

TESIS

**ANALISIS KECERDASAN BISNIS
BERDASARKAN KONSEP RECENCY,
FREQUENCY, MONETARY DAN LIFETIME
KASUS : (Toko Retail Batik)**



MUHAMAD KASWA

22916019

**PROGRAM STUDI TEKNIK INDUSTRI
PROGRAM MAGISTER
FAKULTAS TEKNOLOGI INDUSTRI
UNIVERSITAS ISLAM INDONESIA
YOGYAKARTA**

2026

Lembar Pernyataan Keaslian

Dengan ini saya menyatakan bahwa dalam tesis yang berjudul “Analisis Kecerdasan Bisnis Berdasarkan Konsep Recency, Frequency, Monetary Dan Lifetime Kasus : (Toko Retail Batik)” merupakan hasil karya saya sendiri dan tidak terdapat plagiat dari karya orang lain kecuali kutipan dan ringkasan yang tertulis dengan jelas sumbernya yang telah dicantumkan sesuai dengan etika penulisan karya ilmiah.

Yogyakarta, 10 Maret 2026



Muhamad Kaswa

Lembar Pengesahan Pembimbing

**ANALISIS KECERDASAN BISNIS
BERDASARKAN KONSEP RECENCY,
FREQUENCY, MONETARY DAN LIFETIME
KASUS : (Toko Retail Batik)**

**Diajukan sebagai salah satu syarat untuk memperoleh gelar
Magister Strata-2 pada jurusan Teknik Industri Fakultas
Teknologi Industri Universitas Islam Indonesia**

Disusun oleh :

Muhamad Kaswa

22916019

Tesis telah disetujui pada tanggal, 22 Februari 2026

Pembimbing



Ir. Muhammad Ridwan Andi Purnomo, S.T., M.Sc., Ph.D., IPM
NIK 015220101

Lembar Pengesahan Penguji

**ANALISIS KECERDASAN BISNIS
BERDASARKAN KONSEP RECENCY,
FREQUENCY, MONETARY DAN LIFETIME
KASUS : (Toko Retail Batik)**

**MUHAMAD KASWA
22916019**

Tesis Telah Diuji dan Dinilai Oleh Panitia Penguji Program Studi Magister
Teknik Industri Fakultas Teknologi Industri Universitas Islam Indonesia
Yogyakarta

Ketua Penguji

Ir. Muhammad Ridwan Andi Purnomo, S.T., M.Sc., Ph.D., IPM

(.....)

Anggota I

Dr. Agus Mansur, S.T., M.Eng.Sc

(.....)

Anggota II

Dr. Drs. Imam Djati Widodo, M.Eng.Sc

(.....)

Mengetahui

Ketua Program Studi Teknik Industri Program Magister
Fakultas Teknologi Industri
Universitas Islam Indonesia



Ir. Winda Nur Cahyo, S.T., M.T., Ph.D., IPM, ASEAN-Eng., APEC-Eng

NIK 025200519

Daftar Isi

Lembar Pernyataan Keaslian	Error! Bookmark not defined.
Lembar Pengesahan Pembimbing.....	ii
Lembar Pengesahan Penguji	iii
Daftar Isi.....	iv
Daftar Tabel	vi
Daftar Gambar.....	vii
ABSTRAK	viii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang Masalah.....	1
1.2 Rumusan Masalah.....	3
1.3 Tujuan Penelitian	4
1.4 Manfaat Penelitian	4
BAB II TINJAUAN PUSTAKA.....	6
2.1 Kajian Induktif.....	6
2.2 Kajian Deduktif.....	20
BAB III METODE PENELITIAN	23
3.1 Objek dan Subjek Penelitian.....	23
3.2 Ruang Lingkup Penelitian.....	23
3.3 Pengumpulan Data	24
3.4 Alat dan Bahan Penelitian.....	24
3.5 Alur Penelitian	26
BAB IV.....	28
PENGUMPULAN DAN PENGOLAHAN DATA	28
4.1 Gambaran Umum Data Penelitian	28
4.2 Periode Pengumpulan Data.....	28
4.3 Pra- Pengolahan Data.....	30
4.4 Pengolahan Data Menggunakan Model RFML	30
4.5 Segmentasi Pelanggan Menggunakan K-Means Clusterig	33
4.6 Implementasi Dashboard Business Intelligence.....	35
BAB V	37
PEMBAHASAN	37

5.1	Pembahasan Nilai RFM ⁺	37
5.2	Pembahasan Analisis K-Means Clustering	39
BAB VI	42
KESIMPULAN DAN SARAN	42
6.1	Kesimpulan	42
6.2	Saran untuk peneliti selanjutnya	44
DAFTAR PUSTAKA	45

Daftar Tabel

Tabel 2. 1 Penelitian Terdahulu	17
Tabel 4. 1 Data Transaksi periode 2023-2025	29
Tabel 4. 2 Hasil perhitungan RFML (Recency, Frequency, Monetary, Lifetime).....	32
Tabel 4. 3 Hasil Perhitungan K-Means Clustering	34

Daftar Gambar

Gambar 2. 1 Langkah-langkah proses kerja Business Intelligence.....	21
Gambar 3. 1 Diagram alir penelitian.....	27
Gambar 4. 1 Data Transaksi periode 2023-2025	29
Gambar 4. 2 Hasil perhitungan RFML (Recency, Frequency, Monetary, Lifetime)	32
Gambar 4. 3 Hasil Perhitungan K-Means Clustering.....	34
Gambar 4. 4 Distribusi Segmentasi Pelanggan	35
Gambar 4. 5 Visualisasi slicer tiap segmen	36

ABSTRAK

Perkembangan globalisasi dan persaingan bisnis yang semakin ketat menuntut pelaku usaha ritel untuk mengoptimalkan pemanfaatan data pelanggan dalam pengambilan keputusan strategis. Toko ritel batik sebagai objek penelitian masih menghadapi permasalahan tingginya biaya pemasaran yang belum diimbangi dengan efektivitas dan ketepatan sasaran. Penelitian ini bertujuan untuk mengimplementasikan sistem *Business Intelligence* berbasis model RFM+ (Recency, Frequency, Monetary, dan Lifetime) yang dikombinasikan dengan analisis *K-Means Clustering* guna menghasilkan segmentasi pelanggan yang lebih akurat dan mendukung perumusan strategi pemasaran yang efisien. Data yang digunakan berupa data historis transaksi pelanggan toko ritel batik di Kota Magelang, yang mencakup informasi tanggal transaksi, frekuensi pembelian, nilai transaksi, dan lama berlangganan. Pengolahan dan visualisasi data dilakukan menggunakan Microsoft Power BI untuk menghitung skor RFM+, sedangkan analisis klaster dilakukan menggunakan metode *K-Means*. Hasil penelitian menunjukkan bahwa pelanggan dapat dikelompokkan ke dalam beberapa segmen utama, yaitu *Champion*, *Potential Loyalist*, *At Risk*, *Lost*, dan *New Customer*. Segmen *Potential Loyalist* merupakan kelompok dengan jumlah pelanggan terbanyak, sedangkan segmen *Champion* memiliki nilai kontribusi transaksi tertinggi. Implementasi model RFM+ dan *K-Means Clustering* terbukti mampu memberikan wawasan yang komprehensif mengenai perilaku dan nilai pelanggan. Temuan ini dapat dimanfaatkan oleh manajemen toko ritel batik untuk merancang strategi pemasaran yang lebih tepat sasaran, meningkatkan retensi pelanggan, serta mengoptimalkan alokasi biaya pemasaran. Dengan demikian, penerapan *Business Intelligence* berbasis data dapat meningkatkan efisiensi pemasaran dan daya saing bisnis ritel batik.

Kata kunci: Business Intelligence, RFM+, K-Means Clustering, Segmentasi Pelanggan, Strategi Pemasaran.

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Globalisasi memiliki dampak besar pada budaya masyarakat. Hal ini perlahan-lahan tercermin dengan menyatunya selera dan preferensi di seluruh dunia. Oleh karena itu, bisnis masa depan perlu mengikuti pendekatan non-tradisional, yaitu inovatif dalam mengarahkan keputusan strategis mereka dengan mengadopsi teknologi informasi inovatif berdasarkan data pelanggan dalam melayani pelanggan (Zamil & Vasista, 2021). Data pelanggan merupakan fondasi strategis untuk bisnis yang sukses. Mengeksplorasi data untuk menentukan wawasan pelanggan dan mendukung pengambilan keputusan dapat meningkatkan minat bisnis. Alih-alih menerapkan strategi pemasaran untuk semua pelanggan yang berinteraksi dengan bisnis secara seragam dan kolektif, pengelompokan pelanggan membantu bisnis mengidentifikasi target pelanggan (Ho et al., 2023).

Segmentasi pelanggan didasarkan pada gagasan bahwa setiap orang berbeda dan oleh karena itu memerlukan strategi pemasaran yang dipersonalisasi. Segmentasi pelanggan dapat meningkatkan kepuasan dan profitabilitas pelanggan (Ahmed Mohamed Ahmed Serwah et al., 2023). Mengidentifikasi kelompok pelanggan yang berbeda (berharga, regular, baru, dll.) dan menentukan pendekatan pemasaran yang tepat untuk setiap kelompok, merupakan masalah penting di setiap toko. Semakin hati-hati segmentasi pelanggan dilakukan. Maka, semakin efektif strategi pemasaran yang ditugaskan (Maraghi et al., 2020). Oleh karena itu untuk membuat strategi diberbagai bidang seperti pemasaran dan menarik lebih banyak

pelanggan. Langkah pertama untuk mencapai tujuan ini adalah mengenali spesifikasi pelanggan setiap klaster dan memprediksi perilaku mereka dimasa mendatang (Khalilinezhad et al., 2021).

Strategi pemasaran merupakan investasi penting bagi perusahaan yang ingin meningkatkan visibilitas merek, mendorong penjualan, dan mempertahankan keunggulan kompetitif. Namun, menilai keuntungan finansial dari pengeluaran ini, khususnya kegiatan periklanan dan promosi menimbulkan tantangan yang sangat signifikan karena biaya yang tinggi. Praktik ini seringkali gagal dan menyebabkan inefisiensi dalam alokasi anggaran dan perencanaan yang strategis (Meng, 2024).

Analisis RFM (*Recency, Frequency, Monetary*) merupakan suatu model dalam *Business Intelligence* yang telah diidentifikasi sebagai metode yang sangat efektif dan banyak digunakan untuk memahami perilaku pelanggan, memungkinkan pengembangan model prediktif terkait perilaku pelanggan untuk strategi pemasaran. RFM (*Recency, Frequency, Monetary*) juga dapat digunakan untuk mengkategorikan klien berdasarkan riwayat pembelian mereka, dengan mengandalkan tiga atribut utama pelanggan yaitu tanggal pembelian, frekuensi pembelian, dan nilai moneter pembelian (Akande et al., 2024).

Toko ritel batik yang diteliti merupakan toko ritel penjualan batik yang ingin membuat startegi pemasarannya lebih efisien. Permasalahan utama yang dihadapi oleh toko ritel batik yang diteliti adalah minimnya pemanfaatan teknologi digital untuk strategi pemasaran yang membuat tingginya biaya pemasaran pada toko ritel batik tersebut yang tidak diimbangi dengan efisiensi pengelolaan, sehingga dibutuhkan strategi pemasaran digital yang tepat guna untuk mengefisienkan

biaya pemasaran tanpa mengurangi jangkauan dan efektivitas dalam menarik pelanggan.

Penelitian ini menggunakan model RFM⁺ (*Recency, Frequency, Monetary, Lifetime*) yang berbasis data dan digital dalam analisis *Business Intelligence* dan dikombinasikan dengan analisis *K-Means Clustering* untuk mendukung strategi pemasaran yang lebih tepat sasaran pada pelanggan-pelanggan ritel batik yang diteliti. Keunggulan model RFM terletak pada fleksibel, relevansi dan keakuratannya dengan data yang luas dan objektif variabel yang terukur (Khumaidi et al., 2023). Sedangkan metode K-Means Clustering merupakan metode yang algoritmanya sederhana mudah dipahami dan cepat dalam memilih pusat kluster (Gustriansyah et al., 2020).

Tujuan penelitian ini adalah untuk mengusulkan strategi pemasaran yang lebih efisien dan tepat sasaran berbasis digital untuk toko ritel batik, guna mengurangi biaya pemasaran yang tinggi tanpa mengurangi efektivitas dalam menjangkau pelanggan serta meningkatkan daya saing di pasar yang kompetitif.

1.2 Rumusan Masalah

Berdasarkan latar belakang masalah, maka rumusan masalah dalam penelitian ini adalah sebagai berikut :

1. Berapa nilai *Recency, Frequency, Monetary, dan Lifetime* pada pelanggan toko ritel batik berdasarkan analisis model RFM⁺ ?
2. Bagaimana hasil segmentasi pelanggan berdasarkan kombinasi model RFM⁺ (*Recency, Frequency, Monetary, Lifetime*) dan analisis *K-Means Clustering* pada toko ritel batik yang diteliti?

3. Apa strategi bisnis dan pemasaran yang dapat direkomendasikan berdasarkan hasil analisis RFM⁺ (*Recency, Frequency, Monetary, Lifetime*) dan analisis *K-Means Clustering* untuk toko ritel batik yang diteliti?

1.3 Tujuan Penelitian

Adapun tujuan penelitian berdasarkan rumusan masalah diatas adalah sebagai berikut :

1. Menganalisis perilaku pelanggan toko retail batik menggunakan model RFM⁺ (*Recency, Frequency, Monetary, Lifetime*).
2. Mengidentifikasi segmentasi pelanggan dari hasil skor RFM⁺ (*Recency, Frequency, Monetary, Lifetime*) menggunakan analisis *K-Means Clustering*.
3. Merumuskan strategi bisnis dan pemasaran yang tepat berdasarkan hasil analisis RFM⁺ (*Recency, Frequency, Monetary, Lifetime*) dan analisis *K-Means Clustering* untuk toko ritel batik yang diteliti.

1.4 Manfaat Penelitian

Adapun tujuan penelitian berdasarkan rumusan masalah diatas adalah sebagai berikut :

1. Memberikan kontribusi pada pengembangan ilmu pengetahuan di bidang *Business Intelligence* khususnya penerapan analisis RFM (*Recency, Frequency, Monetary*) dan analisis *K-Means Clustering*.
2. Menjadi referensi bagi peneliti selanjutnya yang berkaitan dengan analisis loyalitas pelanggan, segmentasi, dan strategi pemasaran berbasis data dan digital.

3. Membantu manajemen dalam mengenali pola perilaku pelanggan berdasarkan nilai RFM (*Recency, Frequency, Monetary*) dan analisis *K-Means Clustering*.
4. Mandukung pengambilan keputusan berbasis data dan digital untuk meningkatkan retensi pelanggan.
5. Menjadi contoh penerapan analisis RFM (*Recency, Frequency, Monetary*) dan analisis *K-Means Clustering* yang dapat diadaptasi oleh pelaku usaha lain untuk meningkatkan efektivitas strategi pemasaran pelanggan.

BAB II

TINJAUAN PUSTAKA

2.1 Kajian Induktif

Peneliti melakukan studi pustaka untuk membandingkan penelitian peneliti sebelumnya. Adapun tinjauan pustaka terdahulu sebagai berikut :

Pada penelitian yang berjudul *Customer Segmentation Using Machine Learning Model : An Application of RFM Analysis* yang bertujuan untuk menyediakan perpaduan teknik analisis ML dan RFM untuk prediksi *churn* menggunakan sebagian besar data transaksional. Dataset diambil dari situs web pencarian dataset yang berisi dataset ritel daring. Skor RFM setiap pelanggan dihitung berdasarkan data yang tersedia. Metric *churn* menunjukkan apakah pelanggan telah melakukan transaksi dalam waktu terbatas atau belum (Lewaaelhamd, 2023).

Pada penelitian yang berjudul *Develop a Recommender System Based on a Novel Approach To the RFM Customer Segmentation Model (A Case Study of Greenweb Co.)* yang bertujuan untuk merekomendasikan produk kepada pelanggan dengan memanfaatkan model RFM (*Recency, Frequency, Monetary*) untuk mengelompokkan pelanggan ke dalam delapan kelas dan membuat rekomendasi yang menarik. Untuk mengevaluasi kinerja sistem yang diusulkan, penelitian ini merupakan eksperimen yang menggunakan data yang dikumpulkan melalui GreenWeb Co. Hasilnya menunjukkan bahwa setelah menerapkan sistem rekomendasi yang diusulkan, jumlah pembelian rata-rata pelanggan dalam 8 kategori label RFM telah meningkat sekitar 13,79% (Jamshidi et al., 2024).

Pada penelitian yang berjudul *Integration of Sentiment Analysis and RFM in Restaurant Customer Segmentation: A 7P-Based CRM with clustering* yang bertujuan untuk melakukan segmentasi pelanggan restaurant secara lebih efektif dengan menggunakan metode CRM dan kerangka kerja RFM. Dengan memetakan ulasan pelanggan ke label 7P dan menganalisisnya menggunakan RFM, model ini mengungkap pola perilaku spesifik yang terkait dengan kualitas layanan, harga, dan promosi. Integrasi ini memungkinkan restoran untuk menerapkan strategi yang sesuai (Sunarko et al., 2025).

Pada penelitian yang berjudul *Recency, Frequency, Monetary Value, Clustering, and Internal and External Indices for Customer Segmentation from Retail Data* yang bertujuan untuk mengelompokkan pelanggan dalam basis data retail. Penelitian ini mengidentifikasi pelanggan berdasarkan perilaku unik mereka dari pelanggan yang hilang, pelanggan yang tidak tertarik, pelanggan baru, pelanggan yang kurang baru, pelanggan setia, dan pelanggan terbaik. Perilaku mereka dibuktikan dan dianalisis, yang menunjukkan tren dan preferensi pelanggan (Wilbert et al., 2023).

Pada penelitian yang berjudul *An E-commerce Customer Segmentation Method Based on RFM Weighted K-means* yang bertujuan untuk mengusulkan model segmentasi pelanggan e-commerce berdasarkan RFM-weighted K-means, yang menggunakan kombinasi metode AHP subjektif dan metode pembobotan entropi objektif untuk menggantikan metode pembobotan tunggal tradisional, menghindari deviasi metode tradisional pembagian bobot indeks dari kenyataan, dan detail pelanggan. Hasilnya menunjukkan bahwa pengalompokkan pelanggan e-

commerce yang diperoleh dengan pengalompokkan tertimbang gabungan secara signifikan lebih baik daripada pelanggan e-commerce tradisional, dengan perbedaan yang lebih besar antara kelompok dan pelanggan yang lebih tinggi (Li et al., 2022).

Pada penelitian yang berjudul *A Novel Telecom Customer Churn Analysis System Based on RFM Model and Feature Importance Ranking* yang bertujuan membuat sistem *churn* pelanggan telekomunikasi berbasis model RFM untuk memprediksi dan menganalisis *churn* pelanggan dengan lebih baik. Sistem analisis *churn* pelanggan telekomunikasi terdiri dari tiga bagian utama: segmentasi pelanggan, prediksi *churn*, dan identifikasi factor *churn*. Untuk melakukan segmentasi dataset asli, penelitian ini menggunakan model RFM dan algoritma K-means dengan metode silu. Kemudian menggunakan konstruksi fitur berbasis RFM untuk prediksi *churn* pelanggan dan algoritma *XGBoost* dengan metode SHAP untuk mendapatkan peringkat kepentingan fitur (Xu et al., 2023).

Pada penelitian yang berjudul *Application of Data Mining Technique for Customer Purchase Behavior via Extended RFM model with Focus on BCG Matrix from a Dataset of Online Retailing* yang bertujuan untuk pemanfaatan teknik penambangan data dalam analitik pelanggan, dengan focus pada model RFM yang diperluas (Recency, Frequency, Monetary Value, dan Count day) dalam konteks ritel daring. Model RFM yang diperluas menyempurnakan analisis RFM tradisional dengan menggabungkan demografi dan psikografi pelanggan untuk melakukan segmentasi pelanggan secara lebih efektif berdasarkan pola pembelian mereka (Gholamveisy et al., 2024).

Pada penelitian yang berjudul *An Empirical Study on Customer Segmentation by Purchase Behaviors Using a RFM Model and K-means Algorithm* yang bertujuan untuk menganalisis data transaksi online suatu perusahaan dengan menggunakan RFM dan algoritma pengelompokan K-means. Pelanggan diklasifikasikan menjadi empat kelompok berdasarkan perilaku pembelian. Hasil dari penelitian ini adalah adanya peningkatan indeks kinerja utama seperti pertumbuhan pelanggan aktif, total value pembelian, dan total jumlah konsumsi (Wu et al., 2020).

Pada penelitian yang berjudul *Optimizing Marketing Strategies with RFM Method and K-means Clustering-Based AI Customer Segmentation Analysis* yang bertujuan untuk menyelidiki efisiensi algoritma pengelompokan K-means sebagai teknik untuk segmentasi konsumen yang efisien. Algoritma K-means yang dikonsolidasikan dengan analisis RFM terakreditasi secara global sebagai teknik pengelompokan partisi yang mendalam yang telah terbukti sangat efisien dalam berbagai pengaturan bisnis. Hasil eksperimen memberikan bukti persuasif tentang kinerja algoritma dalam hal segmentasi konsumen (Sarkar et al., 2024).

Pada penelitian yang berjudul *Retail Industry Analytics: Unraveling consumer Behavior through RFM Segmentation and Machine Learning* yang bertujuan untuk mengeksplorasi dinamika kompleks perilaku konsumen di industri ritel Inggris menggunakan analitik tingkat lanjut. Penelitian ini mengembangkan set data ritel pra-proses yang mencakup 495.478 pelanggan ritel. Penelitian ini menggunakan kombinasi metode yaitu model RFM dan metode ML, hasil temuan dari model RFM menunjukkan keunggulan uniknya dalam memberikan wawasan

penting tentang klien dan perilaku mereka. Penelitian ini menetapkan standar baru dalam analitik ritel, menawarkan metodologi yang skalabel dan efisien untuk studi masa depan yang berfokus pada pemanfaatan analitik data untuk memahami dan memprediksi perilaku pelanggan di berbagai entitas bisnis (Arefin et al., 2024).

Pada penelitian yang berjudul *Predictive Analytics Using Big Data For Increased Customer Loyalty : Syriatel Telecom Company Case Study* yang bertujuan untuk menargetkan pelanggan dengan nilai yang berbeda melalui penawaran dan layanan yang tepat. Penelitian ini menggunakan model RFM untuk menentukan segmen pelanggan, beberapa algoritma klasifikasi diterapkan berdasarkan descriptor dan fitur yang dipilih untuk membangun berbagai model prediktif yang digunakan untuk mengklasifikasikan pengguna baru berdasarkan loyalitas. Selanjutnya alasan loyalitas di setiap tingkat ditentukan untuk menargetkan mereka pada penawaran dan layanan yang paling tepat (Wassouf et al., 2020).

Pada penelitian yang berjudul *Predicting Customer Behavior with Activation Loyalty per Period. From RFM to RFMAP* yang bertujuan untuk mengidentifikasi model baru untuk memprediksi perilaku pelanggan berdasarkan variabel baru yang dapat digunakan oleh manajemen pemasaran dan disesuaikan dengan perencanaan bisnis mereka. Model baru ini, RFMAP, yang mencakup periode aktivasi dan loyalitas aktivasi, menghadirkan akurasi prediksi yang lebih tinggi dan peningkatan dibandingkan model tradisional dengan dampak yang jelas, garis segmentasi yang berguna dan mudah dikelola, serta prioritas untuk manajemen pemasaran dalam sistem CRM (Alet Vilaginés, 2020).

Pada penelitian yang berjudul *Enhancing Customer Segmentation: RFM Analysis and K-means Clustering Implementation* yang bertujuan untuk mengelompokkan pelanggan berdasarkan perilaku pembelian mereka dengan model RFM (*Recency, Frequency, Monetary*). Analisis RFM dilakukan untuk mengukur nilai pelanggan, yang kemudian dianalisis lebih lanjut menggunakan algoritma pengelompokan k-means untuk mengidentifikasi segmen pelanggan yang berbeda. Pendekatan ini tidak hanya membantu dalam memperoleh pelanggan baru tetapi juga mempertahankan pelanggan yang sudah ada, yang pada akhirnya berkontribusi pada keunggulan kompetitif yang berkelanjutan (Ramkumar et al., 2025).

Pada penelitian yang berjudul *The Application of Customers Segmentation Using RFM Analysis Method and K-means clustering to Improve Marketing Strategy* yang bertujuan untuk mengatasi permasalahan dalam meningkatkan strategi pemasaran di industri bisnis ritel dengan menggunakan segmentasi pelanggan yang efektif. Metode yang digunakan adalah analisis RFM untuk mengukur kedekatan waktu, frekuensi, dan nilai moneter transaksi pelanggan, serta K-means clustering untuk mengukur pengelompokan pelanggan berdasarkan perilaku pembelian mereka. Hasil penelitian ini menunjukkan bahwa kombinasi kedua metode ini berhasil mengelompokkan pelanggan ke dalam sepuluh segmen berbeda (Robo et al., 2024).

Pada penelitian yang berjudul *Analysis of Customer Segmentation In The Three Most Visited E-Commerce Platforms In Indonesia In 2023 Using RFM Model And clustering Techniques* yang bertujuan untuk menganalisis perilaku pelanggan

di tiga platform e-commerce yang paling banyak dikunjungi di Indonesia (Shopee, Tokopedia, dan Lazada). Penelitian ini menggunakan model RFM (*Recency, Frequency, Monetary*) dan teknik pengelompokan K-means. Studi ini mengintegrasikan analisis demografi, psikografi, dan perilaku pembelian menggunakan metode stratified random sampling untuk mengumpulkan data selama 6 bulan dari 100 responden di setiap platform e-commerce. Hasilnya mengungkapkan enam klaster pelanggan, masing-masing dengan karakteristik yang berbeda (Wulansari & Heikal, 2024).

Pada penelitian yang berjudul *RFM Segmentation and K-means Clustering of Skincare Product (Case Study Scarlett)* yang bertujuan untuk mengelompokkan konsumen berdasarkan skor RFM mereka, serta menganalisis hasil segmentasi untuk mengidentifikasi karakteristik unik setiap segmen. Temuan penelitian ini mengungkapkan preferensi yang jelas untuk produk perawatan kulit diantara segmen ini, yang ditandai dengan waktu pembelian terbaru dalam 3 bulan, frekuensi pembelian sekitar 2 kali dalam periode tersebut, dan pengeluaran rata-rata sebesar Rp. 500.000. diklasifikasikan dalam kelompok pembeli atas, pembeli yang berisiko ini menunjukkan karakteristik unik terutama perempuan, bekerja di sector swasta, dan tinggal diluar Jakarta, dengan rata-rata usia 31 tahun dan pendapatan Rp. 15.000.000. Menanggapi wawasan ini, strategi 7P yang komprehensif diusulkan untuk secara efektif melibatkan pembeli yang berisiko yaitu yang jarang membeli dan anggaran belanjanya rendah (Dinda et al., 2024).

Pada penelitian yang berjudul *Customer Segmentation Using RFM and K-means Clustering to Support CRM in Retail Industry* yang bertujuan untuk

mengatasi tantangan untuk menerapkan pendekatan segmentasi pelanggan berbasis data menggunakan analisis RFM yang dikombinasikan dengan algoritma pengelompokan K-means. Penelitian ini menggunakan 2.353 catatan transaksi dari 369 pelanggan unik yang dikumpulkan selama tiga tahun dari bisnis ritel lokal. Studi ini menunjukkan manfaat praktis dari menggabungkan analisis RFM dengan teknik pengelompokan untuk mengekstrak wawasan yang dapat ditindaklanjuti di lingkungan dengan infrastruktur teknis terbatas (Syahra et al., 2025).

Pada penelitian yang berjudul *A Data Mining Approach for Customer Segmentation Using A SAF-Based Business Intelligence System* yang bertujuan untuk melakukan analisis segmentasi pelanggan menggunakan kriteria RFM dengan mempertimbangkan data SAF-T (PT) yang terstruktur dengan baik dalam repository DW yang berorientasi untuk mendukung strategi penjualan selektif. Penelitian ini menerapkan teknik pengelompokan dan hasilnya divalidasi menggunakan teknik supervisi, pohon keputusan, dan analisis diskriminan linear (Silveira et al., 2020).

Pada penelitian yang berjudul *Clustering Optimization in RFM Analysis Based on K-means* yang bertujuan untuk segmentasi produk yang akan diurutkan berdasarkan penjualan terkini (R), penjualan yang sering (F), dan total uang yang dibelanjakan (M) dengan menggunakan metode data mining. Penelitian ini mengusulkan prosedur baru untuk analisis RFM yaitu pada segmentasi produk dengan menggunakan K-means dan delapan indeks validasi untuk menentukan jumlah kluster yang optimal yaitu metode Elbow, Indeks Silhouette Indeks, Calinski-Harabasz, Indeks Davies-Bouldin, Indeks Ratkowski, Indeks Hubert,

Indeks Ball-Hall, dan Indeks Krzanowski-Lai, yang dapat meningkatkan objektivitas dan kesamaan data pada segmentasi produk sehingga dapat meningkatkan akurasi proses manajemen stok. Hasil evaluasi menunjukkan jumlah kluster optimal untuk metode k-Means yang diterapkan dalam analisis RFM adalah sebanyak tiga kluster (segmentasi) dengan nilai variansi sebesar 0,19113 (Gustriansyah et al., 2019).

Pada penelitian yang berjudul *Application of RFM Model on Customer Segmentation in Digital Marketing* yang bertujuan untuk menilai kemungkinan calon pelanggan membeli dalam waktu dekat. Dengan memanfaatkan kombinasi pengklasifikasi pohon keputusan dan pendekatan klasifikasi yang meningkatkan gradient, penelitian ini tidak hanya berkontribusi pada kemajuan pemodelan prediktif dalam ranah perilaku pelanggan, tapi juga menggarisbawahi penerapan praktis model RFM dalam strategi pemasaran digital. Penelitian ini menawarkan wawasan berharga untuk meningkatkan proses pengambilan keputusan dan mengoptimalkan upaya pemasaran (Akazue et al., 2024).

Pada penelitian yang berjudul *Retail Customer Churn Analysis Using RFM Model and K-means Clustering* yang bertujuan untuk menganalisis churn pelanggan retail dengan menggunakan RFM dan mengelompokkan pelanggan ke dalam segmen tertentu menggunakan K-means Clustering agar perusahaan retail dapat mengidentifikasi pelanggan yang berisiko churn atau hilang. Penelitian ini mengusulkan rancangan strategi yang tepat untuk mempertahankan pelanggan loyal serta mengurangi tingkat churn. Hasilnya segmentasi RFM dan K-means

menghasilkan kelompok pelanggan churn, loyal, dan potensial. Hal ini membantu peritel membuat strategi retensi pelanggan yang tepat (Bagul et al., 2021).

Pada penelitian yang berjudul *Customer Segmentation Using RFM Analysis : Realizing Through Python Implementation* yang bertujuan untuk melakukan segmentasi pelanggan manajemen ritel yang memberikan kontribusi terbaik dari sebuah supermarket dan pelanggan yang memberikan kontribusi paling sedikit untuk periode transaksi tertentu berdasarkan perilaku pembelian pelanggan, merealisasikan analisis RFM secara praktis menggunakan Python serta menyediakan visualisasi untuk membantu pihak manajemen memahami segmen pelanggan. Penelitian ini mendukung decision making untuk program loyalitas dan retensi pelanggan berdasarkan segmentasi pelanggan (Zamil & Vasista, 2021).

Pada penelitian yang berjudul *New RFM-D Classification Model for Improving Customer Analysis and Response Prediction* yang bertujuan untuk segmentasi pelanggan dengan menambahkan parameter keragaman dari model RFM lama menjadi RFMD, yang mengacu pada diverifikasi produk yang dibeli oleh pelanggan tertentu. Segmentasi berdasarkan RFMD diterapkan dalam pasar ritel untuk mendeteksi pola perilaku pelanggan. Model yang diusulkan meningkatkan kualitas prediksi perilaku pelanggan, dimana perusahaan dapat memprediksi pelanggan mana yang akan merespon positif (Smaili & Hachimi, 2023).

Pada penelitian yang berjudul *Customer Segmentation Based on Recency, Frequency, Monetary Analysis Using K-means Algoritma in Apple Ecosystem* yang bertujuan untuk segmentasi pelanggan dengan menentukan cluster yang optimal

dari dataset RFM dan diterapkan metode Elbow. Dataset yang dihasilkan dari RFM dikelompokkan menggunakan algoritma K-means, kualitas algoritma akan dibandingkan dalam pembentukan cluster menggunakan metode Silhouette coefficient. Semua prosedur akan di-load ke dalam aplikasi web Customer Segmentation App (RFM Clustering). Segmentasi pelanggan dari dataset RFM yang telah di-cluster menghasilkan 3 cluster yang optimal yaitu cluster 2 adalah High Spenders dengan jumlah pelanggan 326 pelanggan, cluster 0 adalah VIP Customers, cluster 1 adalah Frequent Buyers. Validasi cluster K-means menggunakan koefisien siluet menghasilkan nilai 0,3524 (Setiawan et al., 2025).

Pada penelitian yang berjudul *Segmentation Strategy of Consumer Interest in Contemporary Coffee Shop Using RFM Model* yang bertujuan untuk meningkatkan loyalitas pelanggan dengan mengelompokkan pelanggan ke dalam beberapa kelompok dan menentukan strategi pemasaran yang tepat dan efektif untuk setiap kelompok. Segmentasi pelanggan dapat dilakukan melalui metode clustering. Penelitian ini menganalisis RFM pelanggan dari hasil segmentasi 5 kedai kopi kontemporer yaitu Janji Jiwa, Kopi Kenangan, Tomoro Coffee, Fore Coffee dan Fami Café, dari riset analisis persona dan segmentasi minat konsumen terhadap kedai kopi kontemporer (Passalaras et al., 2024).

Tabel 2. 1 Penelitian Terdahulu

NO	Researcher(s)	R	F	M	L	K-Means Clustering	Machine Learning	METHOD
1	(Lewaaelhamd, 2023)	√	√	√		√	√	RFM and ML
2	(Jamshidi et al., 2024)	√	√	√				RFM
3	(Sunarko et al., 2025)	√	√	√				RFM
4	(Wilbert et al., 2023)	√	√	√		√		RFM
5	(Li et al., 2022)	√	√	√		√		RFM
6	(Xu et al., 2023)	√	√	√		√		RFM
7	(Gholamveisy et al., 2024)	√	√	√		√		RFM
8	(Wu et al., 2020)	√	√	√		√		RFM
9	(Sarkar et al., 2024)	√	√	√		√		RFM
10	(Arefin et al., 2024)	√	√	√		√		RFM
11	(Wassouf et al., 2020)	√	√	√		√		RFM

12	(Alet Vilagínés, 2020)	√	√	√		√		RFM
13	(Ramkumar et al., 2025)	√	√	√		√		RFM
14	(Robo et al., 2024)	√	√	√		√		RFM
15	(Wulansari & Heikal, 2024)	√	√	√		√		RFM
16	(Dinda et al., 2024)	√	√	√		√		RFM
17	(Syahra et al., 2025)	√	√	√		√		RFM
18	(Silveira et al., 2020)	√	√	√		√		RFM
19	(Gustriansyah et al., 2019)	√	√	√		√		RFM
20	(Akazue et al., 2024)	√	√	√		√		RFM
21	(Bagul et al., 2021)	√	√	√		√		RFM
22	(Zamil & Vasista, 2021)	√	√	√		√		RFM

23	(Smaili & Hachimi, 2023)	√	√	√		√		RFM
24	(Setiawan et al., 2025)	√	√	√		√		RFM
25	(Passalaras et al., 2024)	√	√	√		√		RFM
26	(Kaswa, 2016)	√	√	√	√	√		RFML

Pada tabel 2.1 memaparkan bahwa penelitian terdahulu umumnya menerapkan model RFM dasar dengan metode K-Means Clustering saja, berbeda dengan penelitian ini yang menambahkan variabel baru yaitu Lifetime (L) ke dalam model RFM. Variabel ini mempertimbangkan durasi hubungan jangka panjang antara pelanggan dan toko. Hal ini memberikan dasar lebih kuat dalam perumusan strategi bisnis untuk menjaga loyalitas pelanggan.

2.2 Kajian Deduktif

Kajian deduktif digunakan sebagai acuan dari teori-teori dan prinsip yang sesuai dengan permasalahan yang terlibat dalam penelitian:

1. Business Intelligence

Kecerdasan Bisnis (BI) adalah proses berbasis teknologi yang berkontribusi dalam mengungkap posisi organisasi dibandingkan dengan pesaingnya, kondisi pasar, dan tren masa depan, serta menyajikan informasi demografis dan ekonomi (Fabian, 2023). Kerangka kerja BI, atau sistem BI merujuk pada sistem yang mencakup berbagai program perangkat lunak yang membantu pengorganisasian dan pengelolaan data serta informasi berharga lainnya di dalam organisasi. Sebagian besar, kerangka kerja ini melibatkan penambangan data, pemrosesan daring, pelaporan, dan kueri (Mositsa et al., 2023). Sistem *Business Intelligence* (BI) adalah sistem yang menyediakan transformasi dari data menjadi informasi atau pengetahuan untuk memberikan solusi bagi aplikasi perusahaan (Gurcan et al., 2023).



Gambar 2. 1 Langkah-langkah proses kerja Business Intelligence
 Sumber : (Saabith et al., 2022)

2. RFM (*Recency, Frequency, Monetary*)

RFM (*Recency, Frequency, Monetary*) merupakan teknik penambangan data terpenting yang digunakan untuk mengkategorikan pelanggan ke dalam domain manajemen hubungan dan pemasaran dengan kontribusi tinggi, sel RFM mencakup lima kuintil yang sama dengan 20% kelompok. Semua pelanggan disajikan dalam bentuk kode sebagai 555, 554, 553....111, yang menghasilkan $5 \times 5 \times 5 = 125$ sel. Dengan demikian, segmen pelanggan terbaik dilambangkan dengan 555 dan segmen pelanggan terburuk dilambangkan dengan 111. Berdasarkan skor RFM, pelanggan dapat dikelompokkan ke dalam segmen yang berbeda dan dengan demikian profitabilitas mereka dapat dianalisis lebih lanjut (Zamil & Vasista, 2021).

3. *Clustering*

Clustering sering disebut sebagai segmentasi data dalam beberapa aplikasi karena pengelompokan data besar ke dalam kelompok-kelompok yang memiliki kesamaan dengan kelompok tersebut. Clustering adalah proses pengelompokan dataset fisik dan abstrak dari objek ke dalam kelompok objek yang memiliki kesamaan. Clustering merupakan metode yang banyak digunakan dalam berbagai

bidang seperti segmentasi pelanggan, perilaku pelanggan, profitabilitas pelanggan, pengumpulan data kebakaran hutan dan sebagainya. Berbagai algoritma digunakan dalam clustering, salah satunya adalah algoritma K-means yang paling sering digunakan (Marisa et al., 2020).

4. K-means

K-means merupakan salah satu metode algoritma pembelajaran mesin dari pengelompokan partisi, metode ini telah populer dan masuk dalam 10 besar yang paling banyak digunakan dalam penambangan data dan penemuan pengetahuan sejak tahun 2000-an. Agar algoritma K-means dapat bekerja dengan data kategorikal, maka harus membuat kode data tersebut ke dalam format numerik (Ho et al., 2023).

BAB III

METODE PENELITIAN

3.1 Objek dan Subjek Penelitian

Objek penelitian ini adalah data historis pada toko retail batik yang berlokasi di kota Magelang. Data tersebut mencakup informasi mengenai jumlah transaksi, frekuensi pembelian, nilai belanja, serta identitas pelanggan.

Subjek penelitian ini adalah pelanggan toko retail batik yang telah melakukan pembelian dalam periode tertentu. Pelanggan yang menjadi subjek penelitian dipilih karena mereka memberikan data transaksi yang dapat diolah untuk analisis RFM dan analisis *K-Means Clustering*.

3.2 Ruang Lingkup Penelitian

Adapun ruang lingkup penelitian yang dilakukan ini dibatasi pada hal-hal sebagai berikut:

1. Analisis hanya menggunakan data historis transaksi pelanggan toko retail batik dalam periode penelitian.
2. Data penelitian dibatasi pada periode transaksi selama penelitian dan telah melalui proses data *cleaning* untuk mengurangi pengaruh nilai ekstrem (*outlier*) yang dapat mempengaruhi hasil analisis RFML dan *K-Means Clustering*
3. Model yang digunakan adalah RFM⁺ (*Recency, Frequency, Monetary, Lifetime*) dan analisis *K-Means Clustering* untuk mengukur perilaku pelanggan.

4. Hasil penelitian difokuskan pada segmentasi pelanggan berdasarkan skor RFM⁺ dan *K-Means Clustering* yang digunakan untuk memberikan rekomendasi strategi bisnis dan pemasaran.
5. Penelitian ini tidak membahas faktor eksternal seperti tren pasar, kondisi makroekonomi, maupun strategi pesaing secara mendalam.

3.3 Pengumpulan Data

Adapun metode pengumpulan data yang digunakan dalam penelitian ini adalah sebagai berikut :

3.3.1 Data Primer

1. Observasi langsung pada toko retail batik untuk memahami proses bisnis, sistem pencatatan transaksi, dan interaksi pelanggan.
2. Wawancara dengan manajemen atau staf yang menangani data pelanggan dan transaksi, guna mendapatkan informasi tambahan terkait strategi pemasaran yang sudah dijalankan.

3.3.2 Data Sekunder

1. Data transaksi penjualan pelanggan yang diperoleh dari sistem kasir atau point of sales toko retail batik. Data ini meliputi ID pelanggan, tanggal transaksi, frekuensi pembelian, serta nilai belanja.
2. Literatur dan penelitian terdahulu mengenai penerapan RFM dan *K-Means* pada bisnis ritel sebagai landasan teori dan pembandingan hasil penelitian

3.4 Alat dan Bahan Penelitian

Adapun metode pengumpulan data yang digunakan dalam penelitian ini adalah sebagai berikut :

3.4.1 Alat Penelitian

1. Microsoft Excel yang digunakan untuk data awal, pengolahan sederhana, dan validasi data transaksi.
2. Microsoft Power BI yang digunakan sebagai alat utama analisis Business Intelligence, meliputi:
 - a. Data modelling untuk menghubungkan tabel transaksi dan pelanggan.
 - b. Implementasi formula untuk menghitung nilai RFML. Adapaun rumus yang digunakan sebagai berikut :

$$R_i = t_p - t_i \quad (1)$$

Dengan :

R_i adalah nilai recency pada pelanggan ke- i

t_i adalah waktu transaksi yang terakhir kali dilakukan oleh pelanggan ke- i

t_p adalah waktu acuan yang ditetapkan untuk penelitian

$$F_i = \sum_{j=1}^n a_{i,j} \quad (2)$$

Dengan :

F_i adalah nilai frequency pada pelanggan ke- i

i adalah banyaknya pelanggan

n adalah banyaknya transaksi selama periode penelitian

$a_{i,j}$ adalah pemesanan yang dilakukan oleh pelanggan ke- i

$$M_i = \sum_{j=1}^n b_i, \quad (3)$$

Dengan :

M_i adalah nilai monetary pada pelanggan ke- i

i adalah banyaknya pelanggan

n adalah banyaknya transaksi selama periode penelitian

$b_{i,j}$ adalah pengeluaran yang dilakukan pelanggan ke- i dalam bertransaksi selama penelitian

$$L_i = T_i^{\text{last}} - T_i^{\text{first}} \quad (4)$$

Dengan :

L_i adalah nilai lifetime pelanggan ke- i

T_i^{last} adalah tanggal transaksi terakhir pelanggan ke- i

T_i^{first} adalah tanggal transaksi pertama pelanggan ke- i

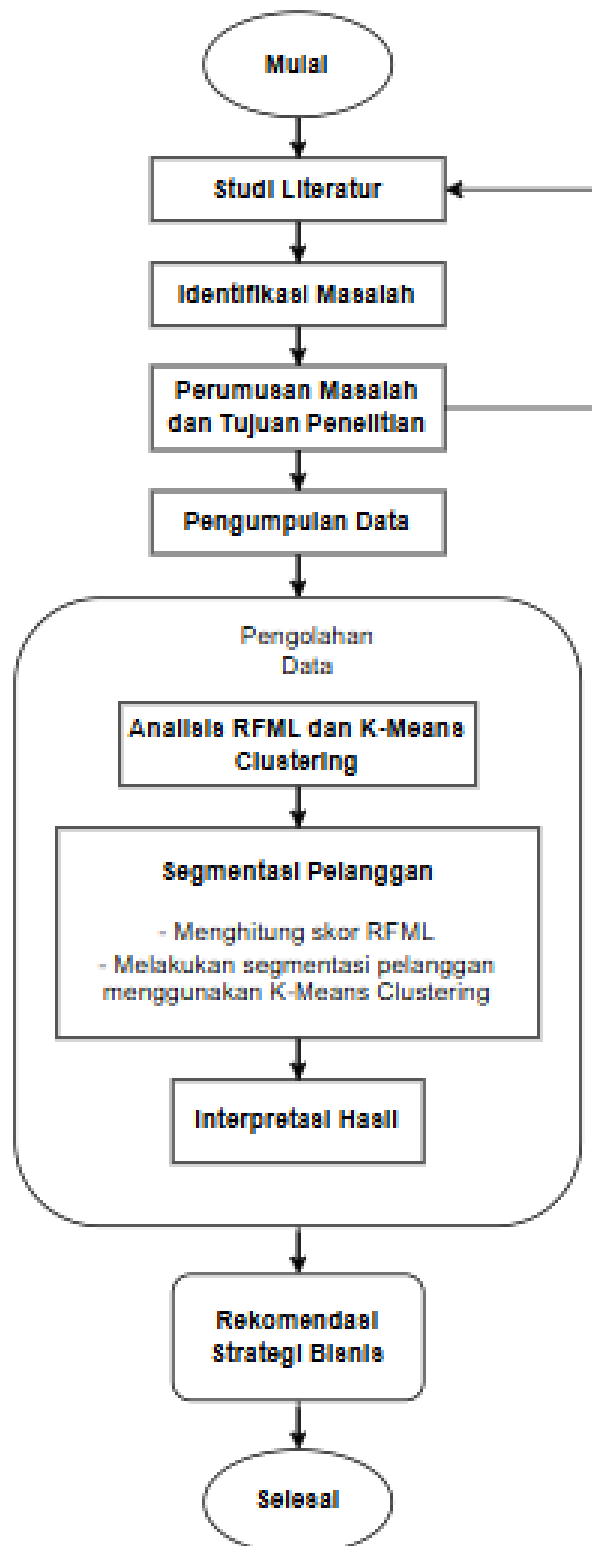
- c. Visualisasi hasil analisis dalam dashboard interaktif yang memudahkan interpretasi data.
3. Literatur/Jurnal Ilmiah yang digunakan sebagai acuan teori dan pembandingan hasil penelitian.

3.4.2 Bahan Penelitian

1. Dataset transaksi pelanggan toko retail batik yang berisi ID pelanggan, tanggal transaksi, jumlah transaksi, dan nilai transaksi.
2. Dataset data pelanggan yang berisi identitas dasar pelanggan seperti nomor ID dan lama berlangganan.

3.5 Alur Penelitian

Pada gambar 3.1 merupakan diagram alir penelitian untuk analisis RFM dan analisis *K-Means Clustering* pada toko retail batik yang diteliti :



Gambar 3. 1 Diagram alir penelitian

BAB IV

PENGUMPULAN DAN PENGOLAHAN DATA

4.1 Gambaran Umum Data Penelitian

Data transaksi pelanggan diolah menggunakan Power BI untuk mendapatkan nilai Recency, Frequency, Monetary dan Lifetime. Keempat variabel ini merupakan dasar untuk mengetahui perilaku pembelian pelanggan. Setelah transformasi data, diperoleh tabel RFML Pelanggan yang berisi Customer ID, recency (R) yaitu selisih hari dari transaksi terakhir, frequency (F) yaitu jumlah transaksi pelanggan, monetary (M) yaitu total nilai pembelian pelanggan, lifetime : (L) yaitu lama menjadi pelanggan

4.2 Periode Pengumpulan Data

Data transaksi yang digunakan dalam penelitian ini merupakan data historis pelanggan dalam satu periode penelitian tertentu. Periode ini dipilih untuk merepresentasikan perilaku pembelian pelanggan secara konsisten dan berkelanjutan, sehingga hasil analisis yang diperoleh dapat mencerminkan kondisi riil pelanggan toko ritel batik. Jumlah data pelanggan yang dianalisis terdiri dari puluhan hingga ratusan pelanggan unik, dengan masing-masing pelanggan memiliki riwayat transaksi yang berbeda-beda. Keberagaman data ini memungkinkan proses segmentasi pelanggan dilakukan secara lebih akurat. Data pelanggan yang diambil dari periode 2023 sampai dengan 2025 ada pada tabel 4.1.

Gambar 4. 1 Data Transaksi periode 2023-2025

TransactionID	CustomerID	ProductID	InvoiceDate	Quantity	UnitPrice	DiscountPct	Channel	PaymentMethod	ShipToCity	ShipToProvince
T101106	C1094	P105	2023-02-03	2	18.68	0.15	Online	Cash	Solo	Jawa Tengah
T100336	C1129	P128	2023-02-09	1	27.65	0	Marketplace	Transfer	Sleman	DI Yogyakarta
T101091	C1176	P151	2023-02-09	2	100.78	0	Marketplace	Cash	Magelang	Jawa Tengah
T100424	C1088	P109	2023-02-13	1	23.1	0	Marketplace	Credit Card	Surabaya	Jawa Timur
T100680	C1217	P147	2023-02-15	2	29.03	0	Marketplace	Transfer	Bandung	Jawa Barat
T101144	C1056	P148	2023-03-04	1	19.34	0	Retail Store	Transfer	Bogor	Jawa Barat
T100595	C1194	P153	2023-03-04	3	15.63	0	Reseller	Cash	Bandung	Jawa Barat
T100442	C1234	P103	2023-03-08	1	26.56	0	Reseller	Cash	Gunungkidul	DI Yogyakarta
T100427	C1061	P113	2023-03-12	1	21.02	0	Online	Transfer	Depok	Jawa Barat
T100029	C1022	P120	2023-03-15	1	28.33	0	Marketplace	E-Wallet	Solo	Jawa Tengah
T100014	C1232	P117	2023-03-17	1	141.52	0	Retail Store	Transfer	Gunungkidul	DI Yogyakarta
T100941	C1030	P159	2023-03-19	1	16.99	0	Reseller	Credit Card	Jakarta	DKI Jakarta
T100486	C1058	P113	2023-03-21	1	22.42	0	Reseller	E-Wallet	Sleman	DI Yogyakarta
T100502	C1039	P124	2023-03-21	1	29.13	0	Retail Store	Cash	Solo	Jawa Tengah
T100875	C1042	P158	2023-03-26	1	17.93	0	Reseller	Transfer	Sleman	DI Yogyakarta
T100737	C1234	P139	2023-04-04	1	70.27	0	Retail Store	Credit Card	Gunungkidul	DI Yogyakarta
T100622	C1080	P123	2023-04-04	1	22.2	0	Marketplace	Credit Card	Bogor	Jawa Barat
T101066	C1005	P115	2023-04-08	1	31.73	0.15	Online	Credit Card	Sleman	DI Yogyakarta
T100911	C1026	P126	2023-04-09	1	27.94	0	Reseller	Cash	Jakarta	DKI Jakarta
T100783	C1192	P144	2023-04-09	1	12.29	0	Online	Transfer	Magelang	Jawa Tengah

4.3 Pra- Pengolahan Data

Sebelum dilakukan analisis, data transaksi terlebih dahulu melalui tahap pra-pengolahan untuk memastikan kualitas data. Tahapan pra-pengolahan data meliputi:

4.3.1 Pembersihan Data

Tahap pembersihan data dilakukan untuk menghilangkan kesalahan dan ketidakkonsistenan dalam data dimana proses ini meliputi menghapus data duplikat pelanggan dan transaksi, memeriksa dan memperbaiki data yang tidak lengkap atau kosong, menyeragamkan format tanggal transaksi dan format nilai transaksi. Langkah ini penting untuk menghindari bias dan kesalahan dalam perhitungan nilai RFM+.

4.3.2 Transform Data

Data transaksi kemudian ditransformasikan agar sesuai dengan kebutuhan analisis. Proses transformasi meliputi, pengelompokan data transaksi berdasarkan ID pelanggan, konversi data tanggal menjadi selisih hari untuk perhitungan recency, penyesuaian nilai transaksi agar berada dalam satuan yang seragam. Transformasi data ini dilakukan menggunakan Microsoft Excel dan Power BI sebagai alat bantu utama.

4.4 Pengolahan Data Menggunakan Model RFML

4.4.1 Perhitungan Recency

Recency dihitung berdasarkan selisih hari antara tanggal transaksi terakhir pelanggan dengan tanggal acuan penelitian. Semakin kecil nilai recency, semakin baru pelanggan melakukan transaksi, yang mengindikasikan tingkat keaktifan pelanggan yang lebih tinggi.

4.4.2 Perhitungan Frequency

Frequency dihitung berdasarkan jumlah transaksi yang dilakukan oleh masing-masing pelanggan selama periode penelitian. Nilai frequency mencerminkan intensitas interaksi pelanggan dengan toko ritel batik.

4.4.3 Perhitungan Monetary

Monetary merupakan total nilai belanja pelanggan selama periode penelitian. Nilai ini digunakan untuk mengukur kontribusi finansial pelanggan terhadap pendapatan toko.

4.4.4 Perhitungan Lifetime

Lifetime dihitung berdasarkan lamanya pelanggan tercatat sebagai pelanggan toko, yang diperoleh dari selisih antara tanggal transaksi pertama dan tanggal transaksi terakhir pelanggan. Variabel ini digunakan untuk menggambarkan kekuatan hubungan jangka panjang antara pelanggan dan toko.

4.4.5 Penentuan Skor RFML

Setiap variabel RFM+ kemudian dikonversi ke dalam skor tertentu berdasarkan interval atau kuintil yang telah ditentukan. Skor ini digunakan untuk mengklasifikasikan pelanggan ke dalam segmen-segmen tertentu seperti Champion, Potential Loyalist, At Risk, Lost, dan New Customer.

Pada tabel 4.2 terdapat hasil perhitungan semua variabel RFML dan hasil segmentasi pelanggan.

Tabel 4. 2 Hasil perhitungan RFML (Recency, Frequency, Monetary, Lifetime)

CustomerID	Recency	Frequency	MonetaryTotal	Lifetime
C1094	265	10	436	673
C1129	50	7	338	882
C1176	23	8	1112	909
C1088	92	5	203	836
C1217	149	8	352	777
C1056	104	5	275	805
C1194	170	5	268	739
C1234	106	9	412	799
C1061	112	10	630	789
C1022	221	7	611	677
C1232	25	6	445	871
C1030	14	6	199	880
C1058	212	6	467	680
C1039	215	7	196	677
C1042	79	11	884	808
C1080	100	6	133	778
C1005	136	4	171	738
C1026	140	5	300	733
C1192	116	6	399	757
C1184	359	2	131	512
C1040	31	5	851	834
C1008	164	3	228	695
C1165	333	7	554	510
C1064	80	3	229	763
C1046	22	6	342	817
C1141	26	7	780	812
C1131	200	5	666	638
C1186	446	4	108	385
C1024	417	4	127	411
C1093	151	6	475	676
C1201	40	8	206	786
C1149	187	3	164	637
C1152	56	9	522	766
C1204	358	5	223	461
C1209	307	4	130	511

Tabel 4.2 menyajikan hasil perhitungan nilai Recency, Frequency, Monetary, dan Lifetime (RFML) untuk setiap pelanggan berdasarkan data transaksi yang telah melalui tahap pra-pengolahan. Nilai recency menunjukkan selisih waktu antara tanggal transaksi terakhir pelanggan dengan tanggal acuan penelitian. Semakin kecil nilai recency, semakin baru pelanggan melakukan transaksi, yang mengindikasikan tingkat keaktifan pelanggan yang lebih tinggi. Variabel frequency merepresentasikan jumlah transaksi yang dilakukan oleh pelanggan selama periode penelitian. Nilai monetary menunjukkan total nilai belanja pelanggan selama periode penelitian. Sementara itu, variabel Lifetime menggambarkan lamanya hubungan pelanggan dengan toko. Hasil perhitungan RFML menunjukkan adanya variasi karakteristik perilaku pelanggan, baik dari sisi keaktifan, intensitas pembelian, nilai transaksi, maupun durasi hubungan.

4.5 Segmentasi Pelanggan Menggunakan K-Means Clustering

Setelah diperoleh skor RFM+, data pelanggan selanjutnya dianalisis menggunakan metode K-Means Clustering untuk mendukung pembentukan segmentasi pelanggan secara otomatis. Proses clustering diintegrasikan ke dalam Power Query sebagai bagian dari sistem Business Intelligence. Algoritma K-Means mengelompokkan pelanggan ke dalam lima cluster, yaitu Cluster 0 hingga Cluster 4, berdasarkan jarak terdekat terhadap pusat cluster yang terbentuk secara otomatis. Setiap pelanggan secara otomatis diberi label cluster sesuai hasil pengelompokan. Label cluster ini digunakan sebagai penguat segmentasi skor RFM+ dan akan diperbarui secara otomatis setiap kali terjadi pembaruan data transaksi. Berikut hasil pengolahan data dari analisis kmeans clustering terdapat pada tabel 4.3.

Tabel 4. 3 Hasil Perhitungan K-Means Clustering

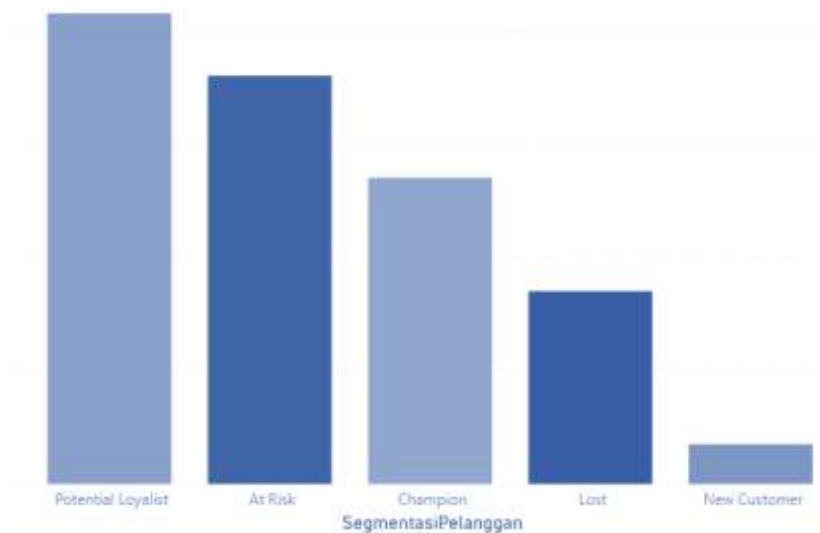
Customer ID	Value Recency	Value Frequency	Value MonetaryTotal	Value Lifetime	Cluster	Cluster Label
C1094	265.0	10	436	673.0	3	Lost
C1176	23.0	8	1112	909.0	0	Champion
C1088	92.0	5	203	836.0	3	Lost
C1217	149.0	8	352	777.0	3	Lost
C1061	112.0	10	630	789.0	0	Champion
C1022	221.0	7	611	677.0	0	Champion
C1080	100.0	6	133	778.0	3	Lost
C1005	136.0	4	171	738.0	1	Potential Loyal
C1026	140.0	5	300	733.0	3	Lost
C1184	359.0	2	131	512.0	2	At Risk
C1040	31.0	5	851	834.0	0	Champion
C1008	164.0	3	228	695.0	1	Potential Loyal
C1165	333.0	7	554	510.0	2	At Risk
C1064	80.0	3	229	763.0	1	Potential Loyal
C1046	22.0	6	342	817.0	3	Lost
C1141	26.0	7	780	812.0	0	Champion
C1131	200.0	5	666	638.0	0	Champion
C1186	446.0	4	108	385.0	2	At Risk
C1024	417.0	4	127	411.0	2	At Risk
C1149	187.0	3	164	637.0	1	Potential Loyal
C1152	56.0	9	522	766.0	0	Champion
C1027	71.0	4	113	731.0	1	Potential Loyal
C1108	36.0	4	264	357.0	1	Potential Loyal
C1015	124.0	2	61	255.0	1	Potential Loyal
C1168	38.0	3	134	337.0	1	Potential Loyal
C1207	58.0	3	227	314.0	1	Potential Loyal
C1235	144.0	7	263	224.0	3	Lost
C1028	342.0	2	64	13.0	4	New Customer

4.6 Implementasi Dashboard Business Intelligence

Dashboard Business Intelligence dikembangkan menggunakan Power BI sebagai media visualisasi hasil pengolahan data dan analisis. Dashboard ini dirancang untuk membantu manajemen dalam memahami pola perilaku pelanggan dan mendukung pengambilan keputusan berbasis data. Dashboard yang dibangun menampilkan beberapa komponen utama, antara lain:

4.6.1 Grafik Distribusi Segmentasi Pelanggan

Visual pada gambar 4.1 menampilkan jumlah pelanggan pada masing-masing segmen RFML seperti Champion, Potential Loyalist, At Risk, Lost dan New Customer. Tujuan visual ini untuk memberikan gambaran umum mengenai komposisi pelanggan toko ritel batik, sehingga management dapat mengetahui segmen pelanggan yang paling dominan dan segmen yang perlu mendapat perhatian khusus.

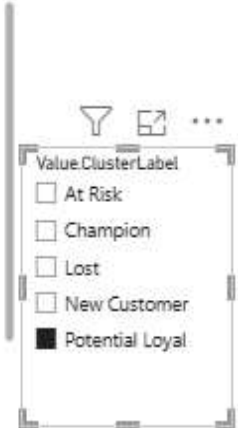


Gambar 4. 4 Distribusi Segmentasi Pelanggan

4.6.2 Filter dan Slicer Interaktif

Visual ini untuk melengkapi analisis pelanggan seperti periode waktu, segmen RFML, dan cluster kmeans. Fitur ini memungkinkan pengguna melakukan analisis secara dinamis dan mendalam sesuai kebutuhan, tanpa harus melakukan perhitungan ulang secara manual. Pada gambar 4.5 merupakan salah satu contoh filter dan slicer untuk pelanggan potential loyalist karena yang di centang atau dipilih pada slicer adalah pelanggan dengan label cluster potential loyalist.

Value.CustomerID	Value.Recency	Value.Frequency	Value.MonetaryTotal	Value.Lifetime	Value.Cluster	Value.ClusterLabel
C1020	67.0	2	87	509.0	1	Potential Loyal
C1027	71.0	4	113	731.0	1	Potential Loyal
C1031	178.0	4	158	445.0	1	Potential Loyal
C1035	88.0	4	115	582.0	1	Potential Loyal
C1036	131.0	5	186	494.0	1	Potential Loyal
C1037	45.0	3	245	265.0	1	Potential Loyal
C1045	153.0	3	57	511.0	1	Potential Loyal
C1047	100.0	3	109	602.0	1	Potential Loyal
C1049	135.0	4	192	652.0	1	Potential Loyal
C1051	16.0	5	438	203.0	1	Potential Loyal
C1060	110.0	4	159	450.0	1	Potential Loyal
C1062	8.0	4	239	548.0	1	Potential Loyal
C1064	80.0	3	229	763.0	1	Potential Loyal
C1069	43.0	4	163	266.0	1	Potential Loyal
C1071	148.0	2	33	365.0	1	Potential Loyal
C1077	51.0	2	53	390.0	1	Potential Loyal
C1081	132.0	3	83	82.0	1	Potential Loyal
C1084	64.0	5	298	372.0	1	Potential Loyal
C1086	25.0	3	81	127.0	1	Potential Loyal
C1089	12.0	5	126	520.0	1	Potential Loyal
C1091	138.0	4	55	552.0	1	Potential Loyal
C1096	140.0	3	217	379.0	1	Potential Loyal
C1100	230.0	2	84	457.0	1	Potential Loyal
C1102	159.0	2	404	336.0	1	Potential Loyal
C1103	168.0	3	216	97.0	1	Potential Loyal
C1104	38.0	3	76	189.0	1	Potential Loyal
C1108	36.0	4	264	357.0	1	Potential Loyal
C1111	34.0	3	120	487.0	1	Potential Loyal
C1114	203.0	5	110	559.0	1	Potential Loyal
C1116	16.0	4	88	307.0	1	Potential Loyal



Gambar 4. 5 Visualisasi slicer tiap segmen

BAB V

PEMBAHASAN

5.1 Pembahasan Nilai RFM⁺

Model RFM⁺ digunakan untuk mengidentifikasi karakteristik perilaku pelanggan berdasarkan aktivitas transaksi dan hubungan jangka panjang pelanggan dengan toko. Penambahan variabel *Lifetime* pada model RFM memberikan perspektif yang lebih komprehensif dibandingkan RFM konvensional karena mempertimbangkan durasi hubungan pelanggan.

5.1.1 Recency

Hasil analisis menunjukkan bahwa nilai *recency* pelanggan bervariasi secara signifikan. Pelanggan dengan nilai *recency* rendah menandakan aktivitas transaksi yang masih baru dan menunjukkan tingkat keterlibatan yang tinggi dengan toko. Sebaliknya, pelanggan dengan nilai *recency* tinggi menunjukkan jarak waktu yang lama sejak transaksi terakhir, sehingga berpotensi mengalami penurunan loyalitas.

Temuan ini sejalan dengan konsep RFM yang menyatakan bahwa semakin baru transaksi terakhir pelanggan, semakin besar kemungkinan pelanggan tersebut melakukan pembelian ulang. Dalam konteks ritel batik, *recency* menjadi indikator awal untuk mendeteksi pelanggan yang mulai pasif dan membutuhkan pendekatan retensi.

5.1.2 Frequency

Variabel *frequency* menggambarkan intensitas pembelian pelanggan selama periode penelitian. Pelanggan dengan *frequency* tinggi umumnya berada pada segmen pelanggan bernilai tinggi, seperti *Champion* dan *Potential Loyalist*. Hal ini

menunjukkan bahwa frekuensi pembelian memiliki hubungan yang kuat dengan loyalitas pelanggan.

Sebaliknya, pelanggan dengan frequency rendah cenderung berada pada segmen *New Customer* atau *Lost*. Kondisi ini mengindikasikan bahwa peningkatan frekuensi transaksi perlu menjadi fokus utama strategi pemasaran, misalnya melalui program loyalitas atau promosi berulang.

5.1.3 Monetary

Variabel *monetary* menunjukkan total nilai belanja pelanggan. Hasil penelitian memperlihatkan bahwa segmen pelanggan loyal memiliki nilai *monetary* yang relatif tinggi dan memberikan kontribusi signifikan terhadap pendapatan toko.

Namun demikian, ditemukan pula pelanggan dengan nilai *monetary* historis tinggi yang saat ini memiliki *recency* besar dan frequency rendah. Pelanggan ini tergolong dalam segmen *At Risk*, yang menunjukkan risiko kehilangan pelanggan bernilai tinggi apabila tidak segera dilakukan strategi retensi yang tepat.

5.1.4 Lifetime

Lifetime menggambarkan lamanya hubungan pelanggan dengan toko. Pelanggan dengan *lifetime* tinggi umumnya memiliki loyalitas yang lebih baik dan berada pada segmen *Champion* dan *Potential Loyalist*. Sebaliknya, pelanggan dengan *lifetime* rendah merupakan pelanggan baru yang masih memerlukan pendekatan khusus agar dapat berkembang menjadi pelanggan loyal.

Integrasi *lifetime* dalam model RFM+ memperkuat analisis segmentasi karena mempertimbangkan aspek hubungan jangka panjang, sehingga hasil segmentasi menjadi lebih relevan untuk perencanaan strategi bisnis berkelanjutan.

5.2 Pembahasan Analisis K-Means Clustering

Hasil penerapan metode K-Means Clustering pada penelitian ini menghasilkan lima cluster pelanggan yang diberi label Cluster 0 hingga Cluster 4, di mana Cluster 0 merepresentasikan pelanggan dengan nilai Frequency dan Monetary tertinggi, sedangkan Cluster 4 merepresentasikan pelanggan dengan nilai terendah. Pembentukan cluster dilakukan secara otomatis melalui Power Query dan digunakan sebagai penguat serta validasi terhadap segmentasi pelanggan berbasis skor RFM+. Pengelompokan ini menunjukkan bahwa K-Means Clustering mampu mengidentifikasi pola perilaku transaksi pelanggan yang konsisten dengan hasil segmentasi RFM+, sehingga memperkuat keakuratan penentuan skor dan segmentasi pelanggan.

5.3.1 Cluster 0 – Pelanggan Bernilai Tertinggi (Champion)

Cluster 0 terdiri dari pelanggan dengan nilai *frequency* dan *monetary* paling tinggi dibandingkan cluster lainnya. Pelanggan dalam cluster ini memiliki intensitas pembelian yang sangat tinggi serta memberikan kontribusi pendapatan terbesar bagi toko ritel batik. Karakteristik Cluster 0 sejalan dengan segmen Champion pada skor RFM+, yaitu pelanggan yang sangat aktif, loyal, dan bernilai tinggi. Kesesuaian ini menunjukkan bahwa K-Means Clustering berhasil memperkuat identifikasi pelanggan inti yang perlu dipertahankan melalui strategi loyalitas dan layanan eksklusif.

5.3.2 Cluster 1 – Pelanggan Potensial Loyal (Potential Loyalist)

Cluster 1 mencakup pelanggan dengan nilai *frequency* dan *monetary* yang tinggi, namun masih berada di bawah Cluster 0. Pelanggan pada cluster ini

menunjukkan pola pembelian yang cukup aktif dan memiliki potensi besar untuk meningkatkan loyalitas. Cluster 1 memperkuat segmen Potential Loyalist pada skor RFM+, yaitu pelanggan yang hampir mencapai kategori Champion. Strategi pemasaran yang tepat, seperti program loyalitas dan promosi pembelian ulang, dapat mendorong pelanggan pada cluster ini naik ke Cluster 0.

5.3.3 Cluster 2 – Pelanggan Menengah (At Risk)

Cluster 2 terdiri dari pelanggan dengan nilai *monetary* yang relatif cukup baik, tetapi memiliki *frequency* yang cenderung menurun. Pola ini menunjukkan bahwa pelanggan dalam cluster ini sebelumnya aktif, namun mulai mengalami penurunan intensitas transaksi. Karakteristik Cluster 2 selaras dengan segmen At Risk pada skor RFM+, yaitu pelanggan bernilai yang berpotensi hilang apabila tidak segera dilakukan strategi retensi. Hasil clustering ini menegaskan pentingnya perhatian khusus terhadap pelanggan dalam cluster ini.

5.3.4 Cluster 3 – Pelanggan Bernilai Rendah (Lost)

Cluster 3 mencakup pelanggan dengan nilai *frequency* dan *monetary* yang rendah. Pelanggan pada cluster ini jarang melakukan transaksi dan memberikan kontribusi pendapatan yang kecil. Cluster 3 memperkuat segmen Lost pada skor RFM+, yaitu pelanggan yang sudah tidak aktif. Upaya reaktivasi dapat dilakukan secara selektif, dengan mempertimbangkan efisiensi biaya pemasaran.

5.3.5 Cluster 4 – Pelanggan Baru (New Customer)

Cluster 4 terdiri dari pelanggan dengan nilai *frequency* dan *monetary* yang rendah karena baru melakukan sedikit transaksi. Meskipun kontribusi saat ini masih terbatas, pelanggan pada cluster ini memiliki potensi untuk berkembang. Cluster 4

sejalan dengan segmen *New Customer* pada skor RFM+, yang menekankan pentingnya strategi onboarding, edukasi produk, dan pengalaman belanja awal yang positif agar pelanggan dapat berkembang menjadi pelanggan loyal.

5.3.6 Peran K-Means Clustering dalam Memperkuat Segmentasi RFM+

Secara keseluruhan, hasil K-Means Clustering dengan label Cluster 0 hingga Cluster 4 menunjukkan kesesuaian yang kuat dengan segmentasi pelanggan berbasis skor RFML. K-Means Clustering berperan sebagai metode pengelompokan pelanggan dari nilai skor RFML secara objektif dan berbasis data. Integrasi K-Means Clustering dalam *Power Query* memungkinkan pembaruan cluster dan skor pelanggan dilakukan secara otomatis setiap kali data transaksi diperbarui. Dengan demikian, sistem *Business Intelligence* yang dibangun mampu menyajikan segmentasi pelanggan yang dinamis, akurat, dan relevan untuk mendukung pengambilan keputusan manajerial.

BAB VI

KESIMPULAN DAN SARAN

6.1 Kesimpulan

Berdasarkan hasil analisis dan pembahasan yang telah dilakukan, penelitian ini menghasilkan beberapa kesimpulan yang secara langsung menjawab rumusan masalah penelitian.

Berdasarkan analisis model RFM+ (Recency, Frequency, Monetary, dan Lifetime), diperoleh nilai RFML yang mampu menggambarkan perilaku pelanggan toko ritel batik secara objektif dan terukur. Nilai recency terkecil menunjukkan tingkat keaktifan pelanggan, frequency mencerminkan intensitas transaksi, monetary menggambarkan kontribusi nilai belanja pelanggan, dan lifetime menunjukkan kekuatan hubungan jangka panjang antara pelanggan dan toko. Hasil perhitungan ini membuktikan bahwa model RFM+ efektif digunakan untuk menganalisis perilaku pelanggan berbasis data transaksi.

Hasil segmentasi pelanggan berdasarkan kombinasi model RFM+ dan analisis K-Means Clustering menunjukkan bahwa pelanggan dapat dikelompokkan ke dalam beberapa segmen dengan karakteristik yang berbeda. Penerapan K-Means Clustering dengan lima cluster (Cluster 0 hingga Cluster 4) berfungsi sebagai penguat segmentasi skor RFM+, di mana cluster dengan nilai tertinggi (Cluster 0) merepresentasikan pelanggan dengan nilai dan loyalitas tertinggi. Kombinasi kedua metode ini menghasilkan segmentasi pelanggan yang lebih objektif, konsisten, dan mudah diinterpretasikan.

Berdasarkan hasil penelitian dan kesimpulan yang diperoleh, maka peneliti dapat memberikan saran strategi sebagai berikut :

Pada jurnal terdahulu menjelaskan bahwa pentingnya memahami kebutuhan dan preferensi pelanggan berdasarkan hasil K-Means clustering untuk mengoptimalkan pengiriman layanan dan mengatasi masalah yang ada di dalam perusahaan (Rahma et al., 2025). Berdasarkan hasil segmentasi pelanggan menggunakan model RFML dan K-Means Clustering, strategi bisnis yang dapat diterapkan oleh toko ritel batik adalah memfokuskan pengelolaan pelanggan berdasarkan nilai dan perilaku transaksinya, dengan mempertahankan segmen Champion sebagai kontributor utama pendapatan, mengembangkan segmen Potential Loyalist menjadi pelanggan loyal, serta menerapkan strategi retensi pada segmen At Risk untuk meminimalkan potensi kehilangan pelanggan. Pendekatan ini sejalan dengan penelitian Akande et al., (2024) dan Ramkumar et al., (2025) yang menyatakan bahwa kombinasi analisis RFM dan K-Means Clustering efektif dalam mendukung pengambilan keputusan strategis berbasis nilai pelanggan serta meningkatkan loyalitas dan profitabilitas jangka panjang. Dengan strategi bisnis yang berorientasi pada nilai pelanggan, perusahaan dapat mengalokasikan sumber daya pemasaran secara lebih efisien dan terarah.

Adapun strategi taktis yang mendukung implementasi strategi bisnis tersebut dilakukan melalui optimalisasi pemasaran digital berbasis segmentasi, seperti promosi terarah melalui media sosial (Instagram, TikTok, dan Facebook), peningkatan penjualan melalui marketplace (Shopee dan Tokopedia), pemanfaatan WhatsApp Business untuk komunikasi personal berdasarkan kategori pelanggan,

serta penggunaan retargeting ads untuk mendorong repeat purchase. Strategi taktis ini didukung oleh temuan Akazue et al., (2024) dan Sarkar et al., (2024) yang menegaskan bahwa integrasi segmentasi RFM dengan eksekusi digital marketing mampu meningkatkan efektivitas kampanye promosi sekaligus mengurangi pemborosan biaya pemasaran. Dengan demikian, penerapan strategi taktis berbasis data memungkinkan toko ritel batik menjalankan pemasaran yang lebih tepat sasaran dan berkelanjutan.

6.2 Saran untuk peneliti selanjutnya

Berdasarkan hasil penelitian ini, berikut adalah saran yang dapat dilakukan untuk peneliti selanjutnya :

1. Menambahkan analisis profitabilitas pelanggan seperti :
 - a. Customer Lifetime Value (CLV)
 - b. Gross Margin per Customer
 - c. Contribution Margin dengan memasukkan profitabilitas, segmentasi pelanggan akan lebih relevan untuk strategi bisnis jangka panjang.
2. Menggunakan time series analysis untuk mendeteksi perubahan perilaku.
3. Mengembangkan model prediksi retensi pelanggan dengan pendekatan prediktif seperti machine learning.

DAFTAR PUSTAKA

- Ahmed Mohamed Ahmed Serwah, KHAW, K. W., Cheang Sharon Peck Yeng, & Alhamzah Alnoor. (2023). Customer analytics for online retailers using weighted k-means and RFM analysis. *Data Analytics and Applied Mathematics (DAAM)*, 4(1), 1–7. <https://doi.org/10.15282/daam.v4i1.9171>
- Akande, O. N., Akande, H. B., Asani, E. O., & Dautare, B. T. (2024). Customer Segmentation through RFM Analysis and K-means Clustering: Leveraging Data-Driven Insights for Effective Marketing Strategy. *International Conference on Science, Engineering and Business for Driving Sustainable Development Goals, SEB4SDG 2024*, 3(1). <https://doi.org/10.1109/SEB4SDG60871.2024.10630052>
- Akazue, M., Esiri, K., & Clive, A. (2024). Application of Rfm Model on Customer Segmentation in Digital Marketing. *Nigerian Journal of Science and Environment*, 22(1), 57–67. <https://doi.org/10.61448/njse221245>
- Alet Vilaginés, J. (2020). Predecir el comportamiento del cliente con la lealtad de activación por periodo. Del RFM al RFMAP. *ESIC Market*, 51(167), 639–667. <https://doi.org/10.7200/esicm.167.0513.4>
- Arefin, S., Parvez, R., Ahmed, T., Ahsan, M., Sumaiya, F., Jahin, F., & Hasan, M. (2024). *Retail Industry Analytics : Unraveling Consumer Behavior through RFM Segmentation and Machine Learning*.
- Bagul, N., Surana, prof. priya, Berad, P., & Khachane, C. (2021). Retail Customer Churn Analysis using RFM Model and K-Means Clustering. *International Journal of Gender*, 10(03), 2040–0748.
- Dinda, (, Pradina, A., Kurniawati, Y., Afwan, A. S., Heikal, J., & Pradina, D. A. (2024). RFM Segmentation and K-Means Clustering of Skincare Product (Case study Scarlett). *Jurnal Sains Dan Teknologi*, 6(2), 213–216. <https://doi.org/10.55338/saintek.v6i2.3644>
- Fabian, S. A. (2023). A Business Intelligence Effectiveness Model. *International Journal of Strategic Decision Sciences*, 14(1), 1–23. <https://doi.org/10.4018/ijds.320513>
- Gholamveysy, S., Homayooni, S., Shemshaki, M., Sheykhani, S., Boozary, P., Tanhaei, H. G., & Akbari, N. (2024). Application of data mining technique for customer purchase behavior via Extended RFM model with focus on BCG matrix from a data set of online retailing. *Journal of Infrastructure, Policy and Development*, 8(7), 1–15. <https://doi.org/10.24294/jipd.v8i7.4426>

- Gurcan, F., Ayaz, A., Menekse Dalveren, G. G., & Derawi, M. (2023). Business Intelligence Strategies, Best Practices, and Latest Trends: Analysis of Scientometric Data from 2003 to 2023 Using Machine Learning. *Sustainability (Switzerland)*, 15(13). <https://doi.org/10.3390/su15139854>
- Gustriansyah, R., Suhandi, N., & Antony, F. (2019). Clustering optimization in RFM analysis based on k-means. *Indonesian Journal of Electrical Engineering and Computer Science*, 18(1), 470–477. <https://doi.org/10.11591/ijeecs.v18.i1.pp470-477>
- Gustriansyah, R., Suhandi, N., & Antony, F. (2020). Clustering optimization in RFM analysis based on k-means. *Indonesian Journal of Electrical Engineering and Computer Science*, 18(1), 470–477. <https://doi.org/10.11591/ijeecs.v18.i1.pp470-477>
- Ho, T., Nguyen, S., Nguyen, H., Nguyen, N., Man, D. S., & Le, T. G. (2023). An Extended RFM Model for Customer Behaviour and Demographic Analysis in Retail Industry. *Business Systems Research*, 14(1), 26–53. <https://doi.org/10.2478/bsrj-2023-0002>
- Jamshidi, R., Rajabpour Sanati, S., & Sadeghi, M. E. (2024). Develop a recommender system based on a novel approach to the RFM customer segmentation model (A Case Study of GreenWeb Co.). *International Journal of Innovation in Engineering*, 4(1), 1–17. <https://doi.org/10.59615/ijie.4.1.1>
- Khalilinezhad, S., Fazlollahtabar, H., Minaei-Bidgoli, B., & Nosratabadi, H. E. (2021). Detecting Valuable Customers Using the Trade Patterns of Financial Transactions Applying Integrated RFM and OLAP. *International Journal of Industrial Engineering and Production Research*, 32(3), 1–15. <https://doi.org/10.22068/ijiepr.32.3.1>
- Khumaidi, A., Wahyono, H., Darmawan, R., Kartika, H. D., Chusna, N. L., & Fauzy, M. K. (2023). RFM-AR Model for Customer Segmentation using K-Means Algorithm. *E3S Web of Conferences*, 465. <https://doi.org/10.1051/e3sconf/202346502005>
- Lewaaelhamd, I. (2023). Customer Segmentation Using Machine Learning Model: An Application of RFM Analysis. *Journal of Data Science and Intelligent Systems*, 2(1), 29–36. <https://doi.org/10.47852/bonviewjdsis32021293>
- Li, P., Wang, C., Wu, J., & Madlenak, R. (2022). An E-commerce Customer Segmentation Method based on RFM Weighted K-means. *Proceedings - 2022 International Conference on Management Engineering, Software Engineering and*

Service Sciences, ICMSS 2022, January, 61–68.

<https://doi.org/10.1109/ICMSS55574.2022.00017>

Maraghi, M., Adibi, M. A., & Mehdizadeh, E. (2020). Using RFM Model and Market Basket Analysis for Segmenting Customers and Assigning Marketing Strategies to Resulted Segments. *Journal of Applied Intelligent Systems and Information Sciences*, 1(1), 35–43. <https://doi.org/10.22034/jaisis.2020.102488>

Marisa, F., Ahmad, S. S. S., Yusof, Z. I. M., Fachrudin, & Aziz, T. M. A. (2020). Segmentation model of customer lifetime value in Small and Medium Enterprise (SMEs) using K-Means Clustering and LRFM model. *International Journal of Integrated Engineering*, 11(3), 169–180.

<https://doi.org/10.30880/ijie.2019.11.03.018>

Meng, X. (2024). *Accounting for Marketing Expenditures : Analyzing the ROI of Advertising and Promotion*. 13. <https://doi.org/10.37421/2168-9601.2024.13.502>

Mositsa, R. J., Van der Poll, J. A., & Dongmo, C. (2023). Towards a Conceptual Framework for Data Management in Business Intelligence. *Information (Switzerland)*, 14(10). <https://doi.org/10.3390/info14100547>

Passalaras, R. A., Daulay, R. Y., & Heikal, J. (2024). Segmentation Strat Egy of Consumer Interest in Contemporary Coffee Shop Using RFM Model. *BUDGETING : Journal of Business, Management and Accounting*, 5(2), 741–756. <https://doi.org/10.31539/budgeting.v5i2.9030>

Rahma, A. A., Faqih, A., & Rinaldi, R. (2025). *Optimalisasi Strategi Pemasaran melalui Segmentasi Pelanggan dengan Analisis RFM dan Algoritma K-Means untuk Bisnis Ritel Marketing Strategy Optimization through Customer Segmentation with RFM Analysis and K-Means Algorithm for Retail Businesses*. 2, 338–351.

<https://doi.org/10.26798/jiko.v9i2.1737>

Ramkumar, G., Bhuvanewari, J., Venugopal, S., Kumar, S., Ramasamy, C. K., & Karthick, R. (2025). Enhancing customer segmentation: RFM analysis and K-Means clustering implementation. *Hybrid and Advanced Technologies*, 70–76.

<https://doi.org/10.1201/9781003559139-9>

Robo, S., Melani, P. I., Fernatyanan, P., Widiatoro, R., Khairul Bariyyah, S., & Komputer, F. I. (2024). The Application of Customers Segmentation Using RFM Analysis Method and K-Means Clustering to Improve Marketing Strategy. *International Journal of Information System & Technology Akreditasi*, 8(158), 200–211.

- Saabith, A. L. S., Vinothraj, T., & Fareez, M. M. M. (2022). *Business Intelligence Tools – Systematic Review*. *10*(10), 394–408.
- Sarkar, M., Puja, aisharyja roy, & Chowdhury, faiaz rahat. (2024). Optimizing Marketing Strategies with RFM Method and K-means Clustering-Based AI Customer Segmentation Analysis. *Determinants of Employee Retention in Pharmaceutical Company: Case of Saudi Arabia, 2709–0876*, 8–22.
<https://doi.org/10.32996/jbms>
- Setiawan, E., Surarso, B., & Nugraheni, D. M. K. (2025). Customer Segmentation Based on Recency, Frequency, Monetary Analysis Using K-Means Algorithms in Apple Ecosystem. *Jurnal Penelitian Pendidikan IPA*, *11*(2), 634–641.
<https://doi.org/10.29303/jppipa.v11i2.10011>
- Silveira, R., Oliveira, B., Carvalho, M., & Matos, T. (2020). A data mining approach for customer segmentation using a SAF-T based business intelligence system. *Proceedings of the 14th IADIS International Conference Computer Graphics, Visualization, Computer Vision and Image Processing 2020, CGVCVIP 2020 and Proceedings of the 5th IADIS International Conference Big Data Analytics, Data Mining and Computational In, M*, 173–180.
https://doi.org/10.33965/bigdaci2020_2020111021
- Smaili, M. Y., & Hachimi, H. (2023). New RFM-D classification model for improving customer analysis and response prediction. *Ain Shams Engineering Journal*, *14*(12), 102254. <https://doi.org/10.1016/j.asej.2023.102254>
- Sunarko, B., Hasanah, U., Hidayat, S., & Rachmawati, R. (2025). Integration of Sentiment Analysis and RFM in Restaurant Customer Segmentation: A 7P-Based CRM Model with Clustering. *Journal of Applied Data Sciences*, *6*(2), 1291–1300.
<https://doi.org/10.47738/jads.v6i2.633>
- Syakra, Y., Fadlil, A., & Yuliansyah, H. (2025). Customer Segmentation Using RFM and K-Means Clustering to Support CRM in Retail Industry. *Sinkron*, *9*(3), 1120–1131.
<https://doi.org/10.33395/sinkron.v9i3.14907>
- Wassouf, W. N., Alkhatib, R., Salloum, K., & Balloul, S. (2020). Predictive analytics using big data for increased customer loyalty: Syriatel Telecom Company case study. *Journal of Big Data*, *7*(1). <https://doi.org/10.1186/s40537-020-00290-0>
- Wilbert, H. J., Hoppe, A. F., Sartori, A., Stefenon, S. F., & Silva, L. A. (2023). Recency, Frequency, Monetary Value, Clustering, and Internal and External Indices for Customer Segmentation from Retail Data. *Algorithms*, *16*(9).

<https://doi.org/10.3390/a16090396>

Wu, J., Shi, L., Lin, W. P., Tsai, S. B., Li, Y., Yang, L., & Xu, G. (2020). An Empirical Study on Customer Segmentation by Purchase Behaviors Using a RFM Model and K -Means Algorithm. *Mathematical Problems in Engineering*, 2020.

<https://doi.org/10.1155/2020/8884227>

Wulansari, S., & Heikal, J. (2024). Analysis Of Customer Segmentation In The Top Three Most Visited E-Commerce Platforms In Indonesia In 2023 Using RFM Model And Clustering Techniques-Siti Wulansari et.al Analysis Of Customer Segmentation In The Top Three Most Visited E-Commerce Platforms I. *Jurnal Scientia*, 13(03), 1164–1174. <https://infor.seaninstitute.org/index.php/pendidikan>

Xu, T., Ma, Y., Ao, C., Qu, M., & Meng, X. H. (2023). a Novel Telecom Customer Churn Analysis System Based on Rfm Model and Feature Importance Ranking. *Interdisciplinary Journal of Information, Knowledge, and Management*, 18, 719–737. <https://doi.org/10.28945/5192>

Zamil, A., & Vasista, T. (2021). Customer Segmentation Using RFM Analysis: Realizing Through Python Implementation-Web of Science Core Collection. *Pacific Business Review International*, 13(11), 24–36. <https://www-webofscience-com.ezproxy.ulima.edu.pe/wos/woscc/full-record/WOS:000696384300003>