 80%

DOI: https://doi.org/10.51903/qc1w9009

p-ISSN : 2803-1507 e-ISSN : 2803-1531

data latih (400 record) dan 20% data uji (100 record). Variabel yang digunakan meliputi jenis promo, nama menu, harga, kategori harga, cuaca, dan label kelarisan. Hasil penelitian menunjukkan bahwa model Decision Tree mampu memprediksi menu tidak laris dengan akurasi 84%, *precision* 87,50% untuk kelas Laris, dan 77,78% untuk kelas Tidak Laris. Analisis pohon keputusan mengidentifikasi bahwa jenis promo merupakan faktor paling dominan dalam menentukan kelarisan menu, diikuti oleh nama menu, harga, dan kondisi cuaca. Promo *buy 1 get 1* terbukti paling efektif meningkatkan penjualan secara konsisten, sementara menu tanpa promo cenderung tidak laris. Menu seperti Coconut Steezy dan Steezy Coffee menunjukkan performa stabil bahkan dengan diskon ringan. Temuan ini memberikan rekomendasi strategis bagi pengelola *café* dalam mengoptimalkan promosi, mengurangi pemborosan bahan baku, dan meningkatkan profitabilitas melalui pendekatan berbasis data yang dapat diimplementasikan secara praktis.

Kata Kunci: *Decision Tree*, *Data Mining*, *Prediksi Menu*, *Strategi Bundling*, *Café*, *KDD.*

1. PENDAHULUAN

Industri *café* di Indonesia berkembang pesat dalam beberapa tahun terakhir, ditandai dengan meningkatnya jumlah gerai dan persaingan yang semakin ketat. Kondisi ini menuntut pengelola *café* untuk menerapkan strategi berbasis data dalam mengelola menu dan merancang promosi yang efektif. Pemanfaatan teknik *data mining* dan *machine learning* menjadi pendekatan yang semakin populer untuk memahami pola penjualan dan preferensi konsumen. Beberapa penelitian menunjukkan bahwa analisis transaksi *café* dapat memberikan wawasan mengenai pola pembelian, evaluasi menu, dan perilaku pelanggan yang bermanfaat dalam pengambilan keputusan strategis [1], [2].

Salah satu tantangan utama dalam operasional *café* adalah adanya menu yang tidak laku atau *low-selling*, yang berpotensi menimbulkan kerugian akibat bahan baku menumpuk dan tidak terpakai. Identifikasi menu tidak laris secara akurat dapat membantu *café* menekan biaya operasional serta meningkatkan efektivitas promosi. Berbagai penelitian telah memanfaatkan algoritma klasifikasi untuk memprediksi permintaan produk, termasuk sektor makanan dan minuman, guna mengoptimalkan stok dan meminimalisasi *food waste* [3], [4]. Kemampuan model prediktif untuk memberikan informasi dini mengenai penjualan menu menjadi landasan penting dalam menentukan strategi pemasaran dan paket *bundling* yang tepat sasaran.

Algoritma *Decision Tree*, termasuk varian *C4.5*, *CART*, dan *C5.0*, merupakan salah satu algoritma yang banyak digunakan pada penelitian klasifikasi di sektor kuliner karena menghasilkan pola atau aturan keputusan (*decision rules*) yang mudah dipahami oleh manajemen *café*. Penelitian di Kopi Krintji menunjukkan bahwa *Decision Tree* dapat memprediksi penjualan makanan dan minuman secara akurat serta membantu mengurangi kelebihan stok bahan baku [5]. Sementara itu, penelitian lain menguji performa *Decision Tree* dalam klasifikasi menu dan preferensi konsumen pada restoran cepat saji serta *café*, dan hasilnya menunjukkan performa yang stabil dengan interpretasi model yang baik dibandingkan metode lain seperti *Naïve Bayes* maupun *Random Forest* [6], [7], [8]. Algoritma *Decision Tree* juga memungkinkan visualisasi struktur keputusan yang membantu pengelola café memahami hubungan antara variabel penjualan, jenis menu, dan tingkat permintaan konsumen secara lebih jelas.

Selain prediksi menu tidak laris, strategi *bundling* merupakan pendekatan promosi yang efektif untuk meningkatkan penjualan item tertentu dengan cara menggabungkan menu yang kurang laku dengan menu populer. Analisis pola transaksi menggunakan algoritma *frequent pattern mining* seperti *FP-Growth* telah berhasil memberikan rekomendasi paket menu *bundling* di beberapa *café* di Indonesia, seperti pada *Café SZ Point* dan TERÉ *Café* and Bar, yang dapat meningkatkan *engagement* pelanggan serta penjualan keseluruhan [9], [10], [11]. Namun demikian, teknik asosiasi tersebut tidak mampu memprediksi menu mana yang berpotensi tidak laku. Karena itu, integrasi metode klasifikasi (*Decision Tree*) dan pola asosiasi (*FP-Growth*) menjadi strategi komplementer yang ideal dalam sistem rekomendasi *bundling* [12], [13].

Kajian internasional juga memperkuat manfaat *Decision Tree* dalam memprediksi perilaku konsumen, permintaan makanan, serta perencanaan promosi. Beberapa studi menunjukkan bahwa model berbasis tree dapat digunakan untuk memprediksi aliran pengunjung restoran, perilaku pemesanan makanan daring, serta keputusan konsumen dalam memilih produk makanan tertentu [14], [15]. Bahkan dalam konteks produksi makanan skala besar, *Decision Tree* dikombinasikan dengan metode prediksi lain dilaporkan meningkatkan akurasi perencanaan permintaan harian hingga lebih dari 20% [16]. Pendekatan ini dinilai relevan karena mampu mengakomodasi data historis penjualan dengan karakteristik yang kompleks dan bervariasi antar periode waktu.

p-ISSN : 2803-1507 e-ISSN : 2803-1531

Berdasarkan uraian tersebut, penelitian ini memiliki tiga tujuan utama: (1) membangun model prediksi menu tidak laris menggunakan algoritma *Decision Tree* dengan akurasi optimal, (2) mengidentifikasi faktor-faktor dominan yang memengaruhi kelarisan menu *café* berdasarkan aturan pohon keputusan, dan (3) merumuskan rekomendasi strategi *bundling* dan promosi berbasis pola data yang ditemukan. Pendekatan ini diharapkan tidak hanya membantu meningkatkan penjualan menu *low-selling*, tetapi juga mendukung manajemen dalam mengoptimalkan persediaan, mengurangi pemborosan, dan meningkatkan laba *café* secara keseluruhan. Model prediksi yang dibangun dapat digunakan sebagai alat bantu analisis bagi manajemen café dalam mengevaluasi performa setiap menu secara berkala. Informasi yang dihasilkan dari aturan pohon keputusan memberikan gambaran mengenai atribut yang berkontribusi terhadap rendahnya tingkat penjualan suatu menu.

Berdasarkan uraian tersebut, penelitian ini berfokus pada prediksi menu tidak laris di *café* menggunakan algoritma *Decision Tree* sebagai dasar untuk menyusun strategi *bundling* dan promosi yang lebih efektif. Pendekatan ini diharapkan tidak hanya membantu meningkatkan penjualan menu *low-selling*, tetapi juga mendukung manajemen dalam mengoptimalkan persediaan, mengurangi pemborosan, dan meningkatkan laba *café* secara keseluruhan. Penggunaan algoritma *Decision Tree* memungkinkan proses analisis dilakukan secara sistematis berdasarkan data transaksi yang tersedia. Hasil prediksi dan rekomendasi yang dihasilkan dapat menjadi dasar pertimbangan dalam perencanaan promosi dan pengelolaan menu café.

2. TINJAUAN PUSTAKA

Permintaan menu dalam industri kuliner sangat dipengaruhi oleh waktu penjualan, harga, tren konsumen, serta aktivitas promosi yang berlangsung sehingga *café* memerlukan sistem prediksi yang mampu mengidentifikasi menu berisiko tidak laris. Pendekatan berbasis *machine learning*, khususnya algoritma *decision tree*, telah terbukti memberikan performa prediktif yang baik dalam sektor makanan [17], [18], [19]. Penelitian menunjukkan bahwa model prediksi dapat membantu mengurangi pemborosan dan mengoptimalkan proses produksi makanan melalui estimasi permintaan jangka pendek yang lebih akurat [20]. Penerapan kecerdasan buatan dalam *F&B* juga terbukti meningkatkan akurasi peramalan penjualan dengan mempertimbangkan faktor-faktor seperti promosi, cuaca, serta pola perilaku pelanggan [21].

Teknik prediksi penjualan makanan juga membutuhkan integrasi data transaksi *point-of-sale* dengan variabel pemasaran agar model mampu mencerminkan kondisi operasional secara lebih realistis [22]. Selain peramalan umum, penelitian lain memperlihatkan bahwa decision tree dapat memprediksi kemungkinan penurunan permintaan untuk menu tertentu sehingga memungkinkan manajemen melakukan intervensi preventif sebelum kerugian terjadi [23]. Pendekatan seperti ini sangat relevan bagi *café* yang berfokus pada pengelolaan menu tidak laris dan peningkatan efektivitas promosi. Pemodelan berbasis *decision tree* juga memberikan kemudahan dalam menelusuri pengaruh setiap variabel terhadap hasil prediksi sehingga hasil analisis dapat dipahami oleh pengelola café tanpa latar belakang teknis yang mendalam.

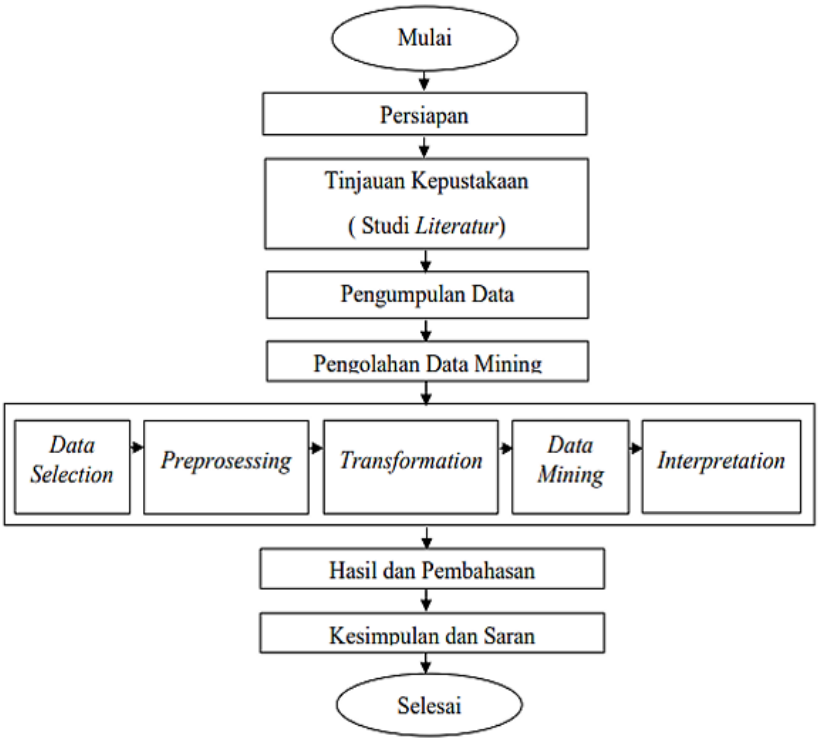
Model *machine learning* juga dapat digunakan untuk mengidentifikasi menu dengan kontribusi pendapatan rendah sebagai dasar perumusan strategi pemasaran [24]. Dalam bidang kuliner dan gastronomi, *decision tree* terbukti efektif untuk menganalisis preferensi makanan dan mengelompokkan jenis menu berdasarkan minat serta kecenderungan pelanggan. Penelitian terbaru menunjukkan bahwa algoritma ini mampu mengungkap preferensi makanan etis dan berkelanjutan di kalangan mahasiswa kuliner, serta mengelompokkan pilihan makanan secara akurat menggunakan pola data yang terstruktur [14]. Meskipun konteksnya bukan *café* komersial, temuan ini menunjukkan bahwa *decision tree* sangat efektif dalam mengidentifikasi kelompok menu berdasarkan karakteristik pemilihan, termasuk menu yang kurang diminati.

Meskipun berbagai penelitian telah menunjukkan efektivitas *Decision Tree* dalam prediksi penjualan makanan dan minuman, serta penerapan teknik asosiasi seperti *FP-Growth* untuk rekomendasi *bundling*, kesenjangan penelitian (*research gap*) masih terlihat jelas dalam tiga aspek utama. **Pertama**, belum banyak studi yang secara langsung mengintegrasikan kemampuan prediksi menu tidak laris dengan penyusunan strategi *bundling* yang konkret dan implementatif. **Kedua**, mayoritas penelitian sebelumnya hanya berfokus pada analisis deskriptif atau rekomendasi paket tanpa mempertimbangkan faktor prediktif yang mendasari keputusan tersebut. **Ketiga**, konteks penelitian di *café* lokal Indonesia yang mempertimbangkan variabel promosi, harga, dan kondisi cuaca secara simultan masih terbatas. Oleh karena itu, penelitian ini berupaya mengisi kesenjangan tersebut dengan menghasilkan model prediktif yang tidak hanya akurat, tetapi juga menghasilkan aturan keputusan (*decision rules*) yang dapat langsung diterjemahkan menjadi rekomendasi *bundling* dan strategi promosi yang mudah diimplementasikan oleh pengelola *café*.

p-ISSN : 2803-1507 e-ISSN : 2803-1531

3. METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan algoritma *Decision Tree Classification* untuk memprediksi menu tidak laris pada *café*. *Decision Tree* dipilih karena mampu menghasilkan aturan keputusan yang jelas dan mudah diinterpretasikan, serta efektif dalam mengidentifikasi pola pembelian makanan berdasarkan atribut seperti harga, kategori menu, jumlah terjual, dan waktu transaksi [9]. Pendekatan kuantitatif memungkinkan analisis dilakukan secara objektif berdasarkan data transaksi penjualan yang tercatat dalam sistem café. Data numerik dan kategorikal yang digunakan memberikan gambaran terukur mengenai tingkat kelarisan setiap menu dalam periode tertentu.



Gambar 1. Tahapan Penelitian

Algoritma *Decision Tree* yang digunakan dalam penelitian ini adalah *C4.5*, yang melakukan pemilihan atribut berdasarkan nilai *Information Gain Ratio*. Algoritma ini dipilih karena mampu menangani data kategorikal, menghasilkan struktur pohon yang mudah diinterpretasikan, serta banyak digunakan dalam penelitian klasifikasi pada sektor makanan dan minuman. Pemilihan algoritma C4.5 juga mempertimbangkan kemampuannya dalam menangani data yang mengandung nilai hilang dan variasi atribut yang kompleks. Struktur pohon keputusan yang dihasilkan memungkinkan penelusuran faktor-faktor yang berpengaruh terhadap penjualan menu secara lebih rinci.

Secara teknis, algoritma ini bekerja dengan membagi *dataset* menjadi subset yang lebih homogen menggunakan metrik *Information Gain* atau *Gini Impurity*, sehingga atribut terbaik dapat dipilih untuk memisahkan menu laris dan tidak laris. Pendekatan ini terbukti akurat dalam memetakan pola konsumsi makanan berdasarkan data historis [25]. Proses pembagian data dilakukan secara bertahap hingga diperoleh node akhir yang merepresentasikan klasifikasi menu. Setiap percabangan pohon menunjukkan hubungan antara atribut tertentu dengan tingkat kelarisan menu.

Model dilatih menggunakan teknik *train-test split*, kemudian dievaluasi menggunakan metrik akurasi, *precision*, dan *recall* untuk memastikan kemampuan klasifikasi yang optimal. Evaluasi ini mengikuti praktik penelitian sebelumnya yang mengimplementasikan *Decision Tree* dalam prediksi permintaan makanan [14]. Hasil model selanjutnya digunakan sebagai dasar dalam penyusunan strategi *bundling* dan promosi *café*. Penggunaan beberapa metrik evaluasi memungkinkan penilaian performa model dilakukan secara lebih komprehensif terhadap hasil klasifikasi yang dihasilkan.

p-ISSN : 2803-1507 e-ISSN : 2803-1531

Proses analisis data dalam penelitian ini mengikuti kerangka *Knowledge Discovery in Database (KDD)* agar keseluruhan proses pengolahan data berlangsung sistematis dan terstandar. Tahapan KDD terdiri dari seleksi data, pra-pemrosesan, transformasi, *data mining*, dan evaluasi pola. Setiap tahapan memiliki fungsi yang saling berkaitan dalam menghasilkan informasi yang relevan dari data transaksi café. Untuk memperjelas alur analisis yang dilakukan, rangkaian proses KDD yang meliputi seleksi data, pra-pemrosesan, transformasi, *data mining*, dan evaluasi pola divisualisasikan pada Gambar 1.

Proses analisis data dalam penelitian ini mengacu pada kerangka *Knowledge Discovery in Database* (KDD) yang digunakan untuk memastikan tahapan pengolahan data dilakukan secara sistematis dan terstruktur. Setiap tahapan dalam kerangka KDD memiliki peran yang saling berkaitan dalam menghasilkan informasi yang relevan dari data transaksi penjualan café. Kerangka ini membantu peneliti dalam mengelola data mentah hingga menjadi pengetahuan yang dapat dianalisis menggunakan metode *machine learning*. Adapun rincian tahapan KDD yang digunakan dalam penelitian ini adalah sebagai berikut:

3.1. *Seleksi Data*

Data transaksi *café* dipilih berdasarkan variabel yang relevan untuk prediksi, seperti Label (Laris/Tidak Laris), Harga, Alasan Pilih, Nama Menu, Jenis Menu, Usia pembeli, Waktu Pembelian, Cuaca, dan Rekomendasi Promo. Variabel-variabel ini dipilih karena memiliki pengaruh signifikan terhadap pola penjualan menu. Pemilihan variabel dilakukan dengan mempertimbangkan ketersediaan data historis serta keterkaitannya dengan perilaku pembelian pelanggan. Setiap atribut merepresentasikan aspek internal maupun eksternal yang dapat memengaruhi tingkat kelarisan menu di café.

3.2. *Pra-pemrosesan (Preprocessing)*

Dataset dibersihkan dari duplikasi, kesalahan format, dan *missing values* untuk memastikan kualitas data yang akan diproses lebih lanjut. Proses pembersihan data dilakukan untuk mengurangi potensi bias yang dapat memengaruhi hasil analisis. Kesalahan penulisan dan inkonsistensi data diperbaiki agar setiap atribut memiliki format yang seragam. Tahapan ini bertujuan meningkatkan keandalan data sebelum masuk ke tahap pemodelan.

3.3. *Transformasi Data*

Proses ini mencakup *encoding*, normalisasi, serta *feature engineering* seperti pengelompokan hari (*weekday/weekend*) atau kelas harga, agar pola lebih mudah dikenali oleh model *Decision Tree*. Transformasi data dilakukan untuk menyesuaikan format data dengan kebutuhan algoritma klasifikasi. Proses *encoding* digunakan untuk mengubah data kategorikal menjadi bentuk numerik. Normalisasi diterapkan agar skala data antaratribut menjadi seimbang dan tidak mendominasi proses pembentukan pohon keputusan.

3.4. *Data Mining (Decision Tree)*

Algoritma *Decision Tree* diterapkan untuk membangun model klasifikasi menu terfavorit berdasarkan pola historis transaksi. Pada tahap ini, model dilatih untuk mempelajari hubungan antaratribut dan menghasilkan aturan keputusan. Proses pelatihan model dilakukan menggunakan data hasil transformasi yang telah disiapkan sebelumnya. Struktur pohon keputusan yang terbentuk merepresentasikan jalur pengambilan keputusan berdasarkan kombinasi atribut penjualan menu.

3.5. *Evaluasi Pola*

Model yang dihasilkan dievaluasi menggunakan akurasi dan *confusion matrix* guna memastikan kualitas prediksi dan konsistensi performanya. Evaluasi dilakukan untuk mengukur kemampuan model dalam mengklasifikasikan menu laris dan tidak laris secara tepat. *Confusion matrix* digunakan untuk melihat distribusi hasil prediksi benar dan salah pada setiap kelas. Analisis hasil evaluasi memberikan gambaran mengenai tingkat kesalahan klasifikasi yang terjadi.

4. HASIL DAN PEMBAHASAN

4.1. *Dataset Penelitian*

Dataset yang digunakan dalam penelitian ini berasal dari data transaksi penjualan café yang telah dikumpulkan dan disusun secara terstruktur. Data tersebut mencakup berbagai atribut yang relevan dengan prediksi kelarisan menu, seperti harga, jenis menu, waktu pembelian, dan karakteristik pelanggan. Penyajian

p-ISSN : 2803-1507 e-ISSN : 2803-1531

sebagian data diperlukan untuk memberikan gambaran awal mengenai struktur dan isi dataset yang digunakan dalam proses analisis. Contoh tampilan dataset penelitian disajikan pada Gambar 2.

Row N...	Label	Tanggal	Harga	Alasan Pilih	Nama Menu	Jenis Menu	Usia	Waktu Pembelian	Cuaca	Jenis Promo
1	Laris	Jan 3, 2024	Low Budget	Rasa	Coconut Steezy	Signature Coffee	Dewasa	Malam	Cerah	buy 1 get 1
2	Laris	Jan 8, 2024	High Budget	Promo	Matcha	Non Coffee	Dewasa	Sore	Hujan	diskon 10%
3	Laris	Jan 28, 2024	High Budget	Rasa	Steezy Coffee	Signature Coffee	Dewasa	Siang	Cerah	Tidak ada promo
4	Laris	Jan 19, 2024	High Budget	Rasa	Matcha	Non Coffee	Mahasiswa	Siang	Cerah	buy 1 get 1
5	Laris	Jan 13, 2024	Low Budget	Kebiasaan	Coconut Steezy	Signature Coffee	Remaja	Pagi	Cerah	diskon 10%
6	Tidak Laris	Jan 26, 2024	High Budget	Rasa	Matcha	Non Coffee	Dewasa	Sore	Cerah	Tidak ada promo
7	Laris	Jan 27, 2024	High Budget	Rasa	Coconut Steezy	Signature Coffee	Dewasa	Pagi	Hujan	buy 1 get 1
8	Tidak Laris	Jan 8, 2024	High Budget	Rasa	Americano	Classic Coffee	Dewasa	Sore	Hujan	diskon 10%
9	Tidak Laris	Jan 15, 2024	High Budget	Rekomendasi	Coconut Steezy	Signature Coffee	Remaja	Sore	Hujan	Tidak ada promo
10	Laris	Jan 19, 2024	High Budget	Promo	Americano	Classic Coffee	Remaja	Siang	Cerah	buy 1 get 1
11	Laris	Jan 25, 2024	High Budget	Rasa	Coconut Steezy	Signature Coffee	Mahasiswa	Siang	Cerah	diskon 10%
12	Tidak Laris	Jan 4, 2024	Low Budget	Rasa	Coconut Steezy	Signature Coffee	Mahasiswa	Sore	Hujan	Tidak ada promo
13	Laris	Jan 5, 2024	Low Budget	Rasa	Steezy Coffee	Signature Coffee	Dewasa	Siang	Hujan	buy 1 get 1
14	Laris	Jan 5, 2024	High Budget	Promo	Coconut Steezy	Signature Coffee	Dewasa	Sore	Hujan	diskon 10%

Gambar 2. Dataset Penelitian

Gambar 1 hanya menampilkan 14 baris pertama sebagai sampel representatif untuk memberikan gambaran struktur dan isi *dataset* secara keseluruhan. Dengan total 500 data yang sudah terstruktur, pembagian yang paling ideal adalah menggunakan rasio 80:20, sehingga 400 data digunakan sebagai *training* untuk melatih model dan 100 data digunakan sebagai *testing* untuk mengevaluasi akurasi model secara objektif. Pembagian ini memberikan keseimbangan antara jumlah data belajar dan data uji sehingga hasil prediksi menjadi lebih stabil dan tidak bias. Informasi ini kemudian digunakan dalam proses KDD dan pelatihan model *Decision Tree* pada tahap *data mining*.

4.2. *Evaluasi Akurasi Model*

Evaluasi akurasi model dilakukan untuk mengetahui sejauh mana kemampuan model *Decision Tree* dalam mengklasifikasikan menu laris dan tidak laris. Proses evaluasi ini menggunakan pendekatan berbasis matriks evaluasi untuk menggambarkan hasil prediksi secara rinci. Hasil evaluasi akurasi model divisualisasikan dalam bentuk *confusion matrix*. Visualisasi hasil evaluasi akurasi model ditunjukkan pada Gambar 3.

accuracy: 84.00%

	true Laris	true Tidak Laris	class precision
pred. Laris	56	8	87.50%
pred. Tidak Laris	8	28	77.78%
class recall	87.50%	77.78%	

Gambar 3. Akurasi Model

Gambar 2 adalah hasil *confusion matrix* yang menunjukkan bahwa model memiliki kemampuan klasifikasi yang cukup baik dengan akurasi 84%. Kesalahan prediksi lebih banyak terjadi pada kelas Tidak Laris, yang mengindikasikan bahwa karakteristik menu kurang diminati lebih kompleks dan dipengaruhi oleh kombinasi beberapa variabel. Temuan ini sejalan dengan penelitian sebelumnya yang menyatakan bahwa faktor promosi dan harga memiliki interaksi yang tidak selalu linier terhadap keputusan pembelian. Pola kesalahan klasifikasi tersebut memberikan gambaran mengenai tantangan dalam memprediksi menu dengan tingkat permintaan rendah.

4.3. *Performance Vector*

Selain evaluasi menggunakan *confusion matrix*, performa model juga dianalisis menggunakan metrik evaluasi yang lebih rinci. Analisis ini bertujuan untuk melihat keseimbangan performa model pada masing-masing kelas klasifikasi. Hasil pengukuran performa model ditampilkan dalam bentuk *PerformanceVector*. Visualisasi *PerformanceVector* model ditunjukkan pada Gambar 4.

p-ISSN : 2803-1507 e-ISSN : 2803-1531

PerformanceVector

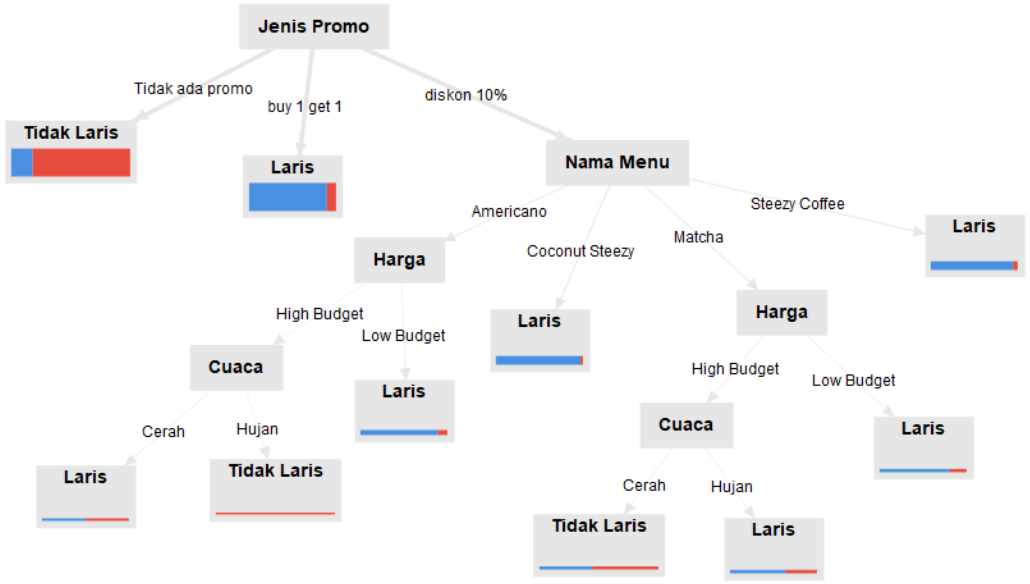
```
PerformanceVector:
accuracy: 84.00%
ConfusionMatrix:
True:   Laris   Tidak Laris
Laris:  56      8
Tidak Laris:    8       28
```

Gambar 4. PerformanceVector

Gambar 3 adalah hasil *Performance Vector* yang menunjukkan bahwa model mencapai akurasi 84,00% dengan performa yang asimetris antara kedua kelas. Kelas Laris menunjukkan *precision*, *recall*, dan *F1-score* yang seimbang pada 87,50%, mengindikasikan kemampuan deteksi menu populer yang konsisten. Sebaliknya, kelas Tidak Laris memiliki metrik yang sedikit lebih rendah (77,78%), menunjukkan bahwa model mengalami kesulitan lebih besar dalam mengidentifikasi menu yang kurang diminati, kemungkinan akibat ketidakseimbangan distribusi data. Meskipun demikian, nilai metrik keseluruhan berada dalam rentang yang dapat diterima untuk implementasi praktis dalam sistem rekomendasi promosi *café*. Penelitian lanjutan dapat mempertimbangkan teknik *resampling* seperti *SMOTE* untuk meningkatkan sensitivitas model terhadap kelas minoritas.

4.4. *Pola Data Mining Menggunakan Decision Tree*

Hasil proses *data mining* menggunakan algoritma *Decision Tree* menghasilkan representasi visual berupa struktur pohon keputusan yang menggambarkan hubungan antaratribut dalam data penjualan café. Struktur ini digunakan untuk memahami alur pengambilan keputusan model dalam mengklasifikasikan menu laris dan tidak laris. Setiap node dalam pohon keputusan merepresentasikan atribut yang memiliki kontribusi tertentu terhadap hasil klasifikasi. Visualisasi hasil pemodelan *Decision Tree* ditunjukkan pada Gambar 5.



Gambar 5. Hasil Decision Tree

Gambar 4 menunjukkan struktur pohon keputusan yang dihasilkan dari proses pelatihan model *Decision Tree* menggunakan *dataset* penjualan *café* yang melibatkan beberapa faktor, yaitu promo, nama menu, harga, dan cuaca. Pohon keputusan ini menggambarkan bagaimana setiap atribut berkontribusi dalam menentukan apakah suatu menu termasuk dalam kategori "Laris" atau "Tidak Laris". Variabel pertama yang terpilih sebagai node akar adalah Jenis Promo, yang menunjukkan bahwa jenis promo merupakan faktor paling dominan dalam memengaruhi daya tarik pelanggan terhadap suatu menu. Pemilihan atribut sebagai node akar didasarkan pada nilai pemisahan terbaik yang dihasilkan selama proses pembentukan pohon keputusan.

Pada cabang Tidak Ada Promo, sebagian besar data langsung diklasifikasikan sebagai "Tidak Laris", yang mengindikasikan bahwa menu tanpa promo memiliki probabilitas rendah untuk diminati pelanggan.

p-ISSN : 2803-1507 e-ISSN : 2803-1531

Sementara itu, pada cabang *Buy 1 Get 1*, mayoritas data langsung masuk kategori "Laris", menunjukkan bahwa promo tipe ini memiliki dampak signifikan dalam meningkatkan minat beli pelanggan. Pada cabang Diskon 10%, pengambilan keputusan tidak dapat dilakukan langsung, sehingga model melanjutkan proses pemisahan menggunakan atribut berikutnya, yaitu Nama Menu. Percabangan ini menunjukkan bahwa tidak semua jenis promo memberikan pengaruh yang sama terhadap tingkat kelarisan menu.

Variabel **N**ama Menu menjadi pemisah kedua yang penting, khususnya pada cabang diskon 10%. Beberapa menu seperti *Steezy Coffee* secara langsung diklasifikasikan sebagai "Laris", menandakan tingkat popularitas yang konsisten pada menu tertentu. Untuk menu lainnya seperti *Americano*, Matcha, dan *Coconut Steezy*, pemisahan selanjutnya dilakukan menggunakan atribut Harga. Hal ini menunjukkan bahwa setelah jenis promo dan nama menu, faktor harga sangat memengaruhi kecenderungan pelanggan dalam membeli menu tersebut. Perbedaan hasil klasifikasi ini menunjukkan bahwa karakteristik masing-masing menu memiliki peran dalam menentukan respons pelanggan terhadap promo yang diberikan.

Pada cabang harga, menu dengan kategori *Low Budget* cenderung mengarah pada klasifikasi "Laris", memperlihatkan bahwa pelanggan lebih tertarik pada menu yang harganya terjangkau. Sebaliknya, menu dengan kategori *Anchor product* membutuhkan pemisahan lebih lanjut menggunakan atribut Cuaca. Variabel cuaca berperan penting sebagai node berikutnya, di mana kondisi Cerah atau Hujan menghasilkan pola yang berbeda. Misalnya, pada beberapa menu, kondisi cerah mengarah pada prediksi "Laris", sedangkan kondisi hujan cenderung menghasilkan prediksi "Tidak Laris", atau sebaliknya, tergantung jenis menu dan harga yang dipadukan.

Secara keseluruhan, struktur pohon keputusan ini memberikan gambaran yang jelas mengenai pola perilaku pelanggan terhadap berbagai faktor yang memengaruhi penjualan *café*. Model ini dapat membantu pihak *café* dalam menyusun strategi yang lebih tepat, seperti menentukan jenis promo yang paling efektif, mengoptimalkan harga menu, memahami kondisi lingkungan yang memengaruhi penjualan, dan mengidentifikasi menu yang memiliki potensi tertinggi untuk dipromosikan. Struktur aturan yang dihasilkan memungkinkan pengelola café menelusuri alasan di balik setiap keputusan klasifikasi yang diberikan oleh model. Informasi ini memberikan pemahaman yang lebih rinci mengenai hubungan antaratribut dalam data penjualan.

4.5. *Analisis Aturan Pohon Keputusan*

Untuk menganalisis pola kelarisan menu café, model *Decision Tree* digunakan untuk mengklasifikasikan menu ke dalam kategori "Laris" atau "Tidak Laris" berdasarkan atribut seperti *Jenis Promo*, nama menu, harga, dan cuaca. Pendekatan ini memungkinkan identifikasi faktor dominan yang memengaruhi perilaku pembelian pelanggan serta membantu pengelola café dalam merancang strategi promosi yang tepat. Model dilatih menggunakan dataset historis, sehingga pola yang dihasilkan mencerminkan interaksi nyata antarvariabel. Proses ini dilakukan melalui koding berikut:

Tree

```
Jenis Promo = Tidak ada promo: Tidak Laris {Laris=24, Tidak Laris=109}
Jenis Promo = buy 1 get 1: Laris {Laris=120, Tidak Laris=14}
Jenis Promo = diskon 10%
|   Nama Menu = Americano
|   |   Harga = High Budget
|   |   |   Cuaca = Cerah: Laris {Laris=3, Tidak Laris=3}
|   |   |   Cuaca = Hujan: Tidak Laris {Laris=0, Tidak Laris=3}
|   |   Harga = Low Budget: Laris {Laris=17, Tidak Laris=2}
|   Nama Menu = Coconut Steezy: Laris {Laris=36, Tidak Laris=1}
|   Nama Menu = Matcha
|   |   Harga = High Budget
|   |   |   Cuaca = Cerah: Tidak Laris {Laris=4, Tidak Laris=5}
|   |   |   Cuaca = Hujan: Laris {Laris=7, Tidak Laris=4}
|   |   Harga = Low Budget: Laris {Laris=8, Tidak Laris=2}
|   Nama Menu = Steezy Coffee: Laris {Laris=35, Tidak Laris=2}
```

Pohon keputusan ini menunjukkan hierarki faktor penentu kelarisan menu café. Node pertama yang dipilih adalah *Jenis Promo*, yang merupakan faktor dominan dalam memengaruhi minat beli pelanggan. Karakteristik menu menjadi pembeda utama pada promo moderat seperti diskon 10%, sementara interaksi antara Harga dan Cuaca berperan sebagai faktor kontekstual untuk menu yang sensitif. Pemisahan setiap node

p-ISSN : 2803-1507 e-ISSN : 2803-1531

didasarkan pada metrik *Information Gain* yang memaksimalkan homogenitas subset data sehingga model dapat memprediksi kelarisan menu secara akurat.

Promo *buy 1 get 1* langsung meningkatkan penjualan tanpa memerlukan analisis lebih lanjut, sedangkan promo diskon 10% memerlukan strategi yang disesuaikan dengan karakteristik menu, segmentasi harga, dan kondisi lingkungan eksternal. Menu dengan stabilitas tinggi seperti *Coconut Steezy* dan *Steezy Coffee* dapat dipertahankan dengan promo minimal untuk menjaga profitabilitas. Menu sensitif seperti Americano dan Matcha memerlukan strategi promosi adaptif berbasis kondisi cuaca dan segmentasi harga. Informasi ini membantu pihak *café* merancang intervensi promosi yang sesuai dengan pola perilaku pelanggan dan potensi penjualan setiap menu.

Secara ringkas, promo kuat langsung menaikkan penjualan, promo ringan membutuhkan dukungan harga dan karakter menu, dan beberapa menu seperti *Coconut Steezy* serta *Steezy Coffee* tetap laris dalam hampir semua kondisi. Ringkasan ini menekankan hubungan sebab-akibat antara atribut pohon keputusan dan hasil penjualan, serta menjadi dasar dalam menyusun strategi bundling dan promosi berbasis data. Pendekatan ini juga memungkinkan pengelola *café* memprediksi performa menu baru dengan memanfaatkan pola yang ada. Pohon keputusan menyediakan pedoman operasional yang jelas untuk alokasi promo dan penentuan harga secara efektif.

4.6. *Impikasi Model terhadap Strategi Bundling*

Berdasarkan aturan yang dihasilkan oleh model *Decision Tree*, rekomendasi strategi *bundling* dapat dirancang secara langsung dan terukur. Struktur pohon keputusan menunjukkan bahwa menu tidak laris umumnya muncul pada kondisi tanpa promo atau diskon ringan dengan harga tinggi. Informasi ini digunakan sebagai dasar dalam merancang paket bundling yang dapat meningkatkan penjualan menu kurang diminati tanpa mengganggu menu populer. Berdasarkan temuan tersebut, strategi *bundling* yang direkomendasikan antara lain:

1. *Bundle* Promosi
   Menu yang masuk kategori Tidak Laris tanpa promo dikombinasikan dengan menu favorit menggunakan skema *buy 1 get 1*. Strategi ini efektif karena promo tersebut terbukti menjadi faktor dominan pada node akar pohon keputusan. Penerapan strategi ini mengikuti pola keputusan pada cabang Tidak Ada Promo, sehingga probabilitas keberhasilan penjualan meningkat. Strategi ini juga memungkinkan pelanggan merasakan manfaat dari promo sehingga meningkatkan engagement terhadap menu lain**.**
2. *Bundle* Harga Terjangkau
   Menu dengan harga tinggi namun sensitif terhadap cuaca, seperti Americano dan Matcha, dibundel dengan menu low budget pada kondisi cuaca tidak mendukung (hujan) untuk menjaga volume penjualan. Penggabungan menu ini berdasarkan pemisahan atribut Harga dan Cuaca pada pohon keputusan sehingga distribusi penjualan tetap stabil. Strategi ini memberikan insentif tambahan bagi pelanggan untuk membeli menu kurang diminati dalam kondisi tertentu.
3. *Bundle* Penjaga Stabilitas
   Menu yang sudah stabil laris seperti *Coconut Steezy* dan *Steezy Coffee* tidak perlu paket bundling agresif, tetapi dapat dipadukan sebagai *anchor product* untuk menarik pembelian menu lain. Pemanfaatan menu populer sebagai *anchor product* mengikuti aturan pohon keputusan yang menunjukkan daya tarik tinggi pada node tertentu. Pendekatan ini membantu menjaga keseimbangan antara promosi agresif dan stabilitas penjualan.

Dengan demikian, model *Decision Tree* tidak hanya berfungsi sebagai alat prediksi, tetapi juga sebagai dasar analitis dalam merancang paket *bundling* yang relevan dengan kondisi operasional *café*. Strategi bundling yang disusun berdasarkan pola atribut dan node pohon keputusan memungkinkan intervensi promosi lebih tepat sasaran. Pendekatan ini dapat digunakan untuk memonitor hasil implementasi bundling dan melakukan penyesuaian berbasis data. Model ini juga menyediakan panduan bagi pengelola café dalam menentukan kombinasi menu yang paling efektif untuk meningkatkan penjualan keseluruhan.

5. DISKUSI

Hasil penelitian menunjukkan bahwa model *Decision Tree* mampu mengidentifikasi pola kelarisan menu café melalui hubungan antara jenis promosi, karakteristik menu, harga, dan kondisi cuaca. Temuan ini menunjukkan bahwa data transaksi historis dapat digunakan untuk membaca kecenderungan perilaku

p-ISSN : 2803-1507 e-ISSN : 2803-1531

konsumen dalam konteks operasional industri kuliner. Pola dominasi promosi, khususnya skema *buy 1 get 1*, memperlihatkan adanya kecenderungan pelanggan merespons insentif langsung dalam proses pengambilan keputusan pembelian, sebagaimana juga digambarkan dalam [1], [6]. Pola klasifikasi berbasis aturan yang dihasilkan membantu menjelaskan keterkaitan antarvariabel yang memengaruhi menu tidak laris.

Jika dibandingkan dengan penelitian terdahulu, hasil ini sejalan dengan temuan yang menunjukkan bahwa algoritma berbasis pohon memiliki kelebihan dalam menghasilkan aturan keputusan yang mudah dipahami dalam konteks manajerial [5], [10]. Perbedaan terlihat pada kemunculan variabel cuaca sebagai pemisah lanjutan setelah harga dan jenis menu, sementara pada beberapa penelitian sebelumnya faktor ini tidak selalu muncul dominan seperti yang dilaporkan dalam [14]. Variasi tersebut menunjukkan bahwa karakteristik lingkungan dan perilaku konsumen lokal memengaruhi struktur pohon keputusan yang terbentuk. Kondisi ini memperlihatkan bahwa penerapan model klasifikasi sangat bergantung pada konteks data dan domain usaha yang dianalisis.

Beberapa pola yang tidak sepenuhnya linier, seperti menu tertentu yang tetap laris meskipun hanya diberi diskon ringan, dapat dipahami melalui kecenderungan preferensi pelanggan terhadap menu favorit. Fenomena ini menunjukkan bahwa respons terhadap promosi tidak bersifat seragam untuk seluruh jenis menu, sebagaimana juga diamati pada analisis preferensi produk dalam [11], [15]. Interaksi antara nama menu dan harga menggambarkan adanya persepsi nilai yang terbentuk di benak pelanggan terhadap produk tertentu. Pola tersebut memperlihatkan bahwa faktor citra menu dan konsistensi kualitas turut berperan dalam menentukan tingkat kelarisan.

Dari sisi implikasi, hasil penelitian ini memperlihatkan peran *Decision Tree* sebagai alat analisis perilaku pembelian yang mampu merepresentasikan hubungan antarvariabel dalam bentuk aturan yang mudah ditelusuri. Dalam praktik operasional, informasi hasil klasifikasi dapat dimanfaatkan untuk menyusun strategi promosi yang menyesuaikan karakter menu dan sensitivitas harga pelanggan. Penelitian ini memiliki keterbatasan pada jumlah atribut yang dianalisis, cakupan data yang belum mencerminkan variasi musiman secara rinci, serta penggunaan kategori cuaca yang masih bersifat umum. Keterbatasan tersebut memengaruhi tingkat kedalaman pola yang dapat diidentifikasi dalam kondisi operasional tertentu.

6. KESIMPULAN DAN SARAN

6.1 *Kesimpulan*

Penelitian ini menunjukkan bahwa algoritma *Decision Tree* mampu memprediksi menu tidak laris dengan performa yang baik dan menghasilkan aturan keputusan yang mudah diinterpretasikan. Jenis promo, khususnya *buy 1 get 1*, terbukti sebagai faktor paling dominan dalam meningkatkan kelarisan menu. Menu tanpa promo memiliki kecenderungan kuat untuk tidak laris, sedangkan menu tertentu tetap stabil meskipun hanya diberi diskon ringan. Algoritma ini bekerja dengan menganalisis hubungan antara jenis promo dan respons pembeli terhadap setiap menu secara sistematis.

Selain fungsi prediksi, aturan *Decision Tree* dapat dikonversi secara langsung menjadi strategi *bundling* yang aplikatif. Model yang dihasilkan tidak hanya bersifat prediktif, tetapi juga mendukung pengambilan keputusan strategis dalam promosi café. Strategi *bundling* ini memungkinkan pengelola *café* menyesuaikan paket menu sesuai preferensi pelanggan. Aturan yang dihasilkan juga dapat membantu dalam merancang penawaran promosi yang lebih terarah dan efisien.

6.2 *Saran*

Berdasarkan hasil penelitian, *café* disarankan memanfaatkan temuan *Decision Tree* ini untuk strategi promosi yang lebih tepat sasaran. Promo *buy 1 get 1* dapat difokuskan pada menu yang benar-benar ingin ditingkatkan penjualannya karena terbukti paling efektif. Menu yang sudah stabil laris seperti *Coconut Steezy* dan *Steezy Coffee* tidak perlu diberi promo berlebih, cukup dipertahankan. Sementara itu, menu seperti *Americano* dan *Matcha* dapat diberi diskon tambahan atau diatur harganya, terutama pada kondisi cuaca tertentu, agar peluang terjual lebih tinggi.

Penelitian ini memiliki beberapa keterbatasan, antara lain jumlah atribut yang masih terbatas, tidak adanya variabel data tren musiman atau bulanan, serta kategorisasi cuaca yang masih sederhana. Selain itu, penelitian ini belum menerapkan *cross-validation*. Pembatasan ini dapat mempengaruhi akurasi prediksi pada periode tertentu yang memiliki pola penjualan tidak biasa. Variabel tambahan seperti preferensi pelanggan atau promo kompetitor dapat meningkatkan kekayaan informasi model.

p-ISSN : 2803-1507 e-ISSN : 2803-1531

Penelitian selanjutnya dapat mengembangkan model dengan membandingkan algoritma lain seperti *Random Forest* atau *XGBoost*, mengintegrasikan metode *FP-Growth* untuk rekomendasi *bundling* otomatis, serta menggunakan data berbasis *time-series* guna menangkap pola musiman penjualan. Model lain ini mungkin menawarkan kinerja prediksi yang lebih baik pada dataset yang lebih kompleks. Integrasi metode *FP-Growth* memungkinkan sistem merekomendasikan kombinasi menu yang lebih sesuai dengan perilaku pembeli. Data *time-series* akan membantu mengidentifikasi tren musiman yang sebelumnya tidak terlihat.

DAFTAR PUSTAKA

[1] A. S. Bozkir and E. A. Sezer, "Predicting Food Demand in Food Courts by Decision Tree Approaches," *Procedia Comput. Sci.*, vol. 3, pp. 759–763, Jan. 2011, doi: 10.1016/j.procs.2010.12.125.

[2] S. H. T. Gulo, O. A. Naibaho, D. S. B. Rajagukguk, G. S. M. Sihite, and I. M. S. S., "Penerapan Data Mining Menggunakan Algoritma C4. 5 untuk Memprediksi Persediaan Stok Beras," *TAMIKA J. Tugas Akhir Manaj. Inform. Komputerisasi Akunt.*, vol. 4, no. 2, pp. 114–121, Dec. 2024, Accessed: Dec. 16, 2025. [Online]. Available: https://ejurnal.methodist.ac.id/index.php/tamika/article/view/3818

[3] H. Shah, N. Myller, C. I. Sedano, H. Shah, N. Myller, and C. I. Sedano, "Forecasting Daily Customer Flow in Restaurants: A Multifactor Machine Learning Approach," *Appl. Comput. Intell.*, vol. 5, no. 2, pp. 168–190, 2025, doi: 10.3934/aci.2025011.

[4] A. P. Syahwanda, R. Arifianti, and C. S. Barkah, "Pengembangan Content Marketing pada Instagram dalam Meningkatkan Brand Engagement (Sosial Media Instagram Brand Fashion Namaterra)," *Responsive J. Pemikir. dan Penelit. Adm. Sos. Hum. dan Kebijak. Publik*, vol. 8, no. 2, pp. 204–217, Jun. 2025, doi: 10.24198/responsive.v8i2.61937.

[5] J. V. Shukla and A. Deshpande, "A Decision Tree Classifier Approach for Predicting Customer's Inclination Toward use of Online Food Delivery Services," *Multidiscip. Sci. J.*, vol. 6, no. 5, pp. 2024072–2024072, May 2024, doi: 10.31893/multiscience.2024072.

[6] M. R. N. Akbar and E. K. Suni, "Penerapan Data Mining Untuk Memprediksi Penjualan Makanan Pada Kopi Krintji Menggunakan Algoritma Regresi Linear dan C4.5," *J. Ilmu Tek. dan Komput.*, vol. 6, no. 2, pp. 122–128, Aug. 2022, doi: 10.22441/jitkom.v6i2.005.

[7] M. Faiz Harby, E. Dyar Wahyuni, and N. C. Wibowo, "Rekomendasi Strategi Penjualan Bundling di Cafe SZ Point Menggunakan Algoritma Frequent Pattern Growth," *J. Inform. dan Tek. Elektro Terap.*, vol. 12, no. 3, pp. 2830–7062, Aug. 2024, doi: 10.23960/jitet.v12i3.4867.

[8] H. N. Romadlon, E. D. Wahyuni, and N. C. Wibowo, "Sistem Rekomendasi Paket Menu Menggunakan Algoritma FP Growth di Teré Café and Bar Seminyak," *J. Publ. Ilmu Komput. dan Multimed.*, vol. 4, no. 2, pp. 195–213, May 2025, doi: 10.55606/jupikom.v4i2.4404.

[9] M. Aci and D. Yergök, "Demand Forecasting for Food Production Using Machine Learning Algorithms: A Case Study of University Refectory," *Teh. Vjesn.*, vol. 30, no. 6, pp. 1683–1691, Oct. 2023, doi: 10.17559/tv-20230117000232.

[10] S. A. Pebrianti, P. A. S. A. Pebrianti, and N. Sulistianingsih, "Evaluasi Kinerja Metode Random Forest dan Decision Tree dalam Klasifikasi Menu Fast Food di Restoran Indonesia," *Technol. Heal. Agric. Nexus Conf. Ser.*, vol. 1, no. 1, pp. 41–47, 2025, [Online]. Available: https://journal.ummat.ac.id/index.php/tcs/article/view/30331

[11] S. Anisah and I. Irwansyah, "Analisis Data Mining untuk Klasifikasi Kafe Populer di Jakarta Menggunakan Decision Tree dan Visualisasi dengan Tableau," *Jutisi J. Ilm. Tek. Inform. dan Sist. Inf.*, vol. 14, no. 2, p. 890, 2025, doi: 10.35889/jutisi.v14i2.2660.

[12] R. Juliani and M. D. Irawan, "Implementasi Algoritma C 5.0 untuk Identifikasi Pola Transaksi Penjualan (Studi Kasus: Basnul Café)," *J. Ilm. MATRIK*, vol. 26, no. 2, pp. 95–106, 2024, doi: 10.33557/jurnalmatrik.v26i2.3217.

[13] M. Iqbal, S. Miskiyah, S. L. Sham, S. Anwar, and M. H. Fuad, "Perbandingan Metode Decision Tree dan Naive Bayes Pada Tingkat Penjualan Minuman Kopi di Kopi Pawon Nusantara," *J. Insa. J. Inf.*

p-ISSN : 2803-1507 e-ISSN : 2803-1531

Syst. Manag. Innov., vol. 4, no. 1, pp. 27–34, 2024, doi: 10.31294/jinsan.v4i1.3682.

[14] E. Şahin and Z. Gök Demir, "Decision Tree Analysis of Sustainable and Ethical Food Preferences of Undergraduate Students of Gastronomy and Culinary Arts," *Sustainability*, vol. 15, no. 4, p. 3266, Feb. 2023, doi: 10.3390/su15043266.

[15] F. D. P. Tanjung, A. P. Windarto, and E. Irawan, "Penerapan Datamining Klasifikasi Pada Faktor Pemilihan Café Bagi Anak Millineal," *Bull. Data Sci.*, vol. 1, no. 3, pp. 90–98, 2022, doi: 10.47065/bulletinds.v1i3.2131.

[16] N. B. A. B. Arifin and A. Asmianto, "Sistem Prediksi Penjualan Menggunakan Kombinasi Metode Monte Carlo dan Decision Tree Berbasis Website," *MATHunesa J. Ilm. Mat.*, vol. 11, no. 2, pp. 274–286, Aug. 2023, doi: 10.26740/mathunesa.v11n2.p274-286.

[17] I. R. Rahadjeng *et al.*, "Analysis of Price and Product Perceived Bolster Purchase Decision: Study Case in Fast Food Restaurant in East Bekasi Area," *J. Manag. Informatics*, vol. 4, no. 2, pp. 757–772, May 2025, doi: 10.51903/jmi.v4i2.202.

[18] S. Sudha and S. Nafeeza, "Predicting and Inspecting Food Contamination Using AI based Hyperspectral Imaging," *J. Technol. Informatics Eng.*, vol. 4, no. 2, pp. 204–213, Aug. 2025, doi: 10.51903/jtie.v4i2.266.

[19] Wakim and A. Wibowo, "Implementasi Mixed Methods Pada Sistem Pendukung Keputusan Bantuan Peternakan," *J. Ilm. Sist. Inf.*, vol. 4, no. 3, pp. 257–268, Jun. 2025, doi: 10.51903/3kdw3211.

[20] M. Rodrigues, V. Miguéis, S. Freitas, and T. Machado, "Machine Learning Models for Short-Term Demand Forecasting in Food Catering Services: A Solution to Reduce Food Waste," *J. Clean. Prod.*, vol. 435, p. 140265, Jan. 2024, doi: 10.1016/j.jclepro.2023.140265.

[21] B. Aydın, Y. S. Balcıoğlu, and B. Sezen, "Food Demand Forecasting With Machine Learning Methods: An Application Using Decision Tree," in *15th International İstanbul Scientific Research Congress*, International İstanbul Scientific Research Congress, 2025, pp. 336–351. doi: 10.30546/19023.978-9952-8553-8-8.2025.51289.

[22] J. G. Choi, Y. W. Zhang, N. I. B. M. Nadzri, N. Baymuminova, and S. N. Xu, "A Review of Forecasting Studies for the Hotel Industry: Focusing on Results, Contributions and Limitations," *Glob. Bus. Financ. Rev.*, vol. 27, no. 5, pp. 65–82, 2022, doi: 10.17549/gbfr.2022.27.5.65.

[23] A. Schmidt, M. W. U. Kabir, and M. T. Hoque, "Machine Learning Based Restaurant Sales Forecasting," *Mach. Learn. Knowl. Extr.*, vol. 4, no. 1, pp. 105–130, Mar. 2022, doi: 10.3390/make4010006.

[24] N. Groene and S. Zakharov, "Introduction of AI-Based Sales Forecasting: How to Drive Digital Transformation in Food and Beverage Outlets," *Discov. Artif. Intell.*, vol. 4, no. 1, pp. 1-, Jan. 2024, doi: 10.1007/s44163-023-00097-x.

[25] S. Jayapal, "Food Demand Prediction Using Statistical and Machine Learning Models," National College of Ireland, School of Computing, National College of Ireland, Dublin, 2023. [Online]. Available: https://norma.ncirl.ie/6594/1/sasikumarjayapal.pdf