

Artikel_Iliah_final.pdf

By Turnitin LLC

Automatic Menu Recommendation for Industrial Catering Using Constraint-Based Filtering, K-Means Clustering, and Apriori Association Rule Mining

Perancangan Sistem Rekomendasi Menu Otomatis Berbasis Machine Learning Untuk Optimalisasi Perencanaan ‘Puteri Catering’

Elang Rezky Pratama¹⁾, Yulian Findawati^{*2)}, Cindy Taurusta³⁾, Yunianita Rahmawati⁴⁾

^{1, 2, 3, 4)}Program Studi Teknik Informatika, Universitas Muhammadiyah Sidoarjo, Indonesia

*Email Penulis Korespondensi: yulianfindawati@umsida.ac.id

Abstract. Industrial catering providers such as Puteri Catering in Pandaan, Indonesia, face a persistent problem in planning daily menus that jointly satisfy cost limits, ingredient availability, and variety, particularly when the process is still done manually. This study addresses that problem by developing an automatic menu recommendation system that integrates Constraint-Based Filtering, K-Means Clustering, and Apriori Association Rule Mining, implemented with Laravel 11, MySQL, and Python (Scikit-learn, MLxtend) on a dataset of 43 menus, 62 ingredients, and 60 transactions. The system achieved a Silhouette Score of 0.5794, generated 83 association rules with the strongest reaching 88.9% confidence, and passed Black Box Testing across 47 test cases with a 100% success rate. These results confirm that the proposed hybrid approach offers a practical, data-driven decision support tool, enabling catering administrators to select cost-appropriate daily menu packages more efficiently and consistently.

Keywords. Apriori Association Rule Mining; Constraint-Based Filtering; K-Means Clustering; Menu Recommendation System

Abstrak. Layanan catering industri seperti Puteri Catering di Pandaan, Indonesia, menghadapi persoalan berulang dalam merencanakan menu harian yang sekaligus memenuhi batas biaya, ketersediaan bahan baku, dan variasi menu, terutama ketika prosesnya masih dikerjakan secara manual. Penelitian ini menjawab persoalan tersebut dengan mengembangkan sistem rekomendasi menu otomatis yang memadukan Constraint-Based Filtering, K-Means Clustering, dan Apriori Association Rule Mining, diimplementasikan menggunakan Laravel 11, MySQL, dan Python (Scikit-learn, MLxtend) pada dataset 43 menu, 62 bahan baku, dan 60 transaksi. Sistem mencapai Silhouette Score sebesar 0,5794, menghasilkan 83 aturan asosiasi dengan aturan terkuat mencapai confidence 88,9%, serta lolos Black Box Testing pada 47 test case dengan tingkat keberhasilan 100%. Hasil ini menegaskan bahwa pendekatan hybrid yang diusulkan menawarkan alat bantu pengambilan keputusan yang praktis dan berbasis data, memungkinkan admin catering memilih paket menu harian yang sesuai anggaran secara lebih efisien dan konsisten.

Kata Kunci. Apriori Association Rule Mining; Constraint-Based Filtering; K-Means Clustering; Sistem Rekomendasi Menu

I. PENDAHULUAN

Penyusunan menu pada usaha catering industri jauh lebih dari sekadar tugas administratif; ini aktivitas inti yang efeknya langsung terasa pada efisiensi produksi, kendali biaya, dan tingkat kepuasan para pekerja penerimanya. Berlainan dengan restoran yang membebaskan pelanggan memilih hidangannya sendiri; sebaliknya, penyedia catering industri—contohnya penyedia makan harian bagi pekerja pabrik harus menyusun paket menu lengkap tiap hari, meliputi lauk, sayur, hingga pelengkap, dengan tetap memperhitungkan batas anggaran serta stok bahan baku yang ada [13]. Ketika dikerjakan tanpa bantuan sistem apa pun, proses ini umumnya menyita banyak waktu, hasilnya tidak seragam, dan berpotensi keliru, khususnya saat stok bahan baku berfluktuasi setiap harinya.


Berlokasi di Pandaan, Jawa Timur, Indonesia, Puteri Catering merupakan penyedia catering industri yang bertugas menyediakan kotak makan harian untuk para pekerja pabrik. Sampai saat ini, tersedia 43 item menu yang dikelola dan terbagi atas tiga kelompok, yaitu lauk, sayur, dan pelengkap, dengan volume penyajian harian berada di kisaran 50 hingga 80 porsi. Sebelum penelitian ini dijalankan, penyusunan menu masih ditangani sendiri oleh pemilik usaha setiap pagi tanpa mempertimbangkan kondisi stok bahan baku secara langsung ataupun melalui analisis biaya yang terarah. Akibatnya, keputusan yang dihasilkan kerap kurang optimal, dan kesempatan untuk menekan harga pokok produksi (HPP) per porsi pun sering terlewatkan begitu saja.

Data mining dan machine learning telah dicoba oleh berbagai studi terdahulu untuk menganalisis dan merekomendasikan menu makanan. Algoritma Apriori dipakai sebagian studi untuk mengenali pola kombinasi menu atau produk yang berulang muncul pada data transaksi, meski konteksnya berlainan, mulai dari kecenderungan belanja konsumen hingga penjualan makanan ringan [1], [2], [3], [5], [6], sementara studi lainnya memanfaatkan K-Means Clustering untuk mengelompokkan menu atau produk makanan menurut volume penjualan atau karakter harganya

[4], [8], [9], [10]. Efektivitas sistem rekomendasi berbasis constraint pun telah dibuktikan dalam menyaring kandidat lewat batasan tegas seperti anggaran dan ketersediaan barang [12]. Selain sistem rekomendasi, optimasi multi-objektif juga dipakai pada perencanaan menu di lingkungan penyedia makanan institusional seperti sekolah dan rumah sakit, terutama untuk mencapai target gizi sekaligus biaya [25]; kendati begitu, pendekatan tersebut umumnya bersandar pada data gizi yang rinci, bukan pola transaksi historis, sehingga tidak cocok diterapkan pada pengambilan keputusan harian yang dibatasi stok maupun anggaran seperti pada operasional katering industri. Meski demikian, mayoritas penelitian yang disebutkan tadi hanya membahas satu sisi masalah saja—baik penemuan pola, clustering, atau filtering—dan biasanya dijalankan pada konteks ritel makanan umum atau usaha kuliner berskala kecil tanpa mempertimbangkan rumitnya operasional khas katering industri, seperti pengecekan stok harian dan penyusunan paket menu berkomponen jamak [11], [13].

Guna mengisi celah tersebut, penelitian ini merancang dan membangun sistem rekomendasi menu otomatis yang terpadu untuk Puteri Catering, dengan memadukan tiga pendekatan yang saling melengkapi dalam satu rangkaian proses. Tahap awal, Constraint-Based Filtering, mengecek kandidat menu terhadap ketersediaan stok bahan baku secara langsung serta batas anggaran harian. Berikutnya, K-Means Clustering mengelompokkan menu ke dalam tiga tingkatan biaya Murah, Sedang, dan Mahal, berdasarkan nilai HPP tiap porsinya. Tahap terakhir, Apriori Association Rule Mining, menggali pola kombinasi menu yang berulang dari 60 catatan transaksi harian historis untuk menyempurnakan hasil rekomendasi yang dihasilkan. Tiga paket menu rekomendasi setiap hari menjadi luaran akhirnya, satu untuk tiap kategori biaya, sehingga admin katering leluasa memilih paket yang paling sesuai dengan kondisi operasional pada hari tersebut.

Framework Laravel 11, basis data MySQL, dan skrip machine learning berbahasa Python yang memakai pustaka Scikit-learn serta MLxtend menjadi fondasi pembangunan sistem ini sebagai aplikasi berbasis web. Sepanjang penelusuran penulis, upaya memadukan constraint-based filtering, K-Means clustering, dan Apriori mining ke dalam satu alur rekomendasi menu harian yang dirancang khusus untuk konteks katering industri seperti ini tergolong masih jarang dilakukan.



Gambar 1. Diagram Alur Penelitian

Aplikasi berbasis web inilah wujud dari sistem yang dibangun, dan pengujiannya memakai data operasional aktual milik Puteri Catering. Uraian lebih rinci mengenai tiap komponen metode yang diusulkan akan disampaikan pada bagian-bagian berikut.

II. METODE PENELITIAN

Tahapan pengembangan pada penelitian ini berjalan berurutan: diawali dari pengumpulan data dan perancangan sistem, kemudian berlanjut ke implementasi algoritma, pembangunan sistem, hingga pengujian fungsional. Gambar 1 menggambarkan keseluruhan alur penelitian tersebut.


2.1 Pengumpulan Data

Puteri Catering, Pasuruan, Jawa Timur, Indonesia menjadi sumber langsung data yang dipakai pada penelitian ini, yang terbagi ke dalam tiga komponen utama. Data menu menjadi komponen pertama, terdiri dari 43 item yang terbagi ke tiga kelompok: 19 lauk, 11 sayur, dan 13 pelengkap. Komponen kedua adalah data bahan baku sejumlah 62 bahan mentah lengkap dengan harga satuannya, dipakai guna menghitung harga pokok produksi (HPP) tiap porsi. Adapun komponen ketiga berupa 60 catatan data transaksi historis harian yang terekam sepanjang April sampai Juni 2025, masing-masing mencantumkan kombinasi menu yang disajikan, jumlah porsi, serta tanggal penyajian.

2.2 Arsitektur Sistem

Arsitektur tiga lapis (three-tier), mencakup lapisan frontend, backend, dan machine learning menjadi dasar rancangan sistem yang diusulkan. Antarmuka web responsif yang bisa diakses dari browser standar apa saja dihasilkan oleh bagian frontend yang dibangun dengan Bootstrap 5. Sementara itu, bagian backend memakai framework Laravel 11 berbasis PHP guna menangani seluruh logika bisnis, routing, serta interaksi dengan basis data. MySQL dipilih

sebagai basis data yang menampung seluruh data induk dan catatan transaksi pada enam tabel utama: tb_bahan (bahan baku), tb_menu (menu), tb_komposisi (komposisi resep), tb_stok (stok bahan baku), tb_hpp (harga pokok produksi), dan tb_transaksi (transaksi harian). Tiga skrip Python yang dipanggil backend Laravel lewat fungsi shell_exec membentuk lapisan machine learning, dengan hasilnya dikembalikan berformat JSON untuk pemrosesan selanjutnya. Skema split-hosting dipakai saat sistem ini di-deploy: aplikasi Laravel ditempatkan di shared hosting Rumahweb, sedangkan skrip machine learning Python disajikan berupa REST API Flask pada platform cloud Railway. Publik dapat mengakses sistem yang telah di-deploy tersebut lewat <https://puteri-catering.site>.



Gambar 2. Diagram Arsitektur Sistem

2.3 Perhitungan HPP

Skrip Python (`hitung_hpp.py`) dipakai untuk menghitung nilai harga pokok produksi (HPP) tiap porsi pada setiap item menu, dengan cara membaca komposisi bahan baku dari basis data lalu menjumlahkan seluruh biaya bahan per porsinya. Berikut rumus yang dipakai:

$$HPP_{material} = \sum (Q_i \times P_i) \quad (1)$$

Selain biaya bahan baku, tiap porsi turut ditambahkan biaya overhead guna mencakup biaya operasional dasar yang belum tercantum pada resep. Berikut ketentuan overhead yang berlaku pada sistem ini: (a) kategori lauk dan sayur dikenakan overhead Rp1.750 per porsi, merupakan gabungan dari biaya nasi putih (0,1 kg × Rp14.000), minyak goreng dasar (0,02 liter × Rp15.000), serta bumbu dasar (0,005 kg × Rp10.000); (b) kategori pelengkap bebas dari overhead (Rp0) sebab sifatnya berdiri sendiri tanpa memerlukan nasi; dan (c) Nasi Kuning secara khusus hanya dikenai overhead Rp350 per porsi karena bahan nasinya sudah tercakup dalam komposisi resep, sehingga overhead-nya hanya mencakup minyak goreng dasar (0,02 liter × Rp15.000 = Rp300) ditambah bumbu dasar (0,005 kg × Rp10.000 = Rp50). Selanjutnya, angka HPP akhir dibulatkan ke ratusan terdekat agar cocok dengan pecahan mata uang terkecil yang lazim dipakai di Indonesia, seperti dirumuskan pada Persamaan (2):

$$HPP_{final} = \text{round} \left(\frac{(HPP_{material} + \text{Overhead})}{100} \right) \times 100 \quad (2)$$

2.4 Constraint-Based Filtering HPP

Tahap awal pada alur rekomendasi diisi oleh Constraint-Based Filtering. Sebelum layak dipertimbangkan menjadi kandidat rekomendasi, seluruh item menu aktif diperiksa lebih dulu terhadap dua batasan tegas pada tahap ini. Kecukupan stok bahan baku terhadap jumlah porsi yang diminta menjadi hal yang diperiksa pada batasan pertama, seperti dituliskan pada Persamaan (3):

$$S_i \geq Q_i \times N \quad (3)$$

dengan i mewakili setiap bahan baku yang dibutuhkan oleh menu bersangkutan. Sementara itu, batasan kedua mengecek apakah total HPP suatu paket menu tidak melampaui batas anggaran yang telah ditentukan admin, sesuai rumusan pada Persamaan (4):

$$HPP_{Lauk} + HPP_{Sayur} + HPP_{Pelengkap} \leq B \quad (4)$$

Kandidat akan disingkirkan dari daftar bila item menu gagal memenuhi salah satu dari kedua batasan tersebut. Hanya menu yang lolos dari kedua batasan itulah yang berlanjut ke tahap selanjutnya.

2.5 K-Means Clustering

Nilai HPP masing-masing item menu yang lolos filtering menjadi dasar pengelompokan tiga tingkatan biaya lewat K-Means Clustering. Jumlah kluster $K=3$ ditetapkan lewat Metode Elbow: caranya dengan mencermati titik di mana grafik within-cluster sum of squares (WCSS) mulai landai (diminishing returns) meski nilai K terus bertambah. Implementasi algoritma memanfaatkan pustaka Scikit-learn, dengan setelan parameter $n_clusters=3$, $random_state=42$, dan $n_init=10$ agar hasil perhitungannya konsisten bila diulang [4], [8].

Penentuan tiga centroid secara acak menjadi langkah awal proses clustering. Berikutnya, tiap menu dipetakan menuju centroid terdekat berdasarkan jarak Euclidean dari nilai HPP-nya, sesuai yang dituliskan pada Persamaan (5):

$$d(x, c) = |HPP_{menu} - HPP_{centroid}| \quad (5)$$

Pembaruan nilai centroid berlangsung berulang sampai tercapai konvergensi. Ketiga kluster kemudian diurutkan sesuai nilai centroid-nya begitu proses clustering rampung, sehingga penamaan Murah diberikan pada kluster bercentroid terendah, Sedang pada kluster tengah, dan Mahal pada kluster tertinggi. Selanjutnya, kualitas hasil clustering diukur memakai Silhouette Score yang dirumuskan pada Persamaan (6):

$$s(i) = \frac{(b(i) - a(i))}{\max(a(i), b(i))} \quad (6)$$

$a(i)$ pada rumus tersebut mewakili rata-rata jarak dalam kluster dari titik data i , sementara $b(i)$ mewakili rata-rata jarak menuju kluster terdekat lainnya. Semakin skor mendekati 1,0, semakin baik pula pemisahan kluster yang tercapai.

2.6 Apriori Association Rule Mining

Guna menemukan pola kombinasi menu yang kerap berulang dari 60 data transaksi historis, dipakai Apriori Association Rule Mining. Pustaka MLxtend menjadi sarana implementasi algoritma ini, dengan ambang minimum support 0,1 (10%) serta minimum confidence 0,3 (30%) [1], [5].

Support dari suatu itemset X didefinisikan pada Persamaan (7):

$$support(X) = \frac{frequency(X)}{total_{transactions}} \quad (7)$$

Confidence dari suatu aturan $X \rightarrow Y$ didefinisikan pada Persamaan (8):

$$confidence(X \rightarrow Y) = \frac{support(X \cup Y)}{support(X)} \quad (8)$$

Seberapa kuat suatu asosiasi $X \rightarrow Y$ dibandingkan bila kemunculan bersamanya hanya kebetulan semata digambarkan lewat nilai lift, yang dirumuskan pada Persamaan (9):

$$lift(X \rightarrow Y) = \frac{confidence(X \rightarrow Y)}{support(Y)} \quad (9)$$


Bukan sekadar kebetulan, kemunculan bersama X dan Y menjadi bermakna bila nilai lift-nya melebihi 1, menandakan bahwa aturan itu membawa informasi yang berarti. Selanjutnya, pada tahap rekomendasi akhir, aturan-aturan asosiasi hasil Apriori ini dipakai untuk mengutamakan kombinasi menu yang secara historis selaras dengan pola penyajian di Puteri Catering.

2.7 Pembuatan Rekomendasi dan Pengujian Sistem

Gabungan keluaran dari ketiga tahap sebelumnya menghasilkan rekomendasi akhir. Sistem membangkitkan 200 kombinasi paket menu valid secara acak dari kumpulan item menu individual yang sudah lolos Constraint-Based Filtering, masing-masing terdiri dari satu lauk, satu sayur, dan satu pelengkap. Total HPP paket menjadi dasar pengurutan kombinasi-kombinasi tersebut, lalu paket bertotal HPP terendah, median, serta tertinggi masing-masing dijadikan wakil kategori Murah, Sedang, dan Mahal. Satu hal yang perlu digarisbawahi: pengurutan HPP di tingkat paket ini berjalan sendiri, terpisah dari clustering K-Means di tingkat item yang sudah dibahas pada Subbagian E; keluaran clustering lebih berperan menggambarkan sebaran biaya menu secara keseluruhan bagi admin, sedangkan kategori paket akhir ditentukan berdasarkan urutan totalHPP dari kombinasi valid yang dibangkitkan secara acak itu

tadi. Kemudian, di antara kombinasi berperingkat sama, aturan asosiasi dari tahap Apriori diterapkan agar kombinasi yang selaras dengan pola historis yang sering muncul mendapat prioritas.

Metode Black Box Testing dipakai untuk menguji sistem ini, yakni dengan memastikan keluaran sistem cocok dengan hasil yang diharapkan atas serangkaian input tertentu tanpa harus menelusuri logika kode di baliknya [7], guna menilai kebenaran fungsionalnya. Sembilan modul sistem tercakup dalam 47 test case yang disusun, meliputi autentikasi, dashboard, manajemen bahan baku, manajemen menu, manajemen stok, rekomendasi otomatis, pemilihan menu manual, riwayat transaksi, dan modul pelaporan.



Gambar 3. Hasil Metode Elbow untuk Menentukan K Optimal

III. HASIL DAN PEMBAHASAN

Bagian ini berisi paparan hasil implementasi dan pengujian sistem rekomendasi menu otomatis: hasil perhitungan HPP, hasil clustering, hasil penambangan aturan asosiasi, hasil rekomendasi, hasil pengujian fungsional, dan diakhiri pembahasan yang mengaitkan temuan penelitian dengan riset-riset yang lebih dulu terbit.

3.1 Hasil Perhitungan HPP

Perhitungan HPP telah rampung dilakukan atas 43 item menu aktif yang tercatat dalam basis data kuteri Catering secara keseluruhan. Ringkasannya, yang telah dikelompokkan menurut kategori menu, bisa disimak pada Tabel 1 di bawah ini.

Tabel 1. Ringkasan Hasil Perhitungan HPP per Kategori

Kategori Menu	Jumlah Item	HPP Minimum	HPP Maksimum	HPP Rata-rata
Lauk	19	Rp 2,600	Rp 9,800	Rp 4,997
Sayur	11	Rp 2,100	Rp 5,100	Rp 2,936

Pelengkap	13	Rp 400	Rp 2,500	Rp 1,254
Total	43	Rp 400	Rp 9,800	Rp 3,229

Rp400 per porsi menjadi HPP terendah yang dimiliki Kerupuk Udang, sementara Rp9.800 per porsi menjadi HPP tertinggi yang dimiliki Empal Daging. Rentang HPP yang cukup lebar di antara ke-43 menu ini menunjukkan keragaman harga yang cukup untuk mendukung proses clustering yang bermakna, sekaligus mampu mengakomodasi berbagai tingkatan anggaran yang ditetapkan admin. Terbukti berkontribusi besar terhadap total HPP adalah komponen overhead Rp1.750 per porsi untuk kategori lauk dan sayur, terutama pada menu berbiaya bahan rendah seperti Tempe Goreng, di mana sekitar 67% dari HPP akhirnya (Rp1.750 dari total Rp2.600) disumbang oleh overhead.

3.2 Hasil K-Means Clustering


Penerapan K-Means Clustering berparameter K=3 dilakukan atas nilai HPP dari 43 menu secara utuh. Konvergensi tercapai algoritma tersebut setelah 6 kali melalui beberapa putaran iterasi, membentuk tiga klaster yang terpisah cukup baik satu sama lain; rangkumannya bisa dilihat pada Tabel 2 berikut.

Tabel 2. Hasil K-Means Clustering

Klaster	Kategori	Centroid HPP	Jumlah Menu	Persentase
1	Murah	Rp 1,823	26	60.5%
2	Sedang	Rp 4,492	13	30.2%
3	Mahal	Rp 8,700	4	9.3%

Pelengkap, sayur, serta lauk berbahan tempe atau tahu mendominasi isi klaster Murah (centroid Rp1.823). Adapun klaster Sedang (centroid Rp4.492) didominasi hidangan berbahan ayam, telur, dan ikan. Sementara itu, hidangan berbahan dasar daging sapi saja yang mengisi klaster Mahal (centroid Rp8.700), yakni Ayam Goreng Telor, Daging Sunduk (Sate), Daging Kelapa, dan Empal Daging.

Silhouette Score dipakai untuk mengukur kualitas hasil clustering, dan angka 0,5794 yang didapat menandakan pemisahan klaster tergolong Baik, sebab nilai pada rentang 0,50 hingga 0,70 umumnya dipandang mencerminkan struktur klaster yang sudah cukup terdefinisi [4], [8]. Ini menegaskan ketepatan pemilihan K=3 untuk distribusi HPP pada dataset menu Puteri Catering, selaras dengan hasil Metode Elbow yang tersaji pada Gambar 3. Sementara itu, Gambar 4 menampilkan bagaimana sebaran menu pada ketiga klaster tersebut.



Gambar 4. Hasil K-Means Clustering

3.3 Hasil Apriori Association Rule Mining

Algoritma Apriori dijalankan atas 60 data transaksi harian historis yang tersedia. Memakai ambang batas 0,1 untuk support dan 0,3 untuk confidence, ditemukan 15 itemset yang kerap berulang serta terbentuk 83 aturan asosiasi seluruhnya. Daftar sepuluh aturan dengan nilai lift tertinggi dapat disimak pada Tabel 3.

Tabel 3. 10 Aturan Asosiasi Terkuat Berdasarkan Nilai Lift

Anteseden	Konsekuensi	Support	Confidence	Lift
Rawon	Mendol	15.0%	88.9%	3.56
Rawon	Kerupuk Udang	15.0%	88.9%	3.20
Pecel, Urap-urap	Bakwan Sayur	11.7%	87.5%	3.15
Pecel, Urap-urap	Peyek Kacang	11.7%	87.5%	3.15
Ayam Bakar	Sayur Asem	10.0%	85.7%	3.06
Empal Daging	Kerupuk Udang	10.0%	83.3%	3.00
Tongkol Balado	Dadar Jagung	10.0%	80.0%	2.88

Bali Telor	Lodeh Rebung	13.3%	80.0%	2.67
Ayam Goreng Telor	Buah Semangka	18.3%	78.6%	2.48
Daging Sunduk (Sate)	Acar	10.0%	75.0%	2.50

Rawon (sup daging sapi berwarna hitam berbumbu keluak) → Mendol (perkedel tempe/kedelai yang difermentasi) menjadi aturan paling kuat yang ditemukan, dengan confidence 88,9% dan lift 3,56. Ini bermakna, tiap kali Rawon muncul dalam suatu transaksi, terdapat peluang 88,9% Mendol turut muncul, dan peluang kemunculan keduanya bersamaan 3,56 kali lebih besar dibandingkan sekadar kebetulan. Kebiasaan kuliner Jawa Timur selaras dengan pola ini, di mana Mendol beserta Kerupuk Udang lazim menjadi pelengkap saat menyantap Rawon [1], [5]. Karena nilai lift di atas 1 dimiliki oleh seluruh aturan yang dihasilkan, dapat disimpulkan bahwa asosiasi-asosiasi tersebut bermakna secara statistik, bukan kebetulan belaka.


3.4 Hasil Sistem Rekomendasi

Tiga paket menu, masing-masing mewakili tingkat biaya berlainan, dihasilkan sistem rekomendasi terintegrasi ini setiap kali ada permintaan. Tabel 4 menampilkan contoh keluaran rekomendasi untuk 60 porsi dengan batas anggaran Rp10.000 per porsi.

Tabel 4. Contoh Keluaran Rekomendasi (60 Porsi, Anggaran Rp10.000/porsi)

Paket	Lauk	Sayur	Pelengkap	Total HPP	Paket
Murah	Tempe Goreng (Rp 2,600)	Sayur Bayam (Rp 2,600)	Kerupuk Udang (Rp 500)	Rp 5,700	Murah
Sedang	Ayam Goreng (Rp 4,100)	Sayur Sop (Rp 2,700)	Buah Jeruk (Rp 700)	Rp 7,500	Sedang
Mahal	Rawon (Rp 6,300)	Tauge Kemangi (Rp 2,200)	Mendol (Rp 700)	Rp 9,200	Mahal

Urutan biaya yang tetap konsisten berhasil dihasilkan sistem lewat tiga paket berbeda, yakni paket Murah senantiasa lebih rendah dari Sedang, dan Sedang senantiasa lebih rendah dari Mahal. Batasan stok bahan baku untuk 60 porsi pun terpenuhi oleh ketiga paket ini. Aturan hasil Apriori turut tercermin pada keluaran rekomendasi, tampak dari paket Mahal yang memuat kombinasi Rawon dan Mendol, pasangan yang teridentifikasi sebagai aturan asosiasi terkuat dengan confidence 88,9%.



Gambar 5. Hasil Sistem Rekomendasi Menampilkan Tiga Paket Menu

3.5 Hasil Black Box Testing

47 test case yang mencakup 9 modul sistem menjadi objek pengujian fungsional dengan metode Black Box Testing, dan Tabel 5 merangkum hasil pengujian tiap modulnya.

Tabel 5. Ringkasan Hasil Black Box Testing

No	Modul	Jumlah Test Case	Lolos	Gagal	Tingkat Keberhasilan
1	Autentikasi	6	6	0	100%
2	Dashboard	3	3	0	100%
3	Manajemen Bahan Baku	5	5	0	100%
4	Manajemen Menu	5	5	0	100%
5	Manajemen Stok	6	6	0	100%
6	Rekomendasi Otomatis	8	8	0	100%

7	Pemilihan Menu Manual	7	7	0	100%
8	Riwayat Transaksi	3	3	0	100%
9	Laporan dan Analitik	4	4	0	100%

Dinyatakan lolos seluruh 47 test case pada 9 modul, sehingga tingkat keberhasilan totalnya mencapai 100%. Percobaan login, baik yang valid maupun tidak, terbukti ditangani dengan benar oleh modul autentikasi, termasuk validasi field kosong dan pencegahan akses tak sah. Urutan biaya yang tepat senantiasa dipertahankan oleh ketiga paket yang dihasilkan modul rekomendasi otomatis, dan stok bahan baku pun otomatis berkurang begitu suatu paket dipilih, hal ini turut dipastikan modul tersebut. Sementara itu, modul pemilihan menu manual mengonfirmasi diterapkannya syarat minimum oleh sistem, yakni minimal satu item dari tiap kategori, sebelum transaksi diizinkan tersimpan.

Sistem hybrid yang diusulkan memadukan Constraint-Based Filtering, K-Means Clustering, dan Apriori Association Rule Mining terbukti mampu menghadirkan solusi fungsional, andal, dan layak diterapkan secara operasional untuk perencanaan menu harian pada layanan katering industri, sebagaimana ditunjukkan hasil-hasil di atas secara kolektif.

3.6 Pembahasan

Bila dibandingkan dengan penelitian-penelitian sejenis pada literatur yang ada, hasil clustering dan penambahan aturan asosiasi pada penelitian ini bisa dimaknai lebih dalam. Kategori pemisahan “Baik” menjadi tempat bernaung nilai Silhouette Score sebesar 0,5794 yang dicapai penelitian ini, dilihat dari sisi K-Means clustering. Riset-riset sebelumnya yang memakai K-Means guna mengelompokkan menu makanan atau minuman menurut angka penjualannya [4], [8], [9], [10] jarang mencantumkan ukuran validitas kluster yang kuantitatif semacam Silhouette Score; mereka lebih menitikberatkan pembahasan pada interpretasi deskriptif tiap kluster. Yulisasi dkk. [22], pada konteks ritel yang lebih luas, menerapkan K-Means dengan evaluasi Silhouette Score pada dataset segmentasi pelanggan yang jauh lebih besar (2.000 data, 7 atribut), namun Silhouette Score optimal yang didapat hanya 0,439 pada $k=4$, tergolong struktur kluster “lemah”. HPP sebagai satu-satunya variabel biaya kontinu diindikasikan oleh nilai Silhouette Score yang relatif lebih tinggi pada penelitian ini menghasilkan kluster yang lebih tegas terpisah dibandingkan segmentasi pelanggan yang melibatkan banyak atribut; hal ini selaras dengan pengamatan umum bahwa kualitas clustering cenderung menurun seiring bertambahnya dimensi dan heterogenitas atribut yang terlibat.

Kekuatan asosiasi yang jauh melampaui aturan sebanding pada penelitian-penelitian transaksi makanan dan ritel lain diperlihatkan oleh aturan terkuat pada penelitian ini (Rawon → Mendol, confidence 88,9%, lift 3,56), dilihat dari segi Apriori association rule mining. Nilai confidence pada kisaran yang relatif sebanding dilaporkan penelitian rekomendasi menu berbasis Apriori sebelumnya [1], [2], [3], [5], [6], meski lift sebagai ukuran validitas tambahan tidak selalu turut dilaporkan. Confidence aturan terkuat sebesar 60,5% dan lift 2,70 dari 30.000 transaksi supermarket dilaporkan oleh Putri Kausara dan Sulistyono [23] pada dataset transaksi ritel secara umum, sedangkan lift maksimum sebesar 1,655 saja dilaporkan Prasetyo dkk. [24] dari dataset Groceries yang sering dipakai. Nilai confidence dan lift yang jauh lebih tinggi pada penelitian ini kiranya berkaitan dengan karakteristik dataset transaksi Puteri Catering yang berukuran lebih kecil, lebih homogen, dan konsisten secara budaya, di mana kombinasi menu amat dipengaruhi kebiasaan kuliner regional yang sudah mapan, Rawon yang lazim disajikan bersama Mendol misalnya dibandingkan pola pembelian yang jauh lebih beragam serta berkorelasi lemah, sebagaimana umum ditemui pada transaksi ritel atau grosir secara luas.

Jika diposisikan terhadap penelitian sistem rekomendasi berbasis constraint dan knowledge sebelumnya, RDF knowledge graph pada domain pembelian kendaraan dimanfaatkan Le dkk. [12] untuk mengusulkan sistem rekomendasi berbasis constraint, dan efektivitas pemodelan constraint eksplisit dalam menghasilkan rekomendasi relevan berhasil ditunjukkan, meski teknik penemuan pola atau clustering belum dipadukan. Senada dengan itu, penalaran semantik dan graph embedding lebih dititikberatkan oleh perkembangan terbaru pada rekomendasi berbasis knowledge dan knowledge-graph [16], [17], tetapi kategorisasi biaya berbasis clustering ataupun penemuan kombinasi berbasis aturan asosiasi belum terintegrasi ke dalam satu alur proses yang menyatu. Melalui tinjauan sistematis mereka atas sistem rekomendasi makanan, Bondevik dkk. [13] mendapati bahwa satu teknik machine learning saja yang diandalkan mayoritas pendekatan rekomendasi makanan yang ada, paling sering content-based atau collaborative filtering [15], sembari mencatat masih jarang penelitian yang membahas penyusunan paket menu multi-komponen dengan batasan operasional real-time seperti stok dan anggaran. Penelitian rekomendasi makanan lain yang terbit

1

sesudah tinjauan tersebut, pendekatan hybrid KNN-SVD dari Yap dkk. [18] dan sistem rekomendasi makanan-restoran multi-kriteria dari Chemlal dkk. [20], misalnya masih berfokus pada rekomendasi item tunggal, bukan penyusunan paket multi-komponen. Di sisi lain, pendekatan dua tahap clustering-dan-aturan-asosiasi dari Liao dkk. [19] serta metode collaborative-filtering-dengan-clustering-dan-aturan-asosiasi dari Annisa dkk. [21] masing-masing cuma menggabungkan dua dari tiga teknik yang dipakai penelitian ini, tanpa menyertakan constraint-based filtering terhadap data stok dan anggaran real-time, ataupun membahas struktur paket multi-komponen yang menjadi ciri khas menu catering industri. Berpijak dari sini, penelitian ini melangkah lebih jauh dibandingkan [12] dan [13] dengan memperlihatkan bahwa constraint-based filtering, K-Means clustering, dan Apriori association rule mining dapat dipadukan secara efektif dalam satu alur proses berurutan yang sekaligus menjamin kelayakan operasional lewat constraint, kategorisasi biaya lewat clustering, dan pemilihan kombinasi berbasis informasi historis lewat aturan asosiasi untuk paket menu multi-komponen—kombinasi yang belum pernah dibahas pada literatur yang ditinjau.

IV. SIMPULAN

Sistem rekomendasi menu harian otomatis untuk Puteri Catering, sebuah layanan catering industri penyedia kotak makan bagi pekerja pabrik di Pandaan, Jawa Timur, Indonesia, berhasil dirancang sekaligus diimplementasikan pada penelitian ini. Tiga pendekatan algoritmik yang saling melengkapi dipadukan sistem ini dalam satu alur proses berurutan guna mengatasi tantangan operasional pada perencanaan menu harian. Perpaduan Constraint-Based Filtering, K-Means Clustering, dan Apriori Association Rule Mining ke dalam satu alur rekomendasi yang menyatu terbukti efektif menghasilkan paket menu harian yang sekaligus memenuhi batasan anggaran, ketersediaan stok bahan baku, dan pola kombinasi historis. Tiga paket menu berbeda setiap harinya Murah, Sedang, dan Mahal berhasil dihasilkan sistem dengan urutan biaya yang tetap konsisten pada seluruh skenario pengujian. Seluruh 43 item menu berhasil dikelompokkan K-Means Clustering dengan $K=3$ ke dalam tiga kategori biaya berdasarkan nilai HPP, mencapai Silhouette Score 0,5794 yang menandakan pemisahan klaster baik, dengan centroid masing-masing Rp1.823, Rp4.492, dan Rp8.700 per porsi untuk klaster Murah, Sedang, dan Mahal, pengelompokan bermakna yang selaras dengan struktur harga aktual menu di Puteri Catering. 83 aturan asosiasi dari 60 data transaksi historis berhasil digali algoritma Apriori, dengan Rawon → MendoI sebagai aturan terkuat yang memiliki confidence 88,9% dan lift 3,56 mencerminkan pola kombinasi menu yang konsisten secara budaya sesuai tradisi kuliner Jawa Timur, sekaligus efektif mengarahkan sistem rekomendasi pada kombinasi yang efisien dari sisi biaya dan relevan dengan konteksnya. Tingkat keberhasilan 100% dihasilkan pengujian fungsional dengan metode Black Box pada 47 test case yang mencakup 9 modul sistem, menegaskan seluruh fitur sistem berjalan dengan benar sesuai spesifikasi yang telah ditetapkan.

Sebagai bahan pengembangan ke depan, beberapa keterbatasan turut teridentifikasi. Enam puluh data simulasi masih menjadi isi dataset transaksi yang dipakai untuk penambangan Apriori saat ini; aturan asosiasi yang dihasilkan diharapkan kian akurat dan mencerminkan pola penyajian yang sesungguhnya seiring bertambahnya data transaksi harian nyata dari kegiatan operasional Puteri Catering, sehingga kualitas rekomendasi bisa terus meningkat dari waktu ke waktu. Sifat statis masih melekat pada nilai HPP di sistem saat ini, karena mengacu pada harga bahan baku pada saat penelitian berlangsung; oleh sebab itu, mekanisme pembaruan harga berkala semisal revisi mingguan atau bulanan perlu diterapkan supaya perhitungan biaya tetap akurat mengikuti perubahan harga pasar. Admin pun masih diharuskan memasukkan jumlah porsi secara manual setiap harinya pada sistem saat ini; pengembangan berikutnya bisa menambahkan model peramalan permintaan jangka pendek berdasarkan data porsi historis untuk membantu admin memperkirakan kebutuhan harian, seperti yang pernah ditunjukkan Rodrigues dkk. dalam konteks layanan catering makanan [14]. Penggunaan desktop pun masih menjadi fokus optimalisasi antarmuka pengguna sistem saat ini; pengembangan antarmuka yang responsif terhadap perangkat mobile atau aplikasi mobile tersendiri akan memperluas aksesibilitas sistem, terutama bagi usaha catering kecil yang operasionalnya kerap ditangani lewat perangkat mobile. Teknik rekomendasi yang lebih canggih, seperti collaborative filtering atau pendekatan berbasis deep learning, juga dapat dijadi pengembangan selanjutnya untuk semakin meningkatkan personalisasi dan akurasi rekomendasi menu seiring bertambahnya volume data transaksi historis [13].

7

UCAPAN TERIMA KASIH

Rasa terima kasih ingin penulis sampaikan kepada pemilik dan staf Puteri Catering, Pandaan, Jawa Timur, atas izin dan bantuan data operasional yang diberikan selama penelitian ini berlangsung.

REFERENSI

- [1] M. Pusparisti and A. N. Paradhita, "Algoritma Apriori Untuk Memberikan Rekomendasi Menu Makanan Berdasarkan Tren Belanja Konsumen," *Jutisi: Jurnal Ilmiah Teknik Informatika dan Sistem Informasi*, vol. 14, no. 1, pp. 666–678, 2025, doi: 10.35889/jutisi.v14i1.2640.
- [2] F. Handayanna and E. Irfiani, "Analisa Pola Penjualan Makanan Dengan Penerapan Algoritma Apriori," *Techno.Com*, vol. 20, no. 4, pp. 478–488, 2021, doi: 10.33633/tc.v20i4.4715.
- [3] Z. Zulham, I. Rusydi, and M. A. Rahman, "Analisa Pola Sistem Penjualan Makanan Ringan dengan Menggunakan Algoritma Apriori," *Jurnal SAINTIKOM*, vol. 20, no. 2, pp. 52–63, 2021, doi: 10.53513/jis.v20i2.3744.
- [4] H. Syahputra, L. Mayola, and D. Guswandi, "Clustering Tingkat Penjualan Menu (Food and Beverage) Menggunakan Algoritma K-Means," *Jurnal KomtekInfo*, vol. 9, no. 1, pp. 29–33, 2022, doi: 10.35134/komtekinfo.v9i1.274.
- [5] M. Rajagukguk, R. Dewi, E. Irawan, J. T. Hardinata, and I. S. Damanik, "Implementasi Association Rule Mining untuk Menentukan Pola Kombinasi Makanan Dengan Algoritma Apriori," *Jurnal Fasikom*, vol. 10, no. 3, pp. 248–254, 2020, doi: 10.37859/jf.v10i3.2308.
- [6] M. Zunaiddi, V. W. Sari, and L. Marsaulina, "Implementasi Data Mining Untuk Menetapkan Paket Menu Menggunakan Algoritma Apriori," *J-SISKO TECH*, vol. 7, no. 1, pp. 38–46, 2024, doi: 10.53513/jis.v22i2.8242.
- [7] P. K. Ayuningtyas, D. Atmodjo WP, and P. Rachmadi, "Performance and Functional Testing with the Black Box Testing Method," *International Journal of Progressive Sciences and Technologies (IJPSAT)*, vol. 39, no. 2, pp. 212–218, 2023, doi: 10.52155/ijpsat.v39i2.5471.
- [8] M. Padli and A. Yasir, "Penerapan Data Mining pada Menu Makanan dan Minuman Berdasarkan Tingkat Penjualan Menggunakan Metode K-Means," *Device: Journal of Information Systems*, vol. 4, no. 2, pp. 182–191, 2023, doi: 10.46576/device.v4i2.4063.
- [9] G. Triyandana, L. A. Putri, and Y. Umaidah, "Penerapan Data Mining Pengelompokan Menu Berdasarkan Tingkat Penjualan Menggunakan Metode K-Means," *J. Appl. Inf. Comput. (JAIC)*, vol. 6, no. 1, pp. 40–46, 2022, doi: 10.30871/jaic.v6i1.3824.
- [10] L. H. Annisa and D. Rusvinasari, "Segmentasi Pembelian Produk Menggunakan Algoritma K-Means Berdasarkan Clusterisasi pada Pemilihan Menu yang Ada di UMKM Kuliner," *Jurnal Informatika: Jurnal Pengembangan IT*, vol. 9, no. 3, pp. 203–212, 2024, doi: 10.30591/jpit.v9i3.6556.
- [11] A. K. Ningsih and W. Witanti, "Sistem Rekomendasi Penjualan Menu Makanan di UMKM Kuliner Menggunakan Association Rule," *Jurnal ICT: Information Communication & Technology*, vol. 20, no. 2, pp. 87–90, 2021, doi: 10.36054/jict-ikmi.v20i2.265.
- [12] N. L. Le, M.-H. Abel, and P. Gouspillou, "A Constraint-based Recommender System via RDF Knowledge Graphs," in *2023 IEEE 26th International Conference on Computer Supported Cooperative Work in Design (CSCWD)*, Rio de Janeiro, Brazil, 2023, pp. 849–854, doi: 10.1109/CSCWD57460.2023.10152701.
- [13] J. N. Bondevik, K. Nørvg, and H. Pham, "A Systematic Review on Food Recommender Systems," *Expert Systems with Applications*, vol. 238, p. 122166, 2024, doi: 10.1016/j.eswa.2023.122166.
- [14] M. Rodrigues, A. L. N. Fred, and J. Gama, "Machine Learning Models for Short-Term Demand Forecasting in Food Catering Services: A Solution to Reduce Food Waste," *Journal of Cleaner Production*, vol. 435, p. 140265, 2024, doi: 10.1016/j.jclepro.2023.140265.
- [15] M. F. Aljunid, M. D. H. M. K. Hooshmand, W. A. Ali, A. M. Shetty, and S. Q. Alzoubah, "A collaborative filtering recommender systems: Survey," *Neurocomputing*, vol. 617, p. 128718, 2025, doi: 10.1016/j.neucom.2024.128718.
- [16] Z. Shokrzadeh, M.-R. Feizi-Derakhshi, M.-A. Balafar, and J. Bagherzadeh Mohasefi, "Knowledge graph-based recommendation system enhanced by neural collaborative filtering and knowledge graph embedding," *Ain Shams Engineering Journal*, vol. 15, no. 1, p. 102263, 2024, doi: 10.1016/j.asej.2023.102263.
- [17] M. Uta, A. Felfernig, V.-M. Le, T. N. T. Tran, D. Garber, S. Lubos, and T. Burgstaller, "Knowledge-based recommender systems: overview and research directions," *Frontiers in Big Data*, vol. 7, p. 1304439, 2024, doi: 10.3389/fdata.2024.1304439.
- [18] Z.-T. Yap, S.-C. Haw, and N. E. Binti Ruslan, "Hybrid-based food recommender system utilizing KNN and SVD approaches," *Cogent Engineering*, vol. 11, no. 1, Art. no. 2436125, 2024, doi: 10.1080/23311916.2024.2436125.
- [19] S.-H. Liao, R. Widowati, and S.-T. Liao, "Two stages data mining analytics for food intentional and behavioral recommendations," *Intelligent Data Analysis*, 2025, doi: 10.3233/IDA-240664.
- [20] M. Chemlal, A. Zedadra, O. Zedadra, A. Guerrieri, and M. N. Kouahla, "A Multi-Criteria Food and Restaurant Recommendation System," *Journal of Universal Computer Science*, vol. 30, no. 12, pp. 1724–1754, 2024.
- [21] S. Annisa, D. P. Rini, and Abdiansah, "Collaborative Filtering Recommendation System Using A Combination of Clustering and Association Rule Mining," *Journal of Information Systems and Informatics*, vol. 6, no. 3, pp. 1499–1516, 2024, doi: 10.51519/journalisi.v6i3.802.

- [22] B. N. Yuliasih, Herman, Sunardi, and H. Yuliansyah, "Evaluation of K-Means Clustering Using Silhouette Score Method on Customer Segmentation," *ILKOM Jurnal Ilmiah*, vol. 16, no. 3, pp. 330–342, 2024, doi: 10.33096/ilkom.v16i3.2325.330-342.
- [23] K. A. Putri Kausara and M. T. Sulistyono, "Comparative Analysis of Association Rule Mining Algorithms Using Apriori and Eclat on Retail Transaction Data," *Journal of Applied Informatics and Computing*, vol. 10, no. 2, pp. 1622–1630, 2026, doi: 10.30871/jaic.v10i2.12122.
- [24] A. B. Prasetio, B. bin Mohd Aboobaider, and A. bin Ahmad, "Interpretable Product Recommendation through Association Rule Mining: An Apriori-Based Analysis on Retail Transaction Data," *International Journal of Informatics and Information Systems*, vol. 8, no. 2, pp. 67–74, 2025, doi: 10.47738/ijiis.v8i2.252.
- [25] O. Sahin and G. Aytekin-Sahin, "Open-source multi-objective optimization software for menu planning," *Expert Systems with Applications*, vol. 252, p. 124213, 2024, doi: 10.1016/j.eswa.2024.124213.

Conflict of Interest Statement:

The author declares that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.

19%

SIMILARITY INDEX

PRIMARY SOURCES

1	archive.umsida.ac.id Internet	973 words — 17%
2	cmsdata.iucn.org Internet	22 words — < 1%
3	Muhamad Rizal Ubaidillah, Nugroho Adhi Santoso, Erni Ungguk Sedya Utami. "Penerapan K-Means Clustering untuk Klasifikasi Jenis Beras Berdasarkan Tren Harga di Pasar Induk Beras Cipinang (PIBC)", RIGGS: Journal of Artificial Intelligence and Digital Business, 2025 Crossref	14 words — < 1%
4	www.sid.ir Internet	12 words — < 1%
5	mafiadoc.com Internet	10 words — < 1%
6	openlibrarypublications.telkomuniversity.ac.id Internet	10 words — < 1%
7	prosiding.isi.ac.id Internet	10 words — < 1%
8	ml-cookbook.sotaaz.com Internet	9 words — < 1%
9	I Putu Arya Vidyananta Vidyananta, Kadek Teguh Dermawan Dermawan. "PERBANDINGAN ALGORITMA K-MEANS DAN K-MEDOIDS DALAM PENGELOMPOKAN PROVINSI DI INDONESIA BERDASARKAN INDIKATOR KEADAAN SEKOLAH DASAR", Jurnal Informatika dan Teknik Elektro Terapan, 2025 Crossref	8 words — < 1%
10	teknoif.itp.ac.id Internet	8 words — < 1%

EXCLUDE QUOTES	OFF
EXCLUDE BIBLIOGRAPHY	ON

EXCLUDE SOURCES	OFF
EXCLUDE MATCHES	OFF