

PEMODELAN *RFM* & *K-MEANS CLUSTERING* UNTUK SEGMENTASI PELANGGAN DALAM PENJUALAN ONLINE

Ivander Lukas Pratama^{1*}, Finanta Okmayura²⁾, Aidha Tita Irani³⁾, Ernia Juliastuti⁴⁾,
Muhammad Amirulhaq⁵⁾, Rizky Ardiansyah⁶⁾, Sherly Fillia⁷⁾

¹²³⁴⁵⁶⁷ Fakultas Matematika dan Ilmu Pengetahuan Alam (FMIPA), Universitas Riau
email: ivander.lukas3896@student.unri.ac.id¹, finanta.okmayura@lecturer.unri.ac.id²
aidha.tita3285@student.unri.ac.id³, ernia.juliastuti5937@student.unri.ac.id⁴
muhammad.amirulhaq0496@student.unri.ac.id⁵, rizky.ardiansyah0502@student.unri.ac.id⁶,
sherly.fillia3292@student.unri.ac.id⁷

*Corresponding Author

Abstract

The exponential growth of e-commerce platforms necessitates sophisticated customer analytics to maintain competitive advantage and optimize revenue streams. This study addresses the critical challenge of understanding heterogeneous customer purchasing behaviors in online retail environments through advanced data mining techniques. The research implements RFM (Recency, Frequency, Monetary) modeling integrated with K-Means clustering algorithm to achieve comprehensive customer segmentation for strategic marketing optimization. A quantitative-exploratory methodology was employed, utilizing a comprehensive online sales dataset comprising over 40,000 transactional records. The analytical framework involved systematic data preprocessing using Python libraries (Pandas, NumPy), followed by RFM parameter calculation and standardization through StandardScaler normalization. K-Means clustering was subsequently applied with optimal cluster determination via Elbow Method validation, yielding three distinct customer segments. Visualization and interpretation were conducted using Tableau, Matplotlib, and Seaborn for comprehensive segment characterization. Results demonstrate successful identification of strategically significant customer clusters: high-value loyal customers, moderate-engagement prospects, and potential churn-risk segments, each exhibiting distinctive RFM behavioral patterns. The segmentation framework enables targeted marketing strategy formulation, personalized customer retention programs, and optimized resource allocation. This research contributes valuable insights for e-commerce practitioners seeking data-driven approaches to enhance customer relationship management and sustain long-term business profitability in competitive online marketplaces.

Keywords: *RFM Modeling, K-Means Clustering, Online Sales, Customer Segmentation, Customer Analytics*

Abstrak

Pertumbuhan eksponensial platform perdagangan elektronik menuntut analitik pelanggan yang canggih untuk mempertahankan keunggulan kompetitif dan mengoptimalkan aliran pendapatan. Penelitian ini mengkaji tantangan kritis dalam memahami heterogenitas perilaku pembelian pelanggan di lingkungan ritel digital melalui teknik *data mining* yang canggih. Studi ini mengimplementasikan pemodelan *RFM* (*Recency, Frequency, Monetary*) yang terintegrasi dengan algoritma *K-Means clustering* untuk mencapai segmentasi pelanggan yang komprehensif guna optimalisasi strategi pemasaran berbasis data.

Metodologi kuantitatif-eksploratif digunakan dengan memanfaatkan dataset penjualan digital komprehensif yang terdiri dari lebih dari 40.000 catatan transaksional. Kerangka analitis melibatkan *preprocessing* data sistematis menggunakan *library* Python (*Pandas*, *NumPy*), diikuti perhitungan parameter *RFM* dan standarisasi melalui normalisasi *StandardScaler*. *K-Means clustering* kemudian diterapkan dengan penentuan kluster optimal melalui validasi *Elbow Method*, menghasilkan tiga segmen pelanggan yang distinktif. Visualisasi dan interpretasi dilakukan menggunakan *Tableau*, *Matplotlib*, dan *Seaborn* untuk karakterisasi segmen yang komprehensif. Hasil menunjukkan identifikasi sukses kluster pelanggan yang signifikan secara strategis: pelanggan loyal bernilai tinggi, prospek *engagement* moderat, dan segmen berisiko *churn* potensial. Kerangka segmentasi memungkinkan formulasi strategi pemasaran yang tertarget, program retensi pelanggan yang dipersonalisasi, dan alokasi sumber daya yang optimal berdasarkan pola perilaku *RFM* yang distinktif.

Kata Kunci: Pemodelan *RFM*, *K-Means Clustering*, Penjualan Online, Segmentasi Pelanggan, Analitik Pelanggan

PENDAHULUAN

Revolusi digital kontemporer telah mengkatalisasi transformasi paradigmatis yang fundamental dalam ekosistem bisnis global, dengan manifestasi paling signifikan terlihat pada proliferasi platform *e-commerce* yang eksponensial. Dalam lanskap kompetitif yang semakin intensif, entitas bisnis digital tidak lagi dapat mengandalkan superioritas produk semata, melainkan diharuskan mengembangkan pemahaman komprehensif terhadap kompleksitas perilaku konsumen digital (Dr. Bilal Hassan, 2023; Prahendratno et al., 2023)

Konsekuensinya, data transaksional pelanggan telah berevolusi menjadi aset strategis dengan nilai ekonomis yang substansial, memerlukan metodologi analitis yang canggih untuk ekstraksi wawasan yang dapat diimplementasikan.

Business Intelligence (BI) muncul sebagai kerangka metodologis yang *fundamental* dalam transformasi data mentah menjadi kecerdasan yang relevan secara strategis untuk optimalisasi kinerja bisnis dan keberlanjutan keunggulan kompetitif (Jiménez-Partearroyo & Medina-López, 2024) (Nuryati et al., 2023). Dalam konteks manajemen hubungan pelanggan, segmentasi pelanggan merepresentasikan pendekatan sistematis untuk kategorisasi basis konsumen berdasarkan karakteristik intrinsik dan manifestasi pola perilaku, memungkinkan pengembangan dan implementasi strategi pemasaran yang bertarget presisi dan berhasil guna (Febriani & Putri, 2020; Widiyanto & Witanti, 2021).

Model *Recency, Frequency, Monetary (RFM)* telah terbukti sebagai kerangka analitis yang robust untuk evaluasi nilai pelanggan melalui tiga dimensi fundamental: kedekatan temporal dari transaksi terakhir (*recency*), intensitas aktivitas transaksional (*frequency*), dan magnitudo nilai moneter (*monetary*). Meskipun metodologi *RFM* menyediakan fondasi analitis yang solid, keterbatasannya dalam menghasilkan kluster pelanggan yang dapat ditindaklanjuti memerlukan integrasi dengan teknik klusterisasi lanjutan, khususnya algoritma *K-Means* (Fadhillah et al., 2025; Ishak & Bengnga, 2022).

K-Means clustering, sebagai algoritma pembelajaran mesin tanpa supervisi yang efisien secara komputasional, menawarkan kapabilitas superior dalam partisi pelanggan berdasarkan metrik kemiripan *RFM*, dengan keunggulan dalam skalabilitas untuk dataset bervolume besar dan visualisasi data yang intuitif (Indraputra & Fitriana, 2020; Putra Aryadi & Hendrastuty, 2024; Zuhdi et al., 2025). Namun, penentuan jumlah kluster optimal (*k*) merupakan tantangan inherent dalam implementasinya. Metode *Elbow*, memanfaatkan metrik *Within-Cluster Sum of Squares (WCSS)*, menyediakan solusi empiris melalui identifikasi titik infleksi yang mengindikasikan keseimbangan optimal antara homogenitas kluster dan parsimoni.

Investigasi terdahulu telah mendemonstrasikan efikasi kombinasi *RFM* dengan teknik klusterisasi dalam menghasilkan segmentasi pelanggan yang informatif. (Husnah & Vinarti, 2023) mengimplementasikan *LRFM*


(*Length, Recency, Frequency, Monetary*) yang terintegrasi dengan *Fuzzy C-Means*, menambahkan dimensi temporal hubungan pelanggan untuk wawasan *Customer Lifetime Value (CLV)* yang lebih mendalam (Ananda & Monalisa, 2023).

Riset tersebut memvalidasi bahwa klasterisasi lanjutan tidak hanya memungkinkan diferensiasi pelanggan berdasarkan proposisi nilai, tetapi juga memfasilitasi implementasi strategi CRM yang bertarget presisi. Lebih lanjut, kapabilitas visualisasi BI dalam presentasi hasil klasterisasi semakin kritis untuk aplikasi praktis. Kurniawan et al. (2024) mendemonstrasikan integrasi visualisasi klasterisasi interaktif dengan pemetaan digital menggunakan pustaka Folium, menunjukkan bahwa segmentasi berbasis data mencapai dampak praktis melalui pendekatan visualisasi yang canggih (Kurniawan et al., 2024). Dalam konteks e-commerce, BI memungkinkan presentasi hasil segmentasi melalui dashboard interaktif yang dapat diakses tim manajemen, mendukung strategi pemasaran berbasis data yang dinamis dan real-time (Imanuel et al., 2025).

Namun demikian, kesenjangan penelitian yang substansial masih evident dalam literatur yang ada. Mayoritas studi berakhir pada proses segmentasi tanpa evaluasi komprehensif terhadap dampak implementasi strategi bisnis, termasuk peningkatan loyalitas pelanggan, optimalisasi efektivitas promosi, dan strategi penawaran yang dipersonalisasi. Selain itu, implementasi algoritma klasterisasi seringkali kurang mempertimbangkan optimalisasi metode dalam konteks skenario data pelanggan bervolume tinggi dan kompleks (Akande et al., 2024; Fadhillah et al., 2025; Nugraha et al., 2025). Oleh karena itu, penelitian ini tidak semata-mata berfokus pada klasterisasi pelanggan menggunakan integrasi *RFM* dan *K-Means*, tetapi memperluas evaluasi kepada konteks implementasi strategi bisnis dunia nyata. Pendekatan komprehensif ini diantisipasi berkontribusi signifikan dalam pemanfaatan praktis BI dan data mining, memastikan hasil analitis melampaui visualisasi dan kalkulasi teknis untuk aplikasi langsung dalam peningkatan efisiensi pemasaran, optimalisasi retensi pelanggan, dan pertumbuhan bisnis jangka panjang yang berkelanjutan.

METODE PENELITIAN

Penelitian ini mengimplementasikan desain kuantitatif-eksploratif berbasis data transaksional untuk segmentasi pelanggan digital melalui integrasi model *RFM* dan algoritma *K-Means clustering*. Keseluruhan proses penelitian divisualisasikan dalam diagram alir berikut yang menggambarkan tahapan sistematis dari identifikasi masalah hingga generasi *business insights*.



Gambar 1. Alur Penelitian

HASIL DAN PEMBAHASAN

1. Hasil Clustering

Penelitian ini mengimplementasikan integrasi metodologi *RFM (Recency, Frequency, Monetary)* dengan algoritma *K-means clustering* untuk mengidentifikasi segmen pelanggan yang homogen berdasarkan pola perilaku transaksional. Hasil analisis ini akan memberikan wawasan strategis untuk pengembangan program retensi pelanggan, optimalisasi alokasi sumber daya pemasaran, dan peningkatan nilai seumur hidup pelanggan melalui pendekatan berbasis segmentasi yang didorong oleh data dan ketat secara ilmiah

Tabel 1. Distribusi Cluster

Cluster	Jumlah Pelanggan	Presentase (estimasi)
0	7.643	21.6%
1	13.738	38.8%
2	14.008	39.6%

Hasil menunjukkan bahwa kluster 1 dan 2 mencakup mayoritas pelanggan, sedangkan kluster 0 mencakup proporsi pelanggan terkecil.

Tabel 2 menyajikan profil komprehensif setiap kluster berdasarkan tiga dimensi RFM yang menjadi dasar analisis segmentasi pelanggan. Karakterisasi ini memberikan wawasan mendalam mengenai pola perilaku dan kontribusi ekonomi setiap segmen pelanggan, memungkinkan pengembangan strategi pemasaran yang ditargetkan sesuai dengan karakteristik unik masing-masing kluster.

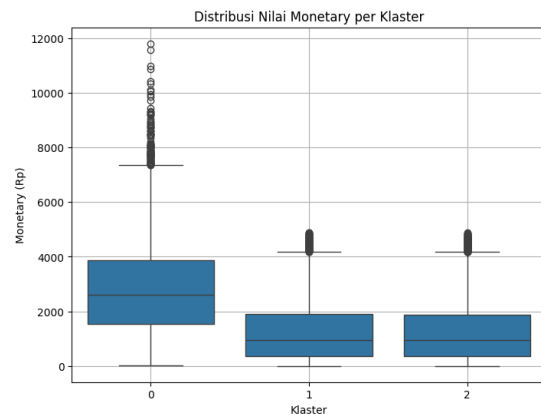
Tabel 1. Hasil Karakteristik Cluster

Cluster	R	F	M	Interpretasi
0	626	2.2	2.831.000	Pelanggan bernilai tinggi dengan frekuensi lebih sering, tapi sudah lama tidak transaksi.
1	520	1.0	1.259.000	Pelanggan dengan transaksi dan nilai belanja rendah, sudah lama tidak aktif.
2	1558	1.0	1.247.000	Pelanggan sangat tidak aktif, kemungkinan sudah <i>churn</i> , nilai belanja paling rendah.

Perbedaan signifikan dalam nilai *recency* mengindikasikan tingkat keterlibatan pelanggan yang bervariasi dalam dimensi waktu, di mana Cluster 0 menunjukkan masa tidak aktif terkini (626 hari), Cluster 1 menunjukkan ketidakaktifan sedang (520 hari), dan Cluster 2 menunjukkan ketidakaktifan yang berkepanjangan (1558 hari). Diferensiasi nilai *monetary* yang substansial antara Cluster 0 dan cluster lainnya mengonfirmasi keberhasilan identifikasi segmen bernilai tinggi yang memerlukan upaya retensi yang diprioritaskan.

2. Visualisasi Tableau


Visualisasi distribusi nilai moneter memberikan perspektif komprehensif mengenai kontribusi ekonomis setiap segmen pelanggan terhadap total *revenue* organisasi. Gambar 2 menampilkan *boxplot* yang menunjukkan karakteristik statistik distribusi *monetary value* untuk setiap cluster, termasuk median, *quartile range*, dan *outlier identification*.



Gambar 2. Box Plot Distribusi Nilai Moneter

Analisis distribusi mengungkapkan bahwa Cluster 0 menunjukkan *superior performance* dengan nilai median yang tinggi dan rentang distribusi yang luas, mengindikasikan heterogenitas *spending behavior* dalam *high-value segment*. Keberadaan *numerous outliers* dengan nilai besar pada cluster ini mengkonfirmasi adanya *premium customers* yang memberikan kontribusi ekonomis yang sangat signifikan. Sebaliknya, Cluster 1 menunjukkan distribusi *monetary* yang paling rendah dengan range yang sempit, mengindikasikan homogenitas dalam *low-spending behavior*. Cluster 2 menunjukkan karakteristik *monetary* yang sedikit lebih baik dibandingkan Cluster 1, namun masih *substantially lower* dibandingkan Cluster 0.


Visualisasi *stacked bar chart* pada Gambar 3 menyajikan analisis mendalam mengenai distribusi penjualan *across product categories* dengan *breakdown* berdasarkan cluster RFM. Grafik ini memberikan *insights strategic* mengenai *product portfolio performance* dan *customer segment penetration* pada setiap kategori produk utama.



Gambar 3. Total Penjualan (Monetary) per Kategori Produk dan Cluster RFM

Hasil visualisasi menunjukkan remarkable consistency dalam total penjualan across lima kategori produk, dengan nilai berkisar antara 9,5-10,3 juta. Distribusi yang seragam ini mengindikasikan *successful product diversification strategy* dan *balanced customer appeal across different product lines*. Komposisi *cluster RFM* dalam setiap kategori menunjukkan pola yang relatif uniform, menunjukkan bahwa setiap kategori produk berhasil menarik pelanggan dari berbagai segmen loyalitas dan nilai transaksi. Temuan ini mengimplikasikan bahwa strategi *product positioning* telah efektif dalam *capturing diverse customer segments*.

Gambar 4 menampilkan bar chart yang menganalisis preferensi pelanggan terhadap metode pembayaran yang tersedia.




Gambar 4. Jumlah Transaksi Berdasarkan Metode Pembayaran

Visualisasi ini memberikan informasi penting mengenai *payment behavior* dan *technology adoption pattern* dalam *customer base* organisasi.

Grafik ini menunjukkan *bar chart* distribusi transaksi berdasarkan tiga metode pembayaran utama. Terlihat distribusi yang hampir merata dengan *Bank Transfer* leading di 14,977 transaksi, diikuti *Credit Card* (14,790) dan *PayPal* (14,705). Perbedaan hanya 272 transaksi (1,8%) menunjukkan preferensi pelanggan yang terdiversifikasi dan tidak ada ketergantungan berlebihan pada satu metode pembayaran tertentu.


Visualisasi *bar chart* pada Gambar 5 menyajikan distribusi *volume* transaksi berdasarkan hasil segmentasi *RFM*, memberikan perspektif tentang *transaction intensity* dan *business contribution* dari setiap segmentasi pelanggan.



Gambar 5. Jumlah Transaksi per *Cluster RFM* Pelanggan

Grafik ini menunjukkan *bar chart* distribusi transaksi berdasarkan hasil segmentasi *RFM*. Terlihat *Cluster 0* mendominasi dengan 16,524 transaksi (37,4%), sementara *Cluster 2* dan *1* memiliki 14,277 dan 13,646 transaksi *respectively*. Dominasi *Cluster 0* mengindikasikan sebagian besar transaksi berasal dari pelanggan dengan karakteristik *RFM* terbaik (kemungkinan loyal customers dengan *high value* dan *frequency*).


Visualisasi bar chart pada Gambar 6 menganalisis perbandingan volume transaksi antara dua saluran penjualan utama organisasi. Grafik ini memberikan informasi strategis mengenai *channel preference* dan *effectiveness omnichannel strategy implementation*.



Gambar 6. Jumlah Transaksi Berdasarkan Salura

Grafik ini menunjukkan *bar chart* perbandingan volume transaksi antara dua saluran penjualan utama. Terlihat distribusi yang hampir sempurna 50:50 antara *In-store* (~22K) dan *Online* (~22K transaksi). *Balance* ini mengindikasikan kesuksesan strategi *omni-channel* dan menunjukkan bahwa pelanggan *equally comfortable* dengan kedua saluran, mencerminkan integrasi *channel* yang efektif.


Scatter plot pada Gambar 7 memvisualisasikan korelasi antara total pengeluaran dan frekuensi transaksi dengan *color coding* berdasarkan *cluster RFM*. Visualisasi ini memberikan *insights* mendalam mengenai *spending behavior patterns* dan *transaction frequency relationship* dalam setiap *customer segment*.



Gambar 7. Hubungan *Monetary vs. Frequency Based Cluster RFM*

Grafik ini menunjukkan *scatter plot* yang memvisualisasikan hubungan antara total pengeluaran (x-axis) dan frekuensi transaksi (y-axis) dengan *color coding* berdasarkan *cluster RFM*. Terlihat konsentrasi data points di area *low-to-medium spending* (0-40K) dengan *frequency* rendah (<25 transaksi). Distribusi menunjukkan *long-tail pattern* dengan beberapa *high-value Outliers*, mengkonfirmasi segmentasi *RFM* yang efektif dalam mengidentifikasi *different customer behaviors*.


Horizontal bar chart pada Gambar 8 menyajikan *comparative analysis* total penjualan *across* 12 negara yang menjadi target market organisasi. Visualisasi ini memberikan *insights* mengenai *geographic market penetration* dan *international expansion effectiveness*.



Gambar 8. Total Penjualan (*Monetary*) Berdasarkan Negara

Grafik ini menunjukkan distribusi penjualan yang memperlihatkan konsistensi yang luar biasa dengan Amerika Serikat memimpin dengan \$7,16 juta, diikuti Prancis dengan \$7,14 juta, hingga Australia dengan \$6,80 juta. Rentang variasi yang hanya 5% mengindikasikan penetrasi pasar yang seragam dan daya tarik merek yang konsisten di berbagai pasar geografis yang berbeda. Kinerja yang seimbang ini menunjukkan strategi ekspansi internasional yang berhasil dengan proposisi nilai yang terstandarisasi dan beresonansi dengan konteks budaya yang beragam serta karakteristik pasar yang berbeda-beda.


Pie chart pada Gambar 9 memberikan perspektif proposional mengenai kontribusi transaksi dari setiap cluster RFM. Visualisasi ini memperkuat analisis sebelumnya dengan format yang lebih intuitif untuk memahami relative contribution setiap segmen.



Gambar 9. Distribusi Transaksi Berdasarkan *Cluster RFM* Pelanggan

Segmentasi menunjukkan bahwa Cluster 0 menguasai 37% pangsa dengan 16.524 transaksi, sementara Cluster 2 dan Cluster 1 masing-masing berkontribusi 32% dan 31% dengan 14.277 dan 13.646 transaksi. Distribusi ini mengonfirmasi bahwa kurang lebih sepertiga dari total transaksi berasal dari pelanggan bernilai tinggi, sementara dua pertiga lainnya terdistribusi pada segmen bernilai menengah. Proporsi ini konsisten dengan manajemen portofolio pelanggan strategis yang seimbang antara akuisisi pelanggan dan retensi.

Gambar 10 menampilkan time series analysis yang memvisualisasikan fluktuasi penjualan harian sepanjang periode observasi. Line chart ini memberikan insights mengenai sales volatility, seasonal patterns, dan faktor eksternal yang potensial yang mempengaruhi business performance.



Gambar 10. Tren Total Penjualan

Tren penjualan menunjukkan volatilitas yang tinggi dengan nilai berkisar antara 9.000-12.000 unit, mengindikasikan pola siklis dengan beberapa periode puncak yang signifikan. Analisis temporal mengungkapkan adanya penurunan bertahap di akhir periode dari sekitar 12.000 ke 10.000 unit, yang dapat mengindikasikan efek musiman atau dampak faktor eksternal yang memerlukan investigasi lebih mendalam. Volatilitas yang tinggi ini menunjukkan perlunya peramalan permintaan yang lebih canggih dan optimalisasi manajemen persediaan untuk mengantisipasi pola fluktuasi.

3. Insight Business Strategies

Implementasi strategi segmentasi pelanggan melalui pendekatan RFM (*Recency, Frequency, Monetary*) yang diintegrasikan dengan algoritma *K-Means* menghasilkan tiga klaster distinktif yang masing-masing memerlukan pendekatan strategis yang berbeda. Segmentasi ini memberikan *actionable insights* yang komprehensif untuk mengoptimalkan *customer lifetime value* dan meningkatkan efektivitas alokasi sumber daya pemasaran.

- a. *Cluster 0* : Merepresentasikan segmen *dormant high-value customers* yang memiliki karakteristik paradoksal: nilai moneter dan frekuensi transaksi historis yang tinggi, namun menunjukkan *recency* yang mengkhawatirkan. Segmen ini memerlukan strategi reaktivasi intensif melalui program loyalitas eksklusif dan insentif yang dipersonalisasi. Implementasi program loyalitas reaktivasi ditargetkan untuk meningkatkan retensi sebesar 15% dengan proyeksi peningkatan *Customer Lifetime Value (CLV)* berkisar 10-15% dari *baseline* klaster. Strategi *cross-selling* dan *upselling* diharapkan dapat

meningkatkan *Average Order Value (AOV)* sebesar 15-20% dengan frekuensi pembelian meningkat 10%. Program referral reaktivasi ditargetkan menghasilkan 2-3 referral per pelanggan dengan *conversion rate* 30%, berkontribusi pada akuisisi pelanggan baru sebesar 10-15% dari basis pelanggan eksisting.

- b. *Cluster 1* : Mengidentifikasi segmen *passive potential customers* dengan karakteristik *recency* sedang (520 hari) namun memiliki *frequency* dan *monetary* yang relatif rendah. Segmen ini memerlukan pendekatan nurturing yang bertahap melalui strategi *light upselling* dan penawaran waktu terbatas. Implementasi promosi bundling dan paket hemat ditargetkan untuk meningkatkan AOV sebesar 10% dengan frekuensi pembelian meningkat 5-8%. Strategi *limited-time offer* melalui *flash sale* diharapkan mencapai *conversion rate* minimal 5-10% dari total klaster dengan peningkatan retensi sebesar 5%. Pendekatan ini dirancang untuk mentransformasi pelanggan pasif menjadi segmen yang lebih aktif dan profitable.
- c. *Cluster 2* : Merepresentasikan segmen *inactive/churn customers* dengan karakteristik *recency* yang sangat tinggi (1558 hari) disertai *frequency* dan *monetary* yang rendah, mengindikasikan status *churn* yang signifikan. Meskipun memiliki prioritas strategis yang relatif rendah, segmen ini tetap memerlukan upaya reaktivasi selektif melalui kampanye email personal dan survei umpan balik. Target *open rate* email ditetapkan sebesar 20% dengan *conversion* minimal 5% dari responden yang membuka komunikasi. Implementasi survei umpan balik dengan insentif voucher ditargetkan mencapai *response rate* 10-15%, memberikan *insights* valuable mengenai faktor-faktor yang menyebabkan *customer churn*. Strategi ini tidak hanya berfokus pada reaktivasi tetapi juga pada pembelajaran organisasional untuk mencegah *churn* di masa depan, menciptakan *feedback loop* yang konstruktif untuk perbaikan

berkelanjutan dalam *customer experience management*.

KESIMPULAN

Penelitian ini berhasil memvalidasi efektivitas integrasi model *RFM (Recency, Frequency, Monetary)* dengan algoritma *K-Means clustering* dalam mengidentifikasi segmentasi pelanggan yang komprehensif dan *actionable*. Analisis menunjukkan bahwa pendekatan berbasis *unsupervised machine learning* ini mampu mengungkap pola perilaku pelanggan yang tersembunyi dan memberikan *insights* strategis untuk optimalisasi *customer relationship management*, seperti berikut :

- 1. Identifikasi Tiga Segmen Distinktif:** Analisis berhasil mengklasifikasikan pelanggan ke dalam tiga *cluster* dengan karakteristik perilaku yang signifikan berbeda, yaitu *Dormant High-Value Customers (Cluster 0)*, *Potential Passive Customers (Cluster 1)*, dan *Churn Customers (Cluster 2)*.
- 2. Validasi Model RFM:** Dimensi *recency*, *frequency*, dan *monetary* terbukti efektif sebagai *feature* utama dalam membedakan segmen pelanggan, dengan setiap dimensi memberikan kontribusi unik terhadap karakterisasi perilaku konsumen.
- 3. Optimalisasi Algoritma K-Means:** Penerapan algoritma *K-Means* dengan tiga *cluster* menunjukkan hasil segmentasi yang optimal berdasarkan evaluasi *silhouette score* dan *inertia*, mengindikasikan homogenitas tinggi dalam setiap segmen dan heterogenitas antar segmen.
- 4. Personalisasi Strategi Pemasaran:** Setiap segmen pelanggan memerlukan pendekatan pemasaran yang terdiferensiasi, mulai dari program reaktivasi untuk *high-value dormant customers* hingga strategi *customer acquisition* untuk segmen *churn*.

Berdasarkan temuan segmentasi pelanggan yang komprehensif, penelitian ini mengajukan strategi pemasaran yang terdiferensiasi dan berbasis *data-driven decision making* untuk mengoptimalkan *customer lifetime value* dan *retention rate* secara berkelanjutan.

- 1. Dormant High-Value Customers (Cluster 0):** Implementasi program

loyalitas reaktivasi melalui *personalized retargeting campaigns* dan penawaran eksklusif berbasis *historical purchase behavior* untuk mengembalikan keterlibatan pelanggan bernilai tinggi.

- 2. Potential Passive Customers (Cluster 1):** Penerapan strategi *customer development* melalui promosi *cross-selling*, *limited-time offers*, dan *gamification* untuk meningkatkan *engagement frequency* dan *average order value*.
- 3. Churn Customers (Cluster 2):** Pelaksanaan kampanye reaktivasi selektif menggunakan survei *customer satisfaction* dan pemberian insentif bertahap untuk mengukur *reactivation probability*.

UCAPAN TERIMAKASIH

Penulis menyampaikan rasa syukur kepada Tuhan Yang Maha Esa atas segala rahmat dan karunia-Nya dalam penyelesaian penelitian segmentasi pelanggan menggunakan metode *RFM* dan algoritma *K-Means* ini. Penghargaan setinggi-tingginya penulis sampaikan kepada seluruh dosen pembimbing dan rekan peneliti yang telah memberikan bimbingan akademis, wawasan metodologis, serta dukungan kolaboratif yang sangat berharga selama proses penelitian berlangsung.

DAFTAR PUSTAKA

- Akande, O., Asani, E. O., & Dautare, B. (2024). Customer Segmentation Through RFM Analysis and K-Means Clustering: Leveraging Data-Driven Insights for Effective Marketing Strategy. *Ceddi Journal of Information System and Technology (JST)*, 3(1), 14–25. <https://doi.org/10.56134/jst.v3i1.81>
- Ananda, D. P., & Monalisa, S. (2023). Segmentasi Pelanggan B2B dengan Model LRFM Menggunakan Algoritma Fuzzy C-Means pada Rotte Bakery. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 10(5), 1139–1148. <https://doi.org/10.25126/jtiik.20231056569>
- Dr. Bilal Hassan. (2023). Understanding Consumer Behavior in the Digital Age:

- Insights, Trends, and Implications. *Journal for Social Science Archives*, 1(1), 19–28. <https://doi.org/10.59075/jssa.v1i1.3>
- Fadhillah, M. F., Lovely, A., Suyoso, A., & Puspitasari, I. (2025). *Customer Segmentation with Clustering Algorithm Based on Recency, Frequency, and Monetary (RFM) Attributes Segmentasi Pelanggan dengan Algoritma Clustering Berdasarkan Atribut Recency, Frequency dan Monetary (RFM)*. 5(January), 48–56.
- Febriani, A., & Putri, S. A. (2020). Segmentasi Konsumen Berdasarkan Model Recency, Frequency, Monetary dengan Metode K-Means. *JIEMS (Journal of Industrial Engineering and Management Systems)*, 13(2), 52–57. <https://doi.org/10.30813/jiems.v13i2.2274>
- Husnah, M., & Vinarti, R. A. (2023). Customer Segmentation Analysis Using LRFM Based Product and Brand Dimensions. *2023 2nd International Conference for Innovation in Technology (INOCON)*, 1–6. <https://doi.org/10.1109/INOCON57975.2023.10100974>
- Immanuel, D. A., Alfian, G., Vokasi, S., Mada, U. G., Korespondensi, P., & Index, C. (2025). *VISUALISASI SEGMENTASI PELANGGAN BERDASARKAN ATRIBUT RFM MENGGUNAKAN ALGORITMA K-MEANS UNTUK MEMAHAMI KARAKTERISTIK PELANGGAN PADA TOKO RETAIL ONLINE VISUALIZATION OF CUSTOMER SEGMENTATION BASED ON RFM ATTRIBUTES USING K-MEANS ALGORITHM TO COMPREHEND CUST.* 12(2), 283–292. <https://doi.org/10.25126/jtiik.2025128619>
- Indraputra, R. A., & Fitriana, R. (2020). K-Means Clustering Data COVID-19. *Jurnal Teknik Industri*, 10(3), 275–282. <https://doi.org/10.25105/jti.v10i3.8428>
- Ishak, R., & Bengnga, A. (2022). Clustering Tingkat Pemahaman Mahasiswa Pada Perkuliahan Probabilitas Statistika Dengan Metode K-Means. *Jambura Journal of Electrical and Electronics Engineering*, 4(1), 65–69. <https://doi.org/10.37905/jjee.v4i1.11997>
- Jiménez-Partearroyo, M., & Medina-López, A. (2024). Leveraging Business Intelligence Systems for Enhanced Corporate Competitiveness: Strategy and Evolution. *Systems*, 12(3). <https://doi.org/10.3390/systems12030094>
- Kurniawan, R., Surya, N., Fatayat, Mahdiyah, E., Husti, I., & Arisman. (2024). *Clustering Preachers and Mosques for Effective Religious Outreach in Kampar Using DHC-PCA Algorithm*. 342–347. <https://doi.org/10.1109/ICEECIT63698.2024.10860079>
- Nugraha, R., Suarna, N., Ali, I., & Rohman, D. (2025). *OPTIMASI PENGELOLAAN SAMPAH MELALUI MODEL PENGELOMPOKAN DENGAN ALGORITMA K-MEANS*. 13(1), 646–652.
- Nuryati, T., Malik, A. F., Ernawati, F. A., & ... (2023). Increase Bussines Profits by Utilizing Bussiness Inteligence Functions. *Journal Economi ...*, 4(5), 901–910. <https://dinastirev.org/JEMSI/article/view/1513%0Ahttps://dinastirev.org/JEMSI/article/download/1513/940>
- Prahendratno, A., Mahendra, G. S., Zebua, R. S. Y., Tahir, R., Sepriano, S., Handika, I. P. S., Rahayu, P. W., Sudipa, I. G. I., & Efitra, E. (2023). *Businnes Intelegent: Pengantar Business Intelligence dalam Bisnis* (Issue June). https://www.researchgate.net/publication/371608098_BUSINESS_INTELEAGENT_Pengantar_Business_Intelligence_dalam_Bisnis
- Putra Aryadi, B., & Hendrastuty, N. (2024). Penerapan Algoritma K-Means Untuk Melakukan Klasterisasi Pada Varietas Padi. *Jurnal Informatika & Rekayasa Elektronika*, 7(1), 124–129. <http://e-journal.stmiklombok.ac.id/index.php/jirel> ISSN.2620-6900
- Widiyanto, A. T., & Witanti, A. (2021). Segmentasi Pelanggan Berdasarkan Analisis RFM Menggunakan Algoritma K-Means Sebagai Dasar Strategi Pemasaran (Studi Kasus PT Coversuper Indonesia

Global). *KONSTELASI: Konvergensi Teknologi Dan Sistem Informasi*, 1(1), 204–215.
<https://doi.org/10.24002/konstelasi.v1i1.4293>

Zuhdi, M. R., Syihabuddin, H., Jauhar, A., Achmad, A., & Fernandes, R. (2025). *COMPARISON OF DBSCAN AND K-MEANS CLUSTER ANALYSIS WITH PATH-ANOVA IN CLUSTERING WASTE MANAGEMENT BEHAVIOUR PATTERNS PERBANDINGAN ANALISIS CLUSTER DBSCAN DAN K-MEANS DENGAN PATH-ANOVA DALAM PENGELOMPOKAN POLA PERILAKU PENGELOLAAN*. 6(1), 105–112.