

RFM-Based Customer Segmentation Using K-Means Clustering for Marketing Strategy Optimization at Queen Audio

Bahar Al Hamid^{1*}, Trianggoro Wiradinata^{2*}

* School of Information Technology, Universitas Ciputra Surabaya
balhamid@student.ciputra.ac.id¹ twiradinata@ciputra.ac.id²

Article Info

Article history:

Received 2026-01-19

Revised 2026-03-03

Accepted 2026-04-08

Keywords:

Customer Segmentation,
RFM Model,
K-Means Clustering,
Marketing Strategy Optimization,
Retail Analytics.

ABSTRACT

Queen Audio, a musical instrument retailer, has recently faced declining sales performance leading to excess inventory. To address this issue, this study aims to optimize marketing strategies through customer segmentation based on transaction behavior. The research applies the Recency, Frequency, and Monetary (RFM) model combined with the K-Means clustering algorithm to classify customers according to purchasing patterns. The optimal number of clusters was determined using the Within-Cluster Sum of Squares (WSS) and Silhouette Score evaluation metrics. The dataset consists of 3,200 transaction records from 2,637 customers collected between July and September 2025. The results indicate that two clusters provide the optimal segmentation structure with a Silhouette Score of 0.513, indicating reasonably well-defined clusters. The analysis reveals a distinct high-value customer segment characterized by higher transaction frequency and monetary value compared to the moderate-value segment. These findings provide practical insights for implementing differentiated marketing strategies, including targeted promotions, customer retention programs, and personalized offers to improve sales performance and inventory management. This study contributes to data-driven marketing decision-making by demonstrating the effectiveness of integrating RFM analysis with K-Means clustering in the retail musical instrument industry.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

I. PENDAHULUAN

Di tengah persaingan industri musik yang kian ketat, setiap perusahaan perlu mengembangkan strategi pemasaran yang responsif serta didukung oleh analisis data yang akurat. Queen Audio, sebagai perusahaan yang bergerak dalam penjualan alat musik, saat ini mengalami tantangan berupa menurunnya realisasi target penjualan. Kondisi tersebut berimbas pada meningkatnya jumlah persediaan produk yang tertahan di gudang. Kondisi ini tidak hanya memengaruhi kinerja finansial perusahaan, tetapi juga menurunkan efisiensi operasional. Oleh karena itu, diperlukan pendekatan strategis yang mampu mengoptimalkan alokasi sumber daya dan meningkatkan efektivitas pemasaran secara terarah.

Salah satu pendekatan yang dapat diterapkan adalah pemanfaatan data transaksi pelanggan sebagai dasar pengambilan keputusan pemasaran. Pelanggan merupakan aset penting dalam bisnis, sehingga pemahaman terhadap perilaku pembelian pelanggan menjadi faktor kunci dalam

meningkatkan loyalitas dan kinerja penjualan. Melalui pengelolaan data transaksi, perusahaan dapat mengidentifikasi kelompok pelanggan berdasarkan tingkat loyalitas dan pola pembelian. Segmentasi pelanggan adalah pendekatan yang lazim diterapkan untuk mengelompokkan konsumen berdasarkan kesamaan karakteristik maupun pola perilaku tertentu [1],[2]. Melalui penerapan segmentasi yang akurat, perusahaan dapat menyusun strategi pemasaran yang lebih terarah sehingga penggunaan sumber daya menjadi lebih optimal dan hasil yang dicapai lebih maksimal.

Pada penelitian ini, perilaku pelanggan dianalisis menggunakan pendekatan Recency, Frequency, dan Monetary (RFM). Metode RFM merupakan salah satu teknik dalam analisis pemasaran yang mengklasifikasikan pelanggan berdasarkan tiga indikator utama, yaitu jarak waktu sejak transaksi terakhir (Recency), tingkat intensitas transaksi (Frequency), serta total nilai pembelian yang dilakukan pelanggan (Monetary) [3]. Pendekatan ini memungkinkan perusahaan memperoleh pemahaman yang

sistematis mengenai kontribusi dan nilai setiap pelanggan, sekaligus memudahkan identifikasi pelanggan potensial maupun pelanggan dengan tingkat partisipasi yang rendah.

Untuk mengelompokkan pelanggan berdasarkan parameter RFM tersebut, penelitian ini menerapkan algoritma K-Means Clustering. K-Means termasuk metode pengelompokan non-hierarkis yang mempartisi data ke dalam beberapa cluster berdasarkan tingkat kemiripan atau kedekatan antar data [4]. Prosesnya diawali dengan penentuan pusat cluster (centroid) secara acak, kemudian setiap data dialokasikan ke centroid terdekat. Tahapan ini dilakukan secara berulang hingga komposisi cluster tidak lagi mengalami perubahan atau telah mencapai kondisi konvergen [5].

K-Means banyak digunakan dalam penelitian segmentasi pelanggan karena efisiensi komputasi dan kemudahannya dalam interpretasi hasil [6]. Namun demikian, keberhasilan metode ini sangat dipengaruhi oleh pemilihan jumlah cluster yang optimal. Oleh karena itu, penelitian ini menggunakan Silhouette Score untuk mengevaluasi kualitas pengelompokan dan menentukan jumlah cluster terbaik [7].


Dalam konteks industri alat musik, penerapan RFM dan K-Means memiliki relevansi yang signifikan. Produk alat musik umumnya memiliki harga relatif tinggi dan siklus pembelian yang lebih panjang dibandingkan produk konsumsi cepat. Karakteristik ini menyebabkan pola transaksi pelanggan berbeda dari sektor ritel pada umumnya. Dengan segmentasi yang tepat, perusahaan dapat mengidentifikasi kelompok pelanggan dengan pola pembelian yang berbeda, sehingga strategi promosi dapat disesuaikan, seperti penawaran eksklusif untuk pelanggan premium maupun promosi khusus untuk pelanggan dengan frekuensi rendah.

Meskipun metode RFM dan K-Means telah banyak diterapkan di sektor ritel dan e-commerce, penerapannya pada industri alat musik masih relatif terbatas. Penelitian ini mengisi celah tersebut dengan mengimplementasikan segmentasi pelanggan berbasis RFM menggunakan K-Means pada industri alat musik. Selain itu, penelitian ini mengintegrasikan evaluasi Silhouette Score untuk memastikan penentuan jumlah cluster yang optimal sehingga meningkatkan akurasi segmentasi dan efektivitas rekomendasi strategi pemasaran.

Urgensi penelitian ini didasarkan pada kondisi nyata yang dihadapi Queen Audio, yaitu penurunan penjualan dan penumpukan persediaan. Dengan segmentasi pelanggan yang lebih terstruktur, perusahaan diharapkan dapat meningkatkan efisiensi pemasaran, mengurangi risiko kelebihan stok, serta meningkatkan kepuasan pelanggan melalui strategi promosi yang lebih personal dan relevan. Secara akademik, penelitian ini memberikan kontribusi dalam pengembangan penerapan metode RFM dan K-Means pada konteks industri dengan karakteristik pembelian bernilai tinggi dan frekuensi rendah.

II. METODE PENELITIAN

Penelitian ini mengadopsi metodologi CRISP-DM [8]. Tahap *deployment* tidak dilakukan dalam penelitian ini karena fokus penelitian dibatasi hingga tahap evaluasi model dan interpretasi hasil segmentasi pelanggan. Alur penelitian yang diterapkan berdasarkan tahapan CRISP-DM ditunjukkan pada Gambar 1.



Gambar 1. Alur penelitian berdasarkan metode CRISP-DM

A. Business Understanding

Queen Audio merupakan perusahaan yang bergerak di industri penjualan alat musik yang menyediakan berbagai produk seperti gitar, keyboard, drum, dan perlengkapan musik lainnya bagi berbagai kalangan, mulai dari pemula hingga profesional. Proses bisnis perusahaan mencakup transaksi pembelian yang dilakukan melalui toko fisik maupun platform daring. Transaksi dinyatakan berhasil apabila pembayaran telah diterima, sedangkan transaksi yang gagal atau melewati batas waktu pembayaran akan dibatalkan secara otomatis oleh sistem.

Dalam upaya meningkatkan penjualan, perusahaan telah menerapkan berbagai strategi promosi seperti diskon produk, bundling, dan pemberian voucher potongan harga. Namun demikian, promosi yang dilakukan belum sepenuhnya berbasis pada karakteristik pelanggan sehingga belum optimal dalam menjangkau segmen pasar yang tepat. Kondisi tersebut berdampak pada penurunan performa penjualan serta penumpukan stok barang.

B. Data Understanding

Data yang digunakan adalah transaksi pelanggan Queen Audio yang diperoleh dari sistem basis data internal perusahaan. Dataset mencakup transaksi yang berhasil dilakukan dalam periode 8 Juli 2025 hingga 11 September 2025. Secara keseluruhan, data terdiri dari 2.637 pelanggan dengan total 3.200 transaksi dan memuat 16 atribut.

Atribut yang tersedia mencakup informasi seperti identitas unik pelanggan dan transaksi, tanggal transaksi, kategori produk, harga, diskon, kuantitas, metode pembayaran, total pembayaran, biaya pengiriman, keuntungan, usia pelanggan, serta jenis kelamin. Namun, tidak seluruh atribut digunakan dalam proses segmentasi. Penelitian ini berfokus pada atribut

yang relevan dengan pendekatan RFM. Rincian atribut utama yang digunakan dalam analisis ditampilkan pada Tabel 1.

TABEL 1. ATRIBUT DATASET

Nama Atribut	Deskripsi
customer_id	Id unik pelanggan
trans_id	Id unik transaksi
order_date	Tanggal transaksi
total_amount	Jumlah total pembayaran

C. Data Preparation

Pada tahap ini dilakukan pembersihan data dengan menghapus data duplikasi berdasarkan *trans_id* serta memastikan bahwa hanya transaksi dengan status berhasil yang digunakan dalam analisis. Selain itu, dilakukan pengecekan terhadap nilai yang tidak valid atau kosong untuk menjaga integritas dataset. Penyesuaian tipe data dilakukan pada atribut *order_date* dengan mengonversinya ke dalam format *datetime* agar dapat digunakan dalam perhitungan nilai *Recency*. Selanjutnya, dilakukan proses perhitungan atribut RFM. Sementara itu, nilai *Recency* dari jumlah transaksi dan nilai *Monetary* dihitung dari total akumulasi *total_amount* yang dibayarkan oleh masing-masing pelanggan. Untuk menjaga privasi pelanggan, atribut sensitif seperti *customer_id* dan *trans_id* disamarkan.

D. Modeling

Pada implementasinya, jumlah iterasi maksimum ditetapkan sebanyak 300 (*max_iter = 300*) untuk memastikan proses konvergensi tercapai. Untuk meminimalkan pengaruh inisialisasi centroid secara acak yang dapat menghasilkan variasi hasil clustering [9],[10], digunakan parameter *n_init* untuk melakukan beberapa kali inisialisasi dan memilih hasil terbaik.

E. Evaluation

Masing-masing cluster dikategorikan ke dalam tiga tingkat, yaitu rendah (*low*), sedang (*medium*), dan tinggi (*high*), berdasarkan nilai rata-rata setiap fitur dalam cluster. Kategori ditentukan menggunakan pendekatan kuartil, di mana nilai rata-rata di bawah kuartil pertama dikategorikan sebagai rendah, nilai antara kuartil pertama dan ketiga sebagai sedang, dan nilai di atas kuartil ketiga sebagai tinggi. Pendekatan ini memberikan dasar kuantitatif dalam menginterpretasikan karakteristik masing-masing segmen pelanggan dan mendukung perumusan strategi pemasaran yang lebih tepat sasaran.

III. HASIL DAN PEMBAHASAN

A. Pra-pemrosesan Data

Dataset awal terdiri dari 3.200 transaksi yang kemudian diolah untuk menghasilkan tiga fitur utama dalam model RFM, yaitu *recency*, *frequency*, dan *monetary*. Fitur *customer_id* tetap dipertahankan sebagai *unique identifier* dan tidak dilibatkan dalam proses perhitungan jarak

clustering. Nilai *recency* dihitung berdasarkan selisih antara tanggal referensi penelitian dengan tanggal transaksi terakhir pelanggan. Setelah fitur RFM diperoleh, dilakukan normalisasi menggunakan metode Z-Score sebagaimana dirumuskan dalam Persamaan (1) [10].

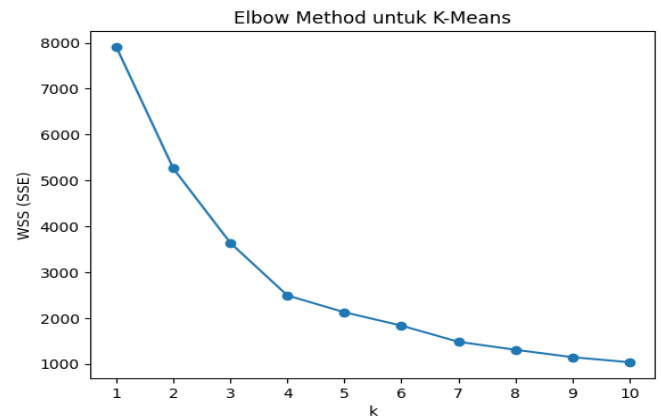
TABEL 2. FITUR SETELAH DINORMALISASI

customer_id	recency	frequency	monetary
C16933	-0.149228	-0.441450	1.731964
C14131	-0.946786	-0.441450	-0.498736
C13072	1.233205	-0.441450	-0.265536
C16573	0.967352	-0.441450	0.028732

Tanpa normalisasi, atribut dengan skala besar dapat mendominasi perhitungan jarak Euclidean dalam K-Means. Hasil normalisasi yang ditampilkan pada Tabel 2 menunjukkan bahwa ketiga fitur telah memiliki distribusi dengan rata-rata mendekati nol.

B. Analisis Jumlah Cluster

Gambar 2 terlihat bahwa pada k=1 nilai WSS sangat tinggi, mendekati 8.000, yang menunjukkan bahwa seluruh data berada dalam satu kelompok besar dengan variasi internal yang tinggi. Ketika jumlah cluster ditingkatkan menjadi k=2, terjadi penurunan WSS yang sangat signifikan hingga sekitar 5.260. Penurunan tajam ini mengindikasikan bahwa pembagian menjadi dua kelompok telah mampu mengurangi variasi dalam cluster secara substansial.



Gambar 2. Elbow Method untuk K-Means

Setelah k=2, penurunan nilai WSS masih terjadi namun dengan laju yang semakin landai. Misalnya, dari k=2 ke k=3 penurunan cukup besar, namun setelah k=4 hingga k=10, penurunan menjadi relatif kecil dan cenderung linear. Pola ini membentuk titik siku (*elbow*) yang paling jelas pada k=2. Dengan demikian, berdasarkan interpretasi visual pada Gambar 2, jumlah cluster optimal secara struktural adalah dua cluster. Selain menggunakan Elbow Method, evaluasi juga dilakukan menggunakan Silhouette Score sebagaimana dirumuskan [11]. Nilai Silhouette untuk masing-masing k ditampilkan pada Tabel 3.


TABEL 3.
SILHOUETTE SCORE

k	wss	silhouette score
2	5260.402992	0.513607
3	3638.526445	0.451379
4	2493.092295	0.484432
5	2126.262603	0.497835
6	1834.793696	0.501728
7	1482.333578	0.442470
8	1307.906531	0.452400
9	1146.540251	0.448718
10	1036.206309	0.459750

Nilai Silhouette untuk $k > 2$ tidak menunjukkan peningkatan signifikan dan cenderung lebih rendah, sehingga memperkuat keputusan bahwa $k=2$ merupakan konfigurasi terbaik.

C. Hasil Clustering

Proses clustering dilakukan menggunakan algoritma K-Means dengan parameter $n_{init} = 3$ dan $max_{iter} = 300$. Berdasarkan hasil evaluasi sebelumnya, jumlah cluster ditetapkan sebanyak dua cluster. Visualisasi hasil clustering setelah reduksi dimensi menggunakan PCA ditampilkan pada Gambar 3. Grafik tersebut memperlihatkan distribusi data dalam dua komponen utama hasil transformasi PCA. Pada sumbu horizontal (1st Principal Component) dan vertikal (2nd Principal Component), terlihat dua kelompok data yang relatif terpisah.



Gambar 3. Visualisasi Cluster PCA

Cluster pertama terlihat lebih padat dan terkonsentrasi pada area tertentu dengan sebaran yang relatif kompak. Hal ini menunjukkan bahwa pelanggan dalam cluster tersebut memiliki karakteristik RFM yang relatif homogen. Sementara itu, cluster kedua memiliki persebaran yang lebih luas dan menyebar pada area komponen utama yang berbeda, yang menunjukkan adanya variasi nilai RFM yang lebih tinggi dalam cluster tersebut. Pemisahan visual yang cukup jelas antara kedua cluster pada Gambar 3 menunjukkan

bahwa hasil segmentasi tidak mengalami tumpang tindih signifikan. Hal ini konsisten dengan nilai Silhouette Score yang berada di atas 0,5, sehingga dapat disimpulkan bahwa model K-Means berhasil membentuk dua kelompok pelanggan yang terpisah secara struktural dan bermakna.

D. Pola dan Interpretasi Tiap Cluster

Karakteristik masing-masing cluster ditampilkan pada Tabel 4. Interpretasi dilakukan berdasarkan nilai rata-rata RFM dan kategorisasi kuartil (low, medium, high).

TABEL 4.
KARAKTERISTIK RFM UNTUK TIAP CLUSTER

cluster	recency	frequency	monetary
0	Medium (33,19)	Medium (1,00)	Medium (2.328.029,1443)
1	Medium (20,83)	High (2,11)	High (7.558.658,6248)

Cluster 0 menunjukkan nilai recency sebesar 33,19 yang berada pada kategori medium. Nilai ini mengindikasikan bahwa pelanggan dalam cluster ini tidak melakukan transaksi dalam waktu yang sangat dekat, namun juga tidak terlalu lama tidak bertransaksi. Nilai frequency sebesar 1,00 menunjukkan frekuensi pembelian yang relatif rendah hingga sedang. Nilai monetary sebesar 2.328.029 berada pada kategori medium, yang menunjukkan kontribusi pendapatan yang cukup, namun bukan yang tertinggi.

Sebaliknya, Cluster 1 menunjukkan recency sebesar 20,83, yang berarti pelanggan dalam cluster ini melakukan transaksi dalam waktu yang lebih dekat dibanding cluster 0. Nilai frequency sebesar 2,11 berada dalam kategori high, menunjukkan bahwa pelanggan dalam cluster ini lebih sering melakukan transaksi. Nilai monetary sebesar 7.558.658 juga berada dalam kategori high, yang menunjukkan kontribusi pendapatan yang signifikan. Berdasarkan karakteristik tersebut, Cluster 1 dapat dikategorikan sebagai High-Value Customers, yaitu pelanggan dengan frekuensi transaksi tinggi dan nilai pembelian besar. Sementara itu, Cluster 0 dapat dikategorikan sebagai Moderate Customers, yaitu pelanggan dengan kontribusi sedang dan potensi untuk dikembangkan lebih lanjut.

E. Implikasi Strategis

Hasil segmentasi menunjukkan bahwa pelanggan Queen Audio secara alami terbagi menjadi dua kelompok utama, yaitu pelanggan bernilai tinggi dan pelanggan bernilai menengah. Struktur dua cluster ini mengindikasikan adanya konsentrasi kontribusi pendapatan pada kelompok tertentu. Bagi pelanggan dalam kategori High-Value, strategi yang dapat diterapkan meliputi program loyalitas eksklusif, penawaran produk premium, serta pendekatan personalisasi promosi. Sementara itu, bagi pelanggan kategori Moderate, strategi yang dapat dilakukan meliputi pemberian insentif pembelian ulang, bundling produk, serta promosi yang mendorong peningkatan frekuensi transaksi. Pendekatan diferensiasi strategi berdasarkan segmentasi ini

memungkinkan perusahaan untuk meningkatkan efektivitas pemasaran sekaligus mengoptimalkan pengelolaan persediaan.

F. Pembahasan

Hasil penelitian menunjukkan bahwa segmentasi pelanggan Queen Audio secara optimal terbagi menjadi dua cluster berdasarkan kombinasi metode RFM dan K-Means. Struktur dua cluster ini didukung oleh hasil evaluasi Elbow Method dan nilai Silhouette sebesar 0,513607 yang menunjukkan kualitas pemisahan cluster yang cukup baik.

Penggunaan metode RFM dalam penelitian ini sejalan dengan temuan [3],[11][12],13 yang menyatakan bahwa pendekatan Recency, Frequency, dan Monetary efektif dalam mengidentifikasi nilai pelanggan secara kuantitatif berdasarkan perilaku transaksi. Dalam konteks Queen Audio, nilai monetary dan frequency yang tinggi pada Cluster 1 menunjukkan adanya kelompok pelanggan dengan kontribusi pendapatan dominan. Hal ini mendukung konsep bahwa kombinasi RFM mampu mengidentifikasi pelanggan bernilai tinggi secara lebih terstruktur dibandingkan analisis deskriptif biasa.

Dari sisi metode clustering, penggunaan K-Means dalam penelitian ini juga konsisten dengan penelitian [4],[6] yang menyatakan bahwa K-Means merupakan algoritma yang efisien dan efektif untuk segmentasi pelanggan berbasis perilaku transaksi. Efisiensi komputasi dan kemudahan interpretasi centroid menjadikan K-Means relevan untuk dataset ritel dengan jumlah transaksi yang relatif besar. Meskipun demikian, [10] menekankan bahwa inisialisasi centroid secara acak dapat memengaruhi stabilitas hasil clustering. Oleh karena itu, penggunaan parameter n_{init} dalam penelitian ini bertujuan untuk meminimalkan bias inisialisasi dan meningkatkan konsistensi hasil segmentasi.

Penentuan jumlah cluster optimal menggunakan Silhouette Score sebagaimana dirumuskan oleh [11] dan didukung oleh pendekatan evaluasi modern [13] menunjukkan bahwa integrasi metode evaluasi kuantitatif memberikan landasan metodologis yang kuat. Temuan bahwa $k=2$ merupakan konfigurasi terbaik menunjukkan adanya polarisasi nilai pelanggan di Queen Audio, yaitu kelompok pelanggan dengan kontribusi tinggi dan kelompok pelanggan dengan kontribusi sedang. Pola ini mencerminkan fenomena yang umum terjadi dalam sektor ritel, di mana sebagian kecil pelanggan menyumbang proporsi pendapatan yang lebih besar.

Jika dikaitkan dengan konteks industri alat musik, hasil ini memiliki implikasi yang signifikan. Produk alat musik cenderung memiliki harga tinggi dan siklus pembelian lebih panjang dibandingkan barang konsumsi cepat. Oleh karena itu, nilai monetary menjadi indikator dominan dalam mengidentifikasi pelanggan bernilai tinggi. Hal ini memperkuat argumen bahwa segmentasi berbasis RFM relevan untuk industri dengan karakteristik pembelian tidak rutin dan bernilai besar. Selain itu, penggunaan PCA dalam visualisasi cluster menunjukkan bahwa reduksi dimensi tetap

mampu mempertahankan struktur pemisahan antar cluster. Visualisasi pada Gambar 3 memperlihatkan dua kelompok yang relatif terpisah, sehingga secara visual mendukung hasil evaluasi numerik Silhouette Score. Integrasi pendekatan statistik dan visualisasi ini memperkuat kredibilitas hasil segmentasi.

Dari perspektif strategis, hasil penelitian ini mendukung temuan [1],[2] yang menyatakan bahwa segmentasi pelanggan memungkinkan perusahaan merancang strategi pemasaran yang lebih terarah. Cluster High-Value Customers yang memiliki frequency dan monetary tinggi sebaiknya difokuskan pada strategi retensi, seperti program loyalitas dan personalisasi promosi. Sementara itu, Cluster Moderate Customers memiliki potensi untuk ditingkatkan melalui strategi peningkatan frekuensi pembelian dan promosi terarah.

Secara konseptual, penelitian ini menunjukkan bahwa integrasi CRISP-DM [8] dengan model RFM dan K-Means memberikan kerangka kerja sistematis dalam pengambilan keputusan berbasis data. Tahapan mulai dari pemahaman bisnis hingga evaluasi memungkinkan analisis dilakukan secara terstruktur dan replikasi metodologi di masa depan menjadi lebih memungkinkan [14],[15]. Dibandingkan penelitian sebelumnya yang lebih banyak diterapkan pada sektor e-commerce dengan siklus transaksi cepat, penelitian ini memberikan kontribusi kontekstual pada industri alat musik yang memiliki karakteristik pembelian berbeda. Dengan demikian, penelitian ini memperluas penerapan metode RFM dan K-Means pada sektor ritel bernilai tinggi [16].

Meskipun demikian, penelitian ini memiliki keterbatasan pada rentang waktu data yang relatif pendek, sehingga belum sepenuhnya menangkap pola musiman atau perubahan perilaku pelanggan jangka panjang. Penelitian selanjutnya dapat memperpanjang periode observasi, membandingkan dengan algoritma clustering lain seperti hierarchical clustering atau K-Medoids, serta mengintegrasikan hasil segmentasi dengan sistem CRM untuk implementasi otomatis.

IV. KESIMPULAN

Penelitian ini berhasil mengoptimalkan strategi pemasaran Queen Audio melalui segmentasi pelanggan berbasis model Recency, Frequency, dan Monetary (RFM) yang diintegrasikan dengan algoritma K-Means Clustering. Hasil segmentasi menunjukkan bahwa pelanggan Queen Audio secara alami terbagi menjadi dua kelompok utama, yaitu pelanggan bernilai tinggi dan pelanggan bernilai menengah. Temuan ini mengindikasikan adanya konsentrasi kontribusi pendapatan pada segmen tertentu, sehingga pendekatan pemasaran berbasis diferensiasi menjadi relevan untuk diterapkan. Strategi retensi dan personalisasi promosi lebih tepat diarahkan kepada pelanggan bernilai tinggi, sedangkan pelanggan bernilai menengah dapat didorong melalui peningkatan frekuensi pembelian dan insentif pembelian ulang.

Secara akademik, penelitian ini memperluas penerapan metode RFM dan K-Means pada industri alat musik yang memiliki karakteristik pembelian bernilai tinggi dan frekuensi relatif rendah, sehingga mengisi keterbatasan penelitian sebelumnya yang lebih banyak berfokus pada sektor ritel dengan siklus transaksi cepat. Integrasi metode evaluasi cluster memberikan validasi metodologis terhadap struktur segmentasi yang dihasilkan.

Meskipun demikian, penelitian ini masih terbatas pada periode observasi yang relatif singkat serta penggunaan satu algoritma utama. Penelitian selanjutnya dapat memperpanjang rentang data dan membandingkan dengan metode clustering lain seperti DBSCAN atau Hierarchical Clustering untuk meningkatkan robustitas model segmentasi.

DAFTAR PUSTAKA

- [1] Rizki, B., N. G. Ginasta, M. A. Tamrin, and A. Rahman, "Customer Loyalty Segmentation on Point of Sale System Using Recency-Frequency-Monetary (RFM) and K-Means," *Jurnal Online Informatika*, pp. 130–136, 2020. doi: 10.15575/join.v5i2.511.
- [2] Mahendra, M. R., E. Darmanto, and S. Muzid, "Penerapan Metode RFM Analysis dan K-Means Clustering untuk Manajemen Pelanggan pada Zhe Homewear," *Jurnal Nasional Komputasi dan Teknologi Informasi (JNKTI)*, vol. 8, no. 4, pp. 2128–2135, 2025. doi: 10.32672/jnkti.v8i4.9452.
- [3] Widhyastuti, L. P. W., I. N. Sukajaya, and K. Y. E. Aryanto, "Customer Profiling Berdasarkan Model RFM dengan Metode K-Means pada Institusi Pendidikan untuk Menunjang Strategi Bisnis di Masa Pandemi Covid-19," *JTIM: Jurnal Teknologi Informasi dan Multimedia*, vol. 4, no. 2, pp. 94–108, 2022. doi: 10.35746/jtim.v4i2.232.
- [4] Chalechema, S., M. Saini, I. Perla, and A. V. Shivanand, "Customer Segmentation Using K-Means Algorithm and RFM Model," in *Proc. 2023 International Conference on Computational Intelligence and Smart Systems (ICCSIS)*, 2023, pp. 393–398. doi: 10.1109/icccis60361.2023.10425556.
- [5] Ikotun, A. M., et al., "K-means clustering algorithms: A comprehensive review," *International Journal of Information Technology & Decision Making*, 2023.
- [6] Mukhtar, H., I. D. Pramaditya, W. S. Weisdiyanto, S. H. Putra, D. Trimuawasih, and A. A. Rilda, "Algoritma K-Means untuk Pengelompokan Perilaku Customer," *Journal of Software Engineering and Information Systems*, vol. 4, no. 2, pp. 96–101, 2021. doi: 10.37859/seis.v4i2.7615.
- [7] Grigorova, I., A. Efremov, and A. Karamfilov, "An Automated Machine Learning Framework for Interpretable Customer Segmentation in Financial Services," *International Journal of Financial Studies*, vol. 13, no. 4, p. 243, 2025. doi: 10.3390/ijfs13040243.
- [8] Triyoga, K. W., P. Widyo Laksono, and R. W. Damayanti, "Optimization of Stock Price Prediction Using Long Short-Term Memory (LSTM) Algorithm and Cross-Industry Standard Process Approach for Data Mining (CRISP-DM)," *International Journal of Electronics and Communications Systems*, vol. 5, no. 1, pp. 19–30, 2025. doi: 10.24042/ijecs.v5i1.26727.
- [9] Sholeh, M., and K. Aeni, "Perbandingan Evaluasi Metode Davies-Bouldin, Elbow dan Silhouette pada Model Clustering dengan Menggunakan Algoritma K-Means," *STRING (Satuan Tulisan Riset dan Inovasi Teknologi)*, vol. 8, no. 1, pp. 56–65, 2023. doi: 10.30998/string.v8i1.16388.
- [10] Abdillah, M. H., "Implementation of Forge Initialization and K-Means++ Algorithms in the K-Means Clustering Method for Sales Data Analysis of Dazzle Store," *Telematika: Jurnal Telematika dan Teknologi Informasi*, vol. 22, no. 2, 2025. doi: 10.31315/telematika.v22i2.14468.
- [10] Trapanese, L., et al., "Comparison of K-Means and Hierarchical Clustering Methods in Animal Movement Data," *Animals*, vol. 15, no. 22, p. 3246, 2025. doi: 10.3390/ani15223246.
- [11] Rousseeuw, P. J., "Silhouettes: A Graphical Aid to the Interpretation and Validation of Cluster Analysis," *Journal of Computational and Applied Mathematics*, vol. 20, pp. 53–65, 1987. doi: 10.1016/0377-0427(87)90125-7.
- [12] Marisa, F., A. R. Wardhani, W. Purnomowati, A. V. Vitianingsih, A. L. Maukar, and E. W. Puspitarini, "Potential Customer Analysis Using K-Means with Elbow Method," *Jurnal Informatika dan Komputer (JIKO)*, vol. 7, no. 2, pp. 307–312, 2023. doi: 10.26798/jiko.v7i2.911.
- [13] Siagian, N. A., A. Rikki, and P. B. N. Simangunsong, "Clustering Menggunakan Metode K-Medoids dengan Pendekatan Manhattan Distance," *KAKIFIKOM (Kumpulan Artikel Karya Ilmiah Fakultas Ilmu Komputer)*, vol. 6, no. 2, pp. 169–175, 2024. doi: 10.54367/kakifikom.v6i2.4608.
- [14] Perdhana, R. B., & Heikal, J. (2024). Enhancing customer segmentation in online transportation services: a comprehensive approach using K-means clustering and RFM model. *Indonesian Interdisciplinary Journal of Sharia Economics (IJSE)*, 7(2), 2849-2865.
- [15] Rajendran, N. (2025). Enhancing Customer Segmentation and Behaviour Analysis with RFM Clustering: A Machine Learning Approach (Doctoral dissertation, Dublin, National College of Ireland).
- [16] Kaewpradit, T. (2025). Optimizing Retail Strategy: A Data-Driven Approach to Customer Segmentation Using RFM Analysis and K-Means Clustering. Available at SSRN 5238097.