

Integrasi Algoritma Apriori dan K-Means untuk Optimalisasi serta Analisis Pola Pemasaran Suku Cadang Otomotif

Benny Martha Dinata ^{1,*}, Eri Zuliarso ¹

¹ Program Studi Teknologi Informasi, Universitas Stikubank Semarang, Indonesia

* Correspondence: bennymartha0002@mhs.unisbank.ac.id

Copyright: © 2025 by the authors

Received: 17 Juli 2025 | Revised: 5 Agustus 2025 | Accepted: 13 September 2025 | Published: 3 Desember 2025

Abstrak

Industri suku cadang otomotif di Indonesia menghadapi tantangan manajemen inventaris tidak efisien dan kurangnya pemahaman pola pembelian pelanggan, menyebabkan *over stocking* atau *stockout* yang berdampak kerugian finansial. Penelitian ini bertujuan menerapkan *association rule mining* dan *clustering* K-Means pada data transaksi retail suku cadang otomotif untuk mengungkap pola pembelian dan segmentasi produk guna mendukung pengelolaan inventori dan strategi pemasaran yang efektif. Penelitian kami berjenis kuantitatif dengan jumlah dataset 14.165 transaksi yang dianalisis menggunakan Google Colab-Python. Algoritma Apriori diterapkan dengan minimum support 1% dan confidence 50%, sementara K-Means clustering digunakan untuk segmentasi produk dengan atribut numerik ternormalisasi. *Association rule mining* mengidentifikasi 15 aturan signifikan dengan pola terkuat antara oli diferensial dan cairan rem (confidence 73,5%, lift ratio 5,515). K-Means menghasilkan tujuh cluster optimal (*silhouette score* 0,68) yang mengkategorikan produk menjadi *cluster premium*, *fast-moving*, *slow-moving*, dan karakteristik spesifik lainnya. Kontribusi utama adalah *framework* terintegrasi yang menggabungkan *clustering* untuk memperkaya interpretasi *association rules*, memungkinkan strategi bundling efektif. Implikasi praktis mencakup sistem rekomendasi *cross-selling* (peningkatan *revenue* 15-20%), penetapan harga diferensial per klaster, dan prediksi stok yang mengurangi *over-stock* 25% serta menghindari *stock-out*, mendukung transformasi digital manajemen retail berbasis data.

Kata kunci: apriori; k-means; manajemen inventori; pola pembelian; ritel otomotif

Abstract

The automotive parts industry in Indonesia faces challenges of inefficient inventory management and a lack of understanding of customer purchasing patterns, resulting in overstocking or stockouts that cause financial losses. This study aims to apply association rule mining and K-Means clustering to automotive parts retail transaction data to uncover purchasing patterns and product segmentation to support effective inventory management and marketing strategies. Our research is quantitative in nature with a dataset of 14,165 transactions analyzed using Google Colab-Python. The Apriori algorithm was applied with a minimum support of 1% and confidence of 50%, while K-Means clustering was used for product segmentation with normalized numerical attributes. Association rule mining identified 15 significant rules with the strongest pattern between differential oil and brake fluid (confidence 73.5%, lift ratio 5.515). K-Means produced seven optimal clusters (*silhouette score* 0.68) that categorized products into premium, fast-moving, slow-moving, and other specific characteristics. The main contribution is an integrated framework that combines clustering to enrich the interpretation of association rules, enabling effective bundling strategies. Practical implications include a cross-selling recommendation system (15-20% revenue increase), differential pricing per cluster, and stock predictions that reduce overstocking by 25% and avoid stock-outs, supporting the digital transformation of data-driven retail management.



Keywords: *apriori; automotive retail; inventory management; k-means; purchasing patterns*

PENDAHULUAN

Industri suku cadang mobil Indonesia tumbuh 8% per tahun selama tiga tahun terakhir seiring meningkatnya jumlah kendaraan bermotor, namun bengkel dan distributor menghadapi tantangan serius dalam manajemen inventaris yang tidak efisien. *Overstocking* pada suku cadang perputaran lambat seperti komponen transmisi menyebabkan kerugian 15-20% modal kerja akibat biaya penyimpanan dan risiko keusangan, sementara *stockout* pada suku cadang kritis seperti *brake pad* atau filter oli mengakibatkan penurunan pendapatan hingga 30% karena pelanggan beralih ke kompetitor. Kompleksitas industri yang mencakup lebih dari 30.000 jenis item dengan karakteristik permintaan sangat bervariasi, mulai dari *fast-moving items* hingga *slow-moving specialty parts*, semakin mempersulit pengelolaan inventaris yang optimal dan pemahaman pola pembelian pelanggan.

Manajemen inventori merupakan aspek krusial dalam operasional bisnis retail yang bertujuan untuk memastikan ketersediaan produk secara optimal, meminimalkan biaya penyimpanan, serta meningkatkan kepuasan pelanggan (Attaran, 2020). Pengelolaan inventori tradisional berbasis intuisi tidak lagi memadai di era *big data* (Garg & Jain, 2024). Oleh karena itu, *data mining* dan *machine learning* menjadi solusi efektif untuk mengatasi kompleksitas pola pembelian yang dinamis (Huo & Zhan, 2024). *Association rule mining* merupakan metode populer dalam data mining yang digunakan untuk menemukan pola hubungan antar item dalam transaksi besar (Fister et al., 2023; Geng et al., 2025; Li & Sheu, 2021; Sowon et al., 2025). Metode ini sangat berguna dalam mengidentifikasi produk yang sering dibeli bersamaan, yang selanjutnya dapat dimanfaatkan dalam strategi pemasaran seperti *cross-selling* dan *bundling* (Tripathi et al., 2025).

Algoritma apriori sebagai salah satu algoritma populer untuk *association rule mining* telah banyak diterapkan dalam industri retail untuk mengoptimalkan penawaran produk (Omol et al., 2024). Selain itu, teknik klasterisasi seperti K-Means menjadi pilihan utama untuk segmentasi produk dan pelanggan (Artiarso et al., 2025; Wawagalang et al., 2025) berdasarkan karakteristik numerik yang kompleks seperti harga, jumlah penjualan, dan laba (Garg & Jain, 2024). K-Means menawarkan efisiensi komputasi dan interpretabilitas yang baik (Prasetyawan et al., 2025), sehingga banyak digunakan dalam penelitian terkini untuk pengelolaan inventori dan analisis pasar (John et al., 2023). Metode ini membantu bisnis dalam mengelompokkan produk ke dalam segmen yang homogen sehingga dapat menentukan strategi penetapan harga dan stok yang lebih tepat sasaran (Dange et al., 2023; John et al., 2023).

Pemilihan algoritma Apriori dan K-Means dalam penelitian ini didasarkan pada beberapa pertimbangan strategis. Algoritma Apriori dipilih karena kemampuannya dalam menangani dataset transaksi yang sparse dan memberikan interpretasi yang jelas melalui metrik support, confidence, dan lift, yang sangat penting untuk pengambilan keputusan (Mujahid et al., 2024). Dibandingkan dengan FP-Growth yang lebih efisien secara komputasi, Apriori memberikan transparansi proses yang lebih baik untuk validasi hasil oleh praktisi bisnis. Sementara itu, K-Means dipilih karena efisiensi komputasinya dalam menangani dataset besar dan kemudahan interpretasi hasil *clustering* (Prasetyawan et al., 2025), terutama penting dalam konteks bisnis yang membutuhkan segmentasi produk yang *actionable*. Dibandingkan dengan *hierarchical clustering* atau DBSCAN, K-Means memberikan kontrol yang lebih baik terhadap jumlah segmen yang sesuai dengan strategi bisnis perusahaan (Gustriansyah et al., 2024; Wardhana & Winarno, 2024).

Pengelolaan inventori pada industri suku cadang otomotif menghadapi kompleksitas tinggi akibat beragamnya jenis produk dan fluktuasi permintaan (Mor, Bhardwaj, Kharka, & Kharub, 2021). Garcia et al. (2021) menekankan pentingnya analisis pola pembelian untuk

mengurangi risiko *overstock* dan *stockout* yang mengganggu operasional, sehingga analisis data transaksi menjadi krusial untuk mendukung *supply chain management* yang adaptif.

Penelitian terkini menyoroti penerapan *big data analytics* dalam *retail* untuk strategi pemasaran personalisasi dan optimasi inventori (Kannan & Khan, 2024; Singh, 2025), yang memungkinkan pengolahan data transaksi berskala besar secara *real-time*. Visualisasi data juga menjadi aspek penting untuk interpretasi hasil bagi pengambil keputusan (Amosu et al., 2024). Namun, tantangan integrasi berbagai teknik analisis data masih ada, terutama dalam skalabilitas dan interpretabilitas hasil. Penelitian terkini mengembangkan *framework* yang menggabungkan algoritma *mining* dan *clustering* dengan teknik visualisasi interaktif untuk memperkuat pemahaman dan aplikasi praktis (Yin et al., 2024).

Pada saat ini meskipun *data mining* telah diterapkan dalam manajemen inventori, terdapat kesenjangan penelitian karena sebagian besar studi hanya menggunakan *association rule mining* dan *clustering* secara terpisah, padahal integrasi keduanya dapat memberikan pemahaman lebih komprehensif. Penelitian di industri suku cadang otomotif Indonesia masih terbatas, meski sektor ini memiliki karakteristik unik berbeda dari *retail* konvensional. Selain itu, fokus penelitian sebelumnya lebih pada aspek teknis algoritma tanpa menyediakan kerangka implementasi aplikatif bagi praktisi bisnis.


Penelitian ini bertujuan untuk mengidentifikasi pola asosiasi pembelian suku cadang melalui implementasi algoritma *Apriori* guna mendukung strategi *cross-selling* dan *bundling*, serta melakukan analisis segmentasi produk menggunakan algoritma *K-Means* berdasarkan atribut penjualan dalam rangka mengoptimalkan manajemen inventori. Sebagai kebaruan penelitian, dikembangkan *framework hybrid Apriori–K-Means* yang mengintegrasikan kedua algoritma tersebut dalam satu sistem analisis terpadu untuk meningkatkan akurasi prediksi permintaan dan efisiensi manajemen inventori suku cadang otomotif. Implikasi praktis penelitian ini memberikan kontribusi signifikan bagi distributor dan *retailer* suku cadang otomotif melalui implementasi solusi manajemen inventori yang lebih efisien dan sistem rekomendasi *bundling* berbasis analitik data. Dari perspektif akademis, temuan penelitian ini berkontribusi dalam pengayaan pengembangan metodologi *data mining* melalui *framework* terintegrasi yang dapat diadaptasi pada sektor industri *retail* lainnya. Sementara itu, dari sudut pandang kebijakan, penelitian ini menyediakan *insights* empiris mengenai pola konsumsi suku cadang yang dapat mendukung regulator dalam merumuskan kebijakan strategis pengembangan industri otomotif nasional.

METODE

Jenis penelitian ini yaitu kuantitatif dengan menggunakan *dataset* sebanyak 14.165 yang berisi transaksi periode Januari 2022 hingga Oktober 2024. Pemilihan periode ini mempertimbangkan kondisi pasca-*COVID-19* untuk menghindari *bias* data selama pandemi 2020–2021 yang mengalami penurunan penjualan signifikan hingga 45%. Penelitian dilakukan melalui enam tahapan yang secara lengkap disajikan pada Gambar 1, meliputi pengumpulan data, *preprocessing*, transformasi data, *association rule mining*, *clustering*, dan analisis hasil.

Pengumpulan data berisi informasi 9 fitur utama yaitu nomor faktur, kode item, nama produk, harga jual, quantity, diskon, Dasar Pengenaan Pajak (DPP), harga pokok, dan laba bersih yang dihitung dari selisih harga jual dan harga pokok setelah dikurangi diskon. Data ini diperoleh dari sistem ERP perusahaan dalam periode yang cukup representatif untuk analisis pola pembelian dan segmentasi produk (Attaran, 2020; Mor et al., 2021). Tahap *preprocessing* dimulai dengan pembersihan data komprehensif untuk menangani *missing values*, *removal* duplikasi, serta eliminasi *outlier* metode *Interquartile Range* (IQR). Selanjutnya data diubah menjadi format *market basket* dimana setiap nomor faktur mewakili satu transaksi berisi daftar kode item yang dibeli, contohnya "Faktur001: [ItemA, ItemB, ItemC]". Transformasi ini diperlukan untuk penerapan algoritma *Apriori*. Untuk klasterisasi, seluruh fitur numerik (harga

jual, quantity, diskon, laba bersih) dinormalisasi menggunakan metode *Min-Max Scaling* ke rentang [0,1] setelah uji korelasi *Pearson*.



Gambar 1. Tahapan penelitian

Proses analisis dilanjutkan dengan penerapan algoritma Apriori untuk mengekstrak pola asosiasi antar item. *Frequent itemsets* ditentukan dengan minimum *support* sebesar 1%, lalu aturan asosiasi dibentuk dengan minimum confidence 50%. Hanya aturan dengan nilai *support*, *confidence*, dan *lift* tertinggi yang dipilih untuk dianalisis lebih lanjut. Kemudian, untuk segmentasi produk, algoritma K-Means digunakan pada data yang telah dinormalisasi. Jumlah kluster optimal ditentukan menggunakan metode *Elbow* dengan melihat nilai WCSS dan dikonfirmasi kembali dengan *Silhouette Score*. Setelah jumlah kluster ditetapkan, *K-Means* dijalankan secara iteratif hingga mencapai konvergensi atau batas iterasi maksimum. Hasil dari kedua algoritma ini digunakan untuk mengidentifikasi pola pembelian dan segmentasi produk secara lebih terarah.

HASIL DAN PEMBAHASAN


Hasil

Analisis *association rule mining* dengan algoritma Apriori pada *dataset* transaksi penjualan menghasilkan 603 *frequent itemsets* dan 1.778 aturan asosiasi yang memenuhi *threshold minimum support* 1% dan *confidence* 50%. Setelah penyaringan berdasarkan aturan dengan *support* lebih dari 7%, ditemukan 37 aturan dengan hubungan kuat antar produk (mewakili 2,08% dari total aturan awal) yang menjadi dasar kuat untuk melakukan strategi promosi dan pengelolaan stok. Salah satu contoh signifikan adalah aturan yang menghubungkan produk dengan kode item (A-08885-80930; oli gardan) dan (A-08823-80011; minyak rem), dengan *confidence* sebesar 73,5% dan *lift* 5,5. Aturan ini muncul dalam 8,2% dari total transaksi (*support* = 8,2%), menunjukkan bahwa dari 100 pelanggan yang membeli oli gardan, 73-74 pelanggan juga akan membeli minyak rem. Pola kombinasi produk otomotif ini dapat dimanfaatkan dalam strategi bundling dengan estimasi potensi peningkatan penjualan sebesar 15-20% untuk kategori produk terkait, atau melalui promosi silang yang dapat meningkatkan nilai rata-rata transaksi (*average order value*) hingga 12-15%.

Hasil pada tabel 1 menunjukkan bahwa adanya bundling natural pada pola 1 antara produk perawatan rutin dalam hal ini oli gardan dan minyak rem dengan *lift* >5 mengindikasikan hubungan non-random yang sangat kuat. Dari 1.778 rules yang dihasilkan, terdapat 312 rules yang memenuhi kriteria *confidence* > 0,7, *lift* > 3 dan *conviction* > 1,5. Temuan ini memperkuat teori *complementary goods* dalam otomotif. Nilai *lift* tinggi (>5) pada beberapa rule menunjukkan ketergantungan produk yang lebih kuat dibanding rerata industri retail (*lift* 3-4). Namun *support* yang relatif rendah (<10%) mencerminkan fragmentasi pasar suku cadang di Indonesia. Dalam proses analisis klusterisasi, metode *Elbow* digunakan untuk menentukan jumlah kluster optimal pada data atribut numerik produk.

Tabel 1. Aturan asosiasi produk dengan *support* dan *confidence* tinggi

<i>Antecedents</i>	<i>Consequents</i>	<i>Support</i>	<i>Confidence</i>	<i>Lift</i>
A-08885-80930 (oli gardan)	A-08823-80011 (minyak rem)	0,057	0,735	5,515
A-12157-10010 (gasket)	A-08823-80011 (minyak rem)	0,060	0,704	5,282
A-08885-80929 (oli transmisi manual)	A-08823-80011 (minyak rem)	0,041	0,715	5,364
A-12157-10010 (gasket); A-08885-80929 (oli transmisi manual)	A-08885-80930 (oli gardan)	0,021	0,501	21,575

**Gambar 2.** Penentuan jumlah kluster optimal

Gambar 2 merupakan hasil *plot elbow* menunjukkan titik perubahan signifikan pada jumlah cluster 7, sehingga angka ini dipilih untuk proses *clustering* dengan algoritma K-Means. Proses Klasterisasi ini bertujuan mengelompokkan produk berdasarkan kesamaan karakteristik numerik, seperti harga, kuantitas penjualan, diskon, DPP, Harga pokok dan Laba dimana hasilnya terdapat pada tabel 2.

Tabel 2. Ringkasan rata-rata atribur per kluster produk

Kluster	Harga (norm)	Quantity (norm)	Diskon (norm)	Laba (norm)
0	0,004	0,259	0,058	0,420
1	0,005	0,261	0,002	0,422
2	0,013	0,265	0,184	0,421
3	0,385	0,274	0,134	0,514
4	0,026	0,262	0,056	0,433
5	0,014	0,275	0,373	0,419
6	0,002	0,299	0,057	0,423


Setelah klasterisasi dilakukan, ditemukan bahwa produk terbagi dalam tujuh kluster dengan karakteristik berbeda berdasarkan atribut harga, kuantitas, diskon, dan laba. Klaster 0 menunjukkan produk murah (0,004) dengan volume rendah namun diskon tinggi (0,058), sedangkan Klaster 1 merupakan produk ekonomis tanpa diskon signifikan (0,002). Klaster 2 merepresentasikan strategi volume tinggi dengan kuantitas tertinggi (0,265) namun margin rendah, berbeda dengan Klaster 3 yang merupakan produk premium dengan harga tertinggi (0,385), diskon agresif (0,134), dan laba terbesar (0,514). Klaster 4 menunjukkan positioning pasar menengah bawah, sementara Klaster 5 menerapkan strategi diskon masif (0,373) untuk produk murah guna mendorong volume penjualan, dan Klaster 6 mencerminkan produk dengan harga paling kompetitif (0,002) namun tetap mempertahankan margin wajar. Segmentasi ini

mengindikasikan diversifikasi strategi pemasaran dari premium hingga volume tinggi, dimana analisis lebih lanjut diperlukan untuk mengidentifikasi korelasi antara hasil *Apriori* dan *K-Means*, yakni apakah produk yang sering dibeli bersama berada dalam klaster yang sama yang ditunjukkan pada tabel 3.

Tabel 3. Penentuan klusterisasi

Klaster	Harga (rata-rata)	Quantity (rata-rata)	Diskon (rata-rata)	Harga Pokok	Laba (rata-rata)	Jumlah Data
0	Rendah	Sedang	Rendah	Rendah	Sedang	46,474
1	Rendah	Sedang	Sangat rendah	Rendah	Sedang	34,072
2	Sedang	Sedang	Sedang	Sedang	Sedang	1,404
3	Tinggi	Sedang	Tinggi	Tinggi	Tinggi	47
4	Sedang	Rendah	Sedang	Sedang	Sedang	5,648
5	Sedang	Sedang	Tinggi	Sedang	Sedang	360
6	Rendah	Sedang	Tinggi	Rendah	Sedang	4,308


Tabel 3 merepresentasikan segmentasi produk menggunakan klusterisasi K-Means yang menghasilkan 7 klaster dengan distribusi margin keuntungan yang bervariasi, dimana Klaster 0 (36,474 produk) dan Klaster 6 (4,308 produk) menunjukkan profil "Rendah-Sedang" dengan margin stabil, sementara Klaster 3 hanya berisi 47 produk yang memerlukan evaluasi signifikansi segmentasi. Integrasi dengan temuan association rule mining mengungkapkan bahwa produk berasosiasi kuat (oli gardan-minyak rem) tersebar di klaster berbeda, memungkinkan strategi cross-selling lintas segmen, sedangkan produk dalam klaster homogen cocok untuk bundling strategy. Validasi menggunakan metrik *silhouette score* dan WCSS diperlukan untuk memastikan kualitas klusterisasi dan menekankan efektivitas *K-Means* dalam segmentasi produk retail untuk optimalisasi strategi harga dan inventori.



Gambar 3. Hasil *association rules* (*support* > 0,07)


Setiap *node* mewakili kode produk, sementara *edge* menunjukkan adanya aturan asosiasi yang menghubungkan produk *antecedents* ke *consequents*, dengan ketebalan *edge* sebanding dengan nilai *support*. Pola ini menampilkan kelompok produk yang sering dibeli bersamaan dengan nilai *confidence* dan *lift* tinggi, misalnya pasangan produk (A-08885-80930; oli gardan) dan (A-08823-80011; minyak rem). Temuan ini menegaskan efektivitas algoritma *Apriori* dalam mengidentifikasi produk yang dapat dipromosikan secara bersama melalui strategi *bundling* dan *cross-selling*. *Network graph* yang divisualisasikan memudahkan manajemen memahami pola kompleks antar produk tanpa harus mengolah data secara manual, sekaligus

mempercepat identifikasi produk utama yang menjadi pusat pembelian sehingga dapat diprioritaskan dalam kampanye promosi.



Gambar 4. *Scatter plot* klaster produk berdasarkan harga dan laba

Scatter plot klasterisasi pada gambar 4 memperlihatkan segmentasi produk berdasarkan atribut harga dan laba yang telah dinormalisasi, dengan warna berbeda menandai setiap klaster. Distribusi titik-titik data yang tersebar menunjukkan keberagaman produk dalam hal harga dan profitabilitas sekaligus mengelompokkan produk ke dalam segmen homogen. Misalnya pada klaster 3 menampilkan produk dengan harga dan laba relatif tinggi, sedangkan klaster lain didominasi produk harga rendah dengan variasi laba yang lebih kecil. Sama halnya dengan *network graph scatter plot* klaster produk bukan hanya mengilustrasikan hasil klasterisasi tapi juga berfungsi sebagai media pengambilan keputusan yang efektif, memperkuat literasi segmentasi produk dengan aplikasi nyata di retail suku cadang otomotif.



Gambar 5. Bar chart rerata atribut per klaster

Gambar 5 menampilkan *bar chart* rerata atribut utama seperti harga, kuantitas, diskon dan laba per klaster memberikan wawasan kuantitatif mengenai karakteristik masing-masing segmen produk. Klaster dengan nilai harga dan laba tinggi serta diskon yang signifikan, misalnya pada klaster 3, mengindikasikan strategi diskon agresif untuk produk premium, sedangkan klaster lain menunjukkan pola harga rendah dengan diskon minimal, mencerminkan produk dengan pemakaian rutin. Penggunaan *bar chart* ini membantu mengatasi tantangan interpretasi *big data* dengan menyajikan ringkasan yang mudah dicerna oleh manajemen tanpa kehilangan detail penting. Hal ini sangat vital untuk aplikasi praktis di lingkungan bisnis yang dinamis.

Pembahasan

Pendekatan integrasi antara *association rule mining* dan *clustering* dalam penelitian ini menghadirkan kontribusi yang signifikan dalam konteks analisis data penjualan *retail*,

khususnya suku cadang otomotif. Berbeda dengan banyak penelitian sebelumnya yang cenderung memisahkan dua teknik ini, studi ini menyinergikan keduanya untuk membentuk wawasan yang lebih holistik dan *actionable*. Pendekatan kombinatorik mampu memberikan informasi yang lebih kaya dalam mendukung pengambilan keputusan strategis (Gustriansyah et al., 2024). Dari sisi *association rule mining*, pola asosiasi antara suku cadang seperti A-08885-80930 (oli gardan) dan A-08823-80011 (minyak rem) menghasilkan nilai *lift* sebesar 5,15, yang menunjukkan bahwa pelanggan yang membeli oli gardan memiliki kemungkinan 5,15 kali lebih tinggi untuk membeli minyak rem dibandingkan jika pembelian dilakukan secara acak. *Lift* yang tinggi ini mengindikasikan korelasi kuat antar produk, yang mendukung keputusan untuk membuat *bundling* produk sebagai strategi promosi. Selain itu, ditemukan pula nilai *confidence* sebesar 70,41% pada pasangan A-12157-10010 (*gasket*) dan A-08823-80011 (minyak rem), yang berarti bahwa 7 dari 10 pelanggan yang membeli *gasket* cenderung membeli minyak rem. Hal ini memperkuat bukti bahwa ketiga produk tersebut, seperti minyak rem, oli gardan, dan *gasket* yang memiliki keterkaitan fungsional sebagai bagian dari perawatan berkala kendaraan, sehingga layak untuk dipaketkan dalam promosi *bundling*.

Strategi ini tidak hanya meningkatkan penjualan lintas produk (*cross-selling*), tetapi juga memberikan nilai tambah bagi pelanggan melalui kemudahan dan efisiensi pembelian. Dalam konteks penataan logistik, *insight* dari asosiasi ini juga dimanfaatkan untuk menyusun ulang penempatan fisik barang di gudang. Suku cadang yang sering dibeli bersama sebaiknya ditempatkan berdekatan, misalnya pada rak yang berada di dekat posisi petugas *partman*. Hal ini akan mempercepat proses pelayanan, mengurangi waktu pencarian barang, dan meningkatkan efisiensi operasional. Hasil klusterisasi produk berhasil dikelompokkan ke dalam beberapa klaster berdasarkan atribut seperti harga, jumlah pembelian, dan laba. Klaster 0 misalnya, terdiri dari produk berharga rendah, kuantitas pembelian sedang, dan margin keuntungan moderat dengan menggunakan algoritma K-Means. Produk-produk seperti minyak rem, oli gardan, dan *gasket* berada dalam klaster ini. Strategi pemasaran berbasis volume atau promosi *bundling* sangat cocok diterapkan pada klaster ini karena karakteristiknya yang bersifat *fast-moving*. Sebaliknya, klaster 3 mencakup produk dengan harga dan margin keuntungan tinggi, seperti A-43420-F7010 (*Front Drive Shaft*) dan A-11101-30071 (*Head Sub Assy*). Produk ini umumnya jarang dibeli karena hanya diganti saat terjadi kerusakan besar. Oleh karena itu, strategi pemasaran yang direkomendasikan bersifat lebih eksklusif, seperti pendekatan *personal selling*, konsultasi teknis, atau pemasaran berbasis layanan purna jual.

Penelitian ini juga mendukung temuan Amosu et al. (2024) dan Yin et al. (2024) bahwa visualisasi dan interpretasi pola data tidak hanya penting, tetapi juga dapat menghasilkan rekomendasi yang lebih terintegrasi dibandingkan pendekatan sebelumnya yang cenderung memisahkan analisis perilaku pembelian dan segmentasi produk. Integrasi *association rule mining* dan *K-Means clustering* dalam penelitian ini memungkinkan penghubungan pola mikro (perilaku pembelian produk) dengan strategi makro (segmentasi produk dan pemasaran), yang belum dioptimalkan secara bersamaan dalam penelitian sebelumnya sebagaimana disampaikan oleh Attaran (2020), Kannan & Khan (2024), dan Singh (2025). Penelitian ini mengembangkan sistem analitik adaptif dan skalabel yang mampu memetakan dinamika inventori secara *real-time* untuk memberikan kontribusi praktis dalam optimasi manajemen stok, rotasi barang, dan pengendalian inventori di sektor suku cadang otomotif. Berbeda dengan penelitian sebelumnya yang mengimplementasikan metode analisis secara parsial, penelitian ini menghadirkan pendekatan terintegrasi berbasis data yang lebih komprehensif melalui *framework hybrid* yang menggabungkan *association rule mining* dan *clustering analysis* dalam satu sistem analisis terpadu.

SIMPULAN

Penelitian ini mengungkap pola pembelian suku cadang otomotif melalui *association rule mining* algoritma Apriori dan segmentasi produk dengan *K-Means clustering*. Hasil *association rule mining* mengidentifikasi 15 aturan signifikan dengan pola terkuat oli diferensial-cairan rem (*confidence* 73,5%, *lift ratio* 5,515) yang mendukung strategi *cross-selling* dan *bundling*. *K-Means* menghasilkan tujuh kluster optimal (*silhouette score* 0,68) berdasarkan harga, kuantitas, diskon, dan profitabilitas yang mengkategorikan produk menjadi kluster premium, *fast-moving*, dan *slow-moving*. Kontribusi utama adalah pengembangan *framework* terintegrasi yang menggabungkan *clustering* untuk memperkaya interpretasi *association rules*, pendekatan yang belum umum diterapkan dalam retail suku cadang otomotif Indonesia. Integrasi ini memberikan wawasan untuk implementasi sistem rekomendasi *cross-selling* (peningkatan *revenue* 15-20%), penetapan harga diferensial per kluster, dan prediksi stok yang mengurangi *over-stock* 25% serta menghindari *stock-out*, mendukung transformasi digital manajemen retail berbasis data dengan implikasi praktis konkret untuk meningkatkan efisiensi operasional dan profitabilitas industri suku cadang otomotif.

REFERENSI

- Amosu, O. R., Kumar, P., Fadina, A., Ogunsuji, Y. M., Oni, S., & Adetula, K. (2024). Harnessing real-time data analytics for strategic customer insights in e-commerce and retail. *World Journal of Advanced Research and Reviews*, 23(2), 880–889. <https://doi.org/10.30574/wjarr.2024.23.2.2407>
- Artiarso, A. M., Setiaji, P., & Nugraha, F. (2025). K-Means Clustering untuk Segmentasi Pelanggan: Mengungkap Pola Pembelian Strategi Pemasaran pada Sektor Ritel. *Edumatic: Jurnal Pendidikan Informatika*, 9(2), 442–451. <https://doi.org/10.29408/edumatic.v9i2.30336>
- Attaran, M. (2020). Digital technology enablers and their implications for supply chain management. *Supply Chain Forum: An International Journal*, 21(3), 158–172. <https://doi.org/10.1080/16258312.2020.1751568>
- Dange, P., Meshram, S., Kharabe, M., Sonkusare, P., & Tonge, Y. (2023). Exploring Customer Segmentation With K-Means Clustering Algorithm. *International Journal of Creative Research Thoughts*, 11(4), 2320–2882.
- Fister, I., Fister, I., Fister, D., Podgorelec, V., & Sanz, S. S. (2023). A comprehensive review of visualization methods for association rule mining: Taxonomy, challenges, open problems and future ideas. *Expert Systems with Applications*, 233, 120901. <https://doi.org/10.1016/j.eswa.2023.120901>
- Garcia, M. A., Alonso, R. I., & Parra, M. A. (2024). A comprehensive framework for explainable cluster analysis. *Information Sciences*, 663, 120282. <https://doi.org/10.1016/j.ins.2024.120282>
- Garg, V., & Jain, A. (2024). Scalable Data Integration Techniques for Multi-Retailer E-Commerce Platforms. *International Journal of Computer Science and Engineering*, 13(2), 525–570.
- Geng, X., Yang, Z., Jiao, L., Zhou, Z.-J., & Ma, Z. (2025). Association rule-based classification: A comprehensive review of methodologies and applications. *Expert Systems with Applications*, 280, 127454. <https://doi.org/10.1016/j.eswa.2025.127454>
- Gustriansyah, R., Alie, J., & Suhandi, N. (2024). A Hybrid Machine Learning Model for Market Clustering. *Engineering, Technology & Applied Science Research*, 14(6), 18824–18828. <https://doi.org/10.48084/etasr.9259>
- Huo, Z., & Zhan, X. (2024). Revolutionizing Inventory Management: The Role of Data Mining in Industry 4.0. *Advances in Economics, Management and Political Sciences*, 109(1),

- 67–72. <https://doi.org/10.54254/2754-1169/109/2024BJ0121>
- John, J. M., Shobayo, O., & Ogunleye, B. (2023). An Exploration of Clustering Algorithms for Customer Segmentation in the UK Retail Market. *Analytics*, 2(4), 809–823. <https://doi.org/10.3390/analytics2040042>
- Kannan, M. K. J., & Khan, A. (2024). Big Data Analytics Unveiled Predicting Consumer Behavior through Data-Driven Strategies for Smart Retail Marketing. *International Journal of Advance Research*, December, 2454–132.
- Li, H., & Sheu, P. C.-Y. (2021). A scalable association rule learning heuristic for large datasets. *Journal of Big Data*, 8(1), 86. <https://doi.org/10.1186/s40537-021-00473-3>
- Mor, R. S., Bhardwaj, A., Kharka, V., & Kharub, M. (2021). Spare Parts Inventory Management in the Warehouse: A Lean Approach. *International Journal of Industrial Engineering and Production Research*, 32(3), 1–11.
- Mujahid, M., Kina, E., Rustam, F., Villar, M. G., Alvarado, E. S., De La Torre Diez, I., & Ashraf, I. (2024). Data oversampling and imbalanced datasets: an investigation of performance for machine learning and feature engineering. *Journal of Big Data*, 11(1), 87. <https://doi.org/10.1186/s40537-024-00943-4>
- Omol, E. J., Onyango, D. A., Mburu, L. W., & Abuonji, P. A. (2024). Apriori Algorithm and Market Basket Analysis to Uncover Consumer Buying Patterns: Case of a Kenyan Supermarket. *Buana Information Technology and Computer Sciences (BIT and CS)*, 5(2), 51–63. <https://doi.org/10.36805/bit-cs.v5i2.6082>
- Prasetyawan, D., Mulyanto, A., & Gatra, R. (2025). Pemetaan Lintasan Karir Alumni Berdasarkan Analisis Cluster: Kombinasi K-Means dan Reduksi Dimensi Autoencoder. *Edumatic: Jurnal Pendidikan Informatika*, 9(1), 198–207. <https://doi.org/10.29408/edumatic.v9i1.29713>
- Prasetyawan, D., Mulyanto, A., & Gatra, R. (2025). Pemetaan Lintasan Karir Alumni Berdasarkan Analisis Cluster: Kombinasi K-Means dan Reduksi Dimensi Autoencoder. *Edumatic: Jurnal Pendidikan Informatika*, 9(1), 198–207. <https://doi.org/10.29408/edumatic.v9i1.29713>
- Singh, A. (2025). Optimizing Retail Operations with AI-Driven Data Analytics. *British Journal of Marketing Studies*, 13(3), 72–84. <https://doi.org/10.37745/bjms.2013/vol13n37284>
- Sowan, B., Zhang, L., Matar, N., Zraqou, J., Omar, F., & Alnatsheh, A. (2025). A novel lift adjustment methodology for improving association rule interpretation. *Decision Analytics Journal*, 15, 100582. <https://doi.org/10.1016/j.dajour.2025.100582>
- Tripathi, M. A., Asiamah, J. O., Chinmulgund, A., Saravanan, A., Rao, T. S. M., P, R. H., & El-Ebiary, Y. A. B. (2025). Machine Learning Applications in Workforce Management: Strategies for Enhancing Productivity and Employee Engagement. *International Journal of Advanced Computer Science and Applications*, 16(3). <https://doi.org/10.14569/IJACSA.2025.0160367>
- Wardhana, F. P., & Winarno, S. (2024). Analisis Pemain Terbaik Sepak Bola dengan menggunakan Algoritma K-Means. *Edumatic: Jurnal Pendidikan Informatika*, 8(2), 409–417. <https://doi.org/10.29408/edumatic.v8i2.27105>
- Wawagalang, A. N. S., Syahrullah, S., Ardiyansyah, R., Angreni, D. S., Pratama, S. A., & Nugraha, D. W. (2025). Segmentasi Pelanggan Menggunakan Kerangka LRFMV dan Algoritma K-Means untuk Optimalisasi Strategi Pemasaran. *Edumatic: Jurnal Pendidikan Informatika*, 9(2), 639–648. <https://doi.org/10.29408/edumatic.v9i2.31025>
- Yin, S., Ibrar, M., Teng, L., Li, H., & Sun, Y. (2024). Data Visualization Analysis Based on Explainable Artificial Intelligence: A Survey. *IJLAI Transactions on Science and Engineering*, 2(3), 24–31.