Analisis Segmentasi Pelanggan Berbasis RFM Menggunakan K-Means dan Hierarchical Clustering pada Data Transaksi E-Commerce

Randy Ramanda
Sistem Informasi, Universitas Merdeka Malang
e-mail: randyramanda2004@gmail.com

Kata Kunci:

K-Means *Clustering*
Hierarchical *Clustering*
Segmentasi Pelanggan
RFM
Online Retail II

ABSTRAK

Meningkatnya volume transaksi e-commerce menghasilkan data pelanggan yang dapat mendukung analisis perilaku dan segmentasi. Penelitian ini membandingkan performa algoritma K-Means Clustering dan Hierarchical Clustering dalam segmentasi pelanggan berbasis Recency, Frequency, dan Monetary (RFM) pada dataset Online Retail II. Menggunakan pendekatan kuantitatif, penelitian melalui tahap preprocessing data, pembentukan variabel RFM, normalisasi dengan Min-Max Scaling, proses clustering, serta evaluasi menggunakan Silhouette Score dan Davies-Bouldin Index (DBI) pada K=2 hingga K=8. Hasil menunjukkan K=2 memberikan kualitas cluster terbaik pada kedua algoritma, dengan K-Means memperoleh Silhouette Score 0,722570 dan DBI 0,429747, sedangkan Hierarchical memperoleh 0,718027 dan 0,445455. Uji Wilcoxon Signed-Rank menghasilkan p-value 0,078125 (p>0,05), menunjukkan tidak ada perbedaan performa signifikan secara statistik, meskipun K- Means sedikit lebih unggul pada sebagian besar variasi K. Hasil segmentasi ini dapat menjadi referensi dalam pemanfaatan data transaksi untuk strategi pemasaran dan pengelolaan pelanggan pada bisnis digital.

Keywords:

K-Means Clustering
Hierarchical Clustering
Customer Segmentation
RFM
Online Retail II

ABSTRACT

The growing volume of e-commerce transactions generates customer data that can support behavioral analysis and segmentation. This study compares the performance of K-Means Clustering and Hierarchical Clustering algorithms in customer segmentation based on Recency, Frequency, and Monetary (RFM) using the Online Retail II dataset. A quantitative approach was applied, involving data preprocessing, RFM variable construction, Min-Max Scaling normalization, clustering, and evaluation using Silhouette Score and Davies-Bouldin Index (DBI) for K=2 to K=8. Results show that K=2 produced the best cluster quality for both algorithms, with K-Means achieving a Silhouette Score of 0.722570 and DBI of 0.429747, while Hierarchical achieved 0.718027 and 0.445455, respectively. The Wilcoxon Signed-Rank Test yielded a p- value of 0.078125 (p>0.05), indicating no statistically significant performance difference, although K-Means slightly outperformed across most K values. These segmentation results can serve as a reference for leveraging transaction data to support marketing strategies and customer management in digitally driven businesses.

Copyright © SENASIF 2026
ISSN: 2598-0076

I. PENDAHULUAN

Transformasi digital telah mendorong perubahan dalam aktivitas perdagangan melalui perkembangan platform e-commerce. Peningkatan penggunaan internet dan perubahan perilaku konsumen dalam melakukan pembelian secara online menyebabkan aktivitas transaksi digital semakin berkembang. Kondisi tersebut menghasilkan data transaksi pelanggan dalam jumlah besar yang dapat dimanfaatkan untuk memahami perilaku pelanggan dan mendukung penyusunan strategi pemasaran yang lebih sesuai dengan karakteristik pelanggan [4], [12]. Data pelanggan yang semakin besar membutuhkan pengolahan menggunakan teknik analisis yang tepat agar dapat menghasilkan informasi yang mendukung pengambilan keputusan. Pemanfaatan customer analytics dapat membantu mengubah data transaksi menjadi informasi yang dapat digunakan dalam memahami pelanggan, meningkatkan kualitas layanan, serta mendukung aktivitas pemasaran [2].

Salah satu pendekatan yang dapat digunakan untuk memahami karakteristik pelanggan adalah Recency, Frequency, dan Monetary (RFM). RFM merepresentasikan pelanggan berdasarkan tiga karakteristik transaksi, yaitu waktu sejak transaksi terakhir, frekuensi transaksi, dan nilai transaksi. Pendekatan tersebut dapat digunakan untuk menggambarkan perilaku pelanggan berdasarkan riwayat transaksi dan menjadi dasar dalam proses segmentasi pelanggan [5]. Penerapan RFM dalam segmentasi pelanggan telah dilakukan pada data transaksi e-commerce menggunakan K-Means dan menunjukkan bahwa karakteristik pelanggan dapat dikelompokkan berdasarkan pola transaksi yang dimiliki [6], [10]. Pendekatan RFM juga digunakan dalam analisis segmentasi pelanggan e-commerce [3]. Dengan demikian, penggunaan RFM dapat memberikan representasi karakteristik pelanggan yang selanjutnya dapat digunakan dalam proses clustering.

Proses clustering memungkinkan pelanggan dikelompokkan berdasarkan kesamaan karakteristik yang dimiliki. K-Means Clustering merupakan metode yang melakukan pengelompokan berdasarkan kedekatan data terhadap pusat cluster, sedangkan Hierarchical Clustering membentuk kelompok secara bertahap berdasarkan tingkat kemiripan antarobjek. Perbedaan mekanisme kedua algoritma tersebut dapat menghasilkan kualitas cluster yang berbeda sehingga pemilihan algoritma perlu disesuaikan dengan karakteristik data yang dianalisis [14], [8]. Penelitian terdahulu juga telah membandingkan algoritma K-Means dan Hierarchical Clustering dalam pengelompokan data maupun segmentasi pelanggan. Penelitian berbasis RFM menunjukkan bahwa performa algoritma clustering dapat dibandingkan menggunakan ukuran kualitas cluster untuk mengetahui metode yang lebih sesuai pada data yang digunakan [9]. Penelitian lain yang menggunakan K-Means dan Hierarchical Clustering untuk segmentasi pelanggan juga menunjukkan bahwa kedua metode dapat menghasilkan kelompok pelanggan berdasarkan karakteristik transaksi [13].

Meskipun berbagai penelitian telah menerapkan RFM dan clustering dalam segmentasi pelanggan, hasil pengelompokan dapat berbeda berdasarkan dataset, karakteristik pelanggan, jumlah cluster, dan metode clustering yang digunakan. Oleh karena itu, diperlukan penelitian yang membandingkan K-Means Clustering dan Hierarchical Clustering pada dataset transaksi yang sama dengan pendekatan RFM dan evaluasi yang sama. Penelitian ini menggunakan dataset Online Retail II yang berisi data transaksi pelanggan pada aktivitas e-commerce. Tahapan penelitian meliputi preprocessing data, pembentukan variabel RFM, normalisasi data menggunakan Min-Max Scaling, proses clustering menggunakan K-Means dan Hierarchical Clustering, serta evaluasi hasil clustering menggunakan Silhouette Score dan Davies-Bouldin Index (DBI). Pengujian dilakukan pada jumlah cluster K=2 hingga K=8 untuk mengetahui konfigurasi cluster yang memberikan hasil optimal.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk menganalisis dan membandingkan performa algoritma K-Means Clustering dan Hierarchical Clustering dalam melakukan segmentasi pelanggan berbasis RFM pada data transaksi e-commerce. Selain membandingkan performa kedua algoritma, penelitian ini juga menganalisis karakteristik pelanggan pada cluster yang terbentuk. Hasil segmentasi diharapkan dapat menjadi referensi bagi usaha yang telah memanfaatkan transaksi digital, termasuk UMKM, dalam mengelompokkan pelanggan berdasarkan karakteristik transaksi sebagai dasar pengelolaan pelanggan dan penyusunan strategi pemasaran yang lebih terarah.

Copyright © SENASIF 2026
ISSN: 2598-0076

II. METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan metode *data mining* melalui teknik *clustering* untuk melakukan segmentasi pelanggan berdasarkan karakteristik transaksi. Data mining dapat digunakan untuk menemukan pola dalam sekumpulan data sehingga informasi yang diperoleh dapat mendukung proses analisis dan pengambilan keputusan [11]. Penelitian dirancang secara komparatif dengan membandingkan algoritma K-Means Clustering dan Hierarchical Clustering menggunakan data dan tahapan pengolahan yang sama. Tahapan penelitian meliputi pengumpulan dataset, *preprocessing*, pembentukan variabel Recency, Frequency, dan Monetary (RFM), normalisasi data, proses *clustering*, evaluasi kualitas *cluster*, serta pengujian statistik. Alur penelitian secara keseluruhan ditunjukkan pada Gambar 1.



Gambar 1. Tahapan Penelitian

Data yang digunakan merupakan data sekunder berupa dataset Online Retail II yang diperoleh dari UCI Machine Learning Repository. Dataset berisi transaksi penjualan ritel daring periode 2010–2011 dengan atribut Invoice, StockCode, Description, Quantity, InvoiceDate, Price, Customer ID, dan Country. Penelitian tidak menggunakan seluruh atribut tersebut karena analisis difokuskan pada pembentukan karakteristik RFM. Atribut yang digunakan terdiri atas Customer ID,

Copyright © SENASIF 2026
ISSN: 2598-0076

Invoice, InvoiceDate, Quantity, dan Price. Customer ID berfungsi sebagai identitas pelanggan, Invoice digunakan untuk menghitung Frequency, InvoiceDate digunakan dalam perhitungan Recency, sedangkan Quantity dan Price digunakan untuk menghitung Monetary.

Tabel 1. Atribut yang Digunakan dalam Penelitian

Atribut	Fungsi
Customer ID	Identifikasi setiap pelanggan
Invoice	Menghitung jumlah transaksi pelanggan
InvoiceDate	Menentukan transaksi terakhir pelanggan
Quantity	Komponen perhitungan nilai transaksi
Price	Komponen perhitungan nilai transaksi

Tahap *preprocessing* dilakukan untuk menghasilkan data yang bersih dan sesuai dengan kebutuhan analisis. Proses tersebut meliputi seleksi atribut, penghapusan data yang tidak memiliki Customer ID, penghapusan data duplikat, penyesuaian format InvoiceDate, serta penyaringan transaksi yang tidak relevan. Transaksi pembatalan yang ditandai dengan nomor Invoice berawalan huruf **C** dikeluarkan karena tidak merepresentasikan transaksi pembelian yang digunakan untuk membentuk karakteristik pelanggan. Setelah proses *preprocessing* selesai, data transaksi digunakan dalam pembentukan variabel RFM.

Data hasil *preprocessing* kemudian ditransformasikan menjadi Recency, Frequency, dan Monetary (RFM) berdasarkan Customer ID. Pendekatan RFM digunakan untuk menggambarkan karakteristik pelanggan berdasarkan aktivitas transaksinya [5], [15]. Recency menunjukkan jarak waktu antara tanggal referensi penelitian dengan transaksi terakhir pelanggan. Frequency menunjukkan tingkat aktivitas transaksi dan dihitung berdasarkan jumlah Invoice unik untuk setiap pelanggan. Monetary menunjukkan total nilai transaksi yang diperoleh dari hasil perkalian Quantity dan Price pada setiap transaksi kemudian dijumlahkan berdasarkan Customer ID. Pendekatan RFM telah banyak digunakan dalam segmentasi pelanggan berbasis transaksi karena mampu merepresentasikan perilaku pelanggan secara terukur [6], [10].

Nilai Recency, Frequency, dan Monetary memiliki rentang yang berbeda sehingga dilakukan normalisasi menggunakan Min-Max Scaling. Normalisasi bertujuan mengubah ketiga variabel ke dalam rentang yang sama, yaitu 0–1, agar atribut dengan nilai yang lebih besar tidak mendominasi proses pembentukan *cluster*. Proses Min-Max Scaling dinyatakan menggunakan Persamaan (1).

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Pada Persamaan (1), x' merupakan nilai hasil normalisasi, x merupakan nilai data sebelum normalisasi, xmin merupakan nilai minimum atribut, dan xmax merupakan nilai maksimum atribut. Normalisasi diterapkan pada Recency, Frequency, dan Monetary menggunakan fungsi MinMaxScaler dari pustaka *scikit-learn*.

Copyright © SENASIF 2026
ISSN: 2598-0076

Data RFM yang telah dinormalisasi selanjutnya digunakan sebagai masukan pada proses *clustering*. Penelitian membandingkan K-Means Clustering dan Hierarchical Clustering. K-Means mengelompokkan data berdasarkan kedekatan setiap objek terhadap titik pusat atau *centroid*. Jarak antara data dan centroid dihitung menggunakan Euclidean Distance sebagaimana ditunjukkan pada Persamaan (2).

$$d(x,y) = \sqrt{\sum_{i=1}^{n}(x_i - y_i)^2} \quad (2)$$

Pada Persamaan (2), d(x,y) merupakan jarak Euclidean antara dua objek, xi merupakan nilai atribut ke-i pada objek pertama, yi merupakan nilai atribut ke-i pada objek kedua, dan n merupakan jumlah atribut. Setiap data ditempatkan pada cluster dengan centroid terdekat, kemudian centroid diperbarui berdasarkan rata-rata anggota cluster. Proses tersebut dilakukan secara berulang hingga posisi centroid stabil.

Pada Hierarchical Clustering digunakan pendekatan *agglomerative*, yaitu setiap objek pada awalnya diperlakukan sebagai *cluster* tersendiri kemudian digabungkan secara bertahap berdasarkan tingkat kedekatannya. Penelitian menggunakan Ward linkage dengan ukuran jarak Euclidean untuk meminimalkan variasi data di dalam setiap kelompok. K-Means dan Hierarchical Clustering diterapkan pada dataset RFM yang sama sehingga hasil kedua metode dapat dibandingkan dalam kondisi analisis yang setara [14], [13].

Pengujian jumlah *cluster* dilakukan pada konfigurasi K=2 hingga K=8. Kualitas masing-masing konfigurasi dievaluasi menggunakan Silhouette Score dan Davies-Bouldin Index (DBI). Silhouette Score digunakan untuk mengetahui tingkat kekompakan objek dalam *cluster* yang sama sekaligus tingkat pemisahannya terhadap *cluster* lain [7]. Perhitungan Silhouette Score dinyatakan pada Persamaan (3).

$$s(i) = \frac{b(i) - a(i)}{max\big(a(i), b(i)\big)} \quad (3)$$

Pada Persamaan (3), *s(i)* merupakan nilai Silhouette untuk data ke-*i*, *a(i)* merupakan rata-rata jarak data terhadap anggota *cluster* yang sama, sedangkan *b(i)* merupakan rata-rata jarak data terhadap *cluster* terdekat lainnya. Nilai Silhouette Score berada pada rentang −1 hingga 1. Nilai yang semakin mendekati 1 menunjukkan bahwa struktur dan pemisahan *cluster* semakin baik [7].

Selain Silhouette Score, penelitian menggunakan Davies-Bouldin Index sebagai metrik evaluasi tambahan. DBI mengukur kualitas *cluster* berdasarkan tingkat penyebaran objek di dalam *cluster* serta tingkat pemisahan antar-*cluster* [13]. Perhitungan DBI dinyatakan pada Persamaan (4).

$$DBI = \frac{1}{K} \sum_{i=1}^{n} max_{i \neq j} \left(\frac{S_{i+S_j}}{M_{ij}}\right) \quad (4)$$

Copyright © SENASIF 2026

ISSN: 2598-0076

Pada Persamaan (4), K merupakan jumlah *cluster*, *Si* dan *Sj* merupakan ukuran penyebaran data terhadap centroid pada *cluster* ke-*i* dan ke-*j*, sedangkan Mij merupakan jarak antara centroid kedua *cluster*. Berbeda dengan Silhouette Score, nilai DBI yang semakin kecil menunjukkan kualitas *cluster* yang semakin baik karena objek dalam kelompok semakin kompak dan pemisahan antar-*cluster* semakin jelas.

Nilai Silhouette Score dan Davies-Bouldin Index dihitung pada seluruh konfigurasi K=2 hingga K=8 untuk K-Means dan Hierarchical Clustering. Konfigurasi dengan Silhouette Score tertinggi dan DBI terendah digunakan sebagai dasar dalam menentukan jumlah *cluster* optimal serta membandingkan kualitas pengelompokan kedua algoritma.

Hasil evaluasi selanjutnya dianalisis menggunakan pengujian statistik untuk mengetahui apakah terdapat perbedaan performa yang signifikan antara K-Means dan Hierarchical Clustering. Pengujian diawali menggunakan Shapiro-Wilk Test terhadap nilai Silhouette Score pada konfigurasi K=2 hingga K=8. Apabila data memenuhi asumsi normalitas, perbandingan dilakukan menggunakan *paired t-test*. Sebaliknya, apabila data tidak memenuhi asumsi normalitas, digunakan Wilcoxon Signed-Rank Test. Pengambilan keputusan dilakukan pada taraf signifikansi α=0,05. Tahap tersebut dilakukan agar perbedaan performa kedua algoritma tidak hanya dinilai berdasarkan selisih nilai metrik secara deskriptif, tetapi juga berdasarkan signifikansi statistiknya.

Seluruh proses pengolahan data mulai dari *preprocessing*, pembentukan RFM, normalisasi, implementasi K-Means dan Hierarchical Clustering, hingga evaluasi dilakukan menggunakan bahasa pemrograman Python melalui Visual Studio Code (VS Code) dengan pustaka Pandas dan *scikit-learn.*

III. HASIL DAN PEMBAHASAN

3.1. Hasil Preprocessing dan Pembentukan RFM

Dataset Online Retail II yang digunakan dalam penelitian terdiri atas 541.910 catatan transaksi periode 2010–2011. Hasil eksplorasi awal menunjukkan adanya data dengan Customer ID kosong dan transaksi pembatalan yang ditandai dengan nomor Invoice berawalan huruf C. Selain itu, atribut StockCode, Description, dan Country tidak digunakan karena tidak berkontribusi langsung terhadap pembentukan Recency, Frequency, dan Monetary (RFM). Oleh karena itu, analisis difokuskan pada atribut Invoice, InvoiceDate, Customer ID, Quantity, dan Price. Unit analisis penelitian adalah pelanggan yang memiliki Customer ID valid. Seluruh transaksi yang memenuhi kriteria preprocessing digunakan sehingga penelitian tidak menerapkan teknik sampling responden. Data diperoleh melalui teknik dokumentasi terhadap dataset publik.

Proses pembersihan data menyebabkan jumlah transaksi berkurang sebagaimana ditunjukkan pada Tabel 2.

Copyright © SENASIF 2026
ISSN: 2598-0076

Tabel 2. Hasil Preprocessing Data

Tahapan	Jumlah Data
Dataset awal	541.910
Setelah menghapus Customer ID kosong	406.830
Setelah menghapus transaksi pembatalan	397.925

Penghapusan Customer ID kosong dilakukan karena transaksi tersebut tidak dapat dikaitkan dengan pelanggan tertentu. Selanjutnya, transaksi pembatalan dikeluarkan sehingga dataset akhir pada tahap ini berjumlah 397.925 transaksi yang dapat digunakan untuk pembentukan RFM.

Data transaksi kemudian dikelompokkan berdasarkan Customer ID sehingga setiap pelanggan memiliki satu nilai Recency, Frequency, dan Monetary. Recency menggambarkan waktu sejak transaksi terakhir, Frequency menunjukkan jumlah transaksi unik, sedangkan Monetary menggambarkan total nilai transaksi pelanggan. Ketiga variabel kemudian dinormalisasi menggunakan Min-Max Scaling agar berada pada skala yang sebanding sebelum proses clustering.



```
print("\nPembentukan RFM")

reference_date = pd.Timestamp("2011-12-10")

print("Reference Date :", reference_date.date())

rfm = df.groupby("Customer ID").agg({
    "InvoiceDate": "max",
    "Invoice": "nunique",
    "TotalPrice": "sum"
})

rfm.rename(columns={
    "InvoiceDate": "LastPurchase",
    "Invoice": "Frequency",
    "TotalPrice": "Monetary"
}, inplace=True)


rfm["Recency"] = (
    reference_date - rfm["LastPurchase"]
).dt.days

rfm = rfm.reset_index()
rfm = rfm[
    [
        "Customer ID",
        "Recency",
        "Frequency",
        "Monetary"
    ]
]

print(rfm.head(10))

print("\nInformasi Dataset RFM")

print("Jumlah Customer :", len(rfm))
```

Gambar 2. Implemantasi Pembentukan Variabel RFM

Pembentukan RFM menghasilkan representasi perilaku transaksi yang lebih ringkas karena riwayat transaksi yang sebelumnya terdiri atas banyak baris diubah menjadi karakteristik pada tingkat pelanggan. Penggunaan RFM sebagai dasar segmentasi sesuai dengan Fauzan dan Alfian [6] yang menunjukkan bahwa Recency, Frequency, dan Monetary dapat digunakan untuk menggambarkan perbedaan aktivitas transaksi pelanggan e-commerce. Wilbert et al. [15] juga menjelaskan bahwa karakteristik tersebut dapat menjadi dasar dalam membentuk kelompok pelanggan berdasarkan pola transaksi.

Copyright © SENASIF 2026
ISSN: 2598-0076

3.2. Hasil Segmentasi Pelanggan

Pengujian K-Means dan Hierarchical Clustering dilakukan menggunakan variasi jumlah cluster K=2 hingga K=8. Berdasarkan hasil evaluasi, konfigurasi K=2 menghasilkan kualitas pengelompokan terbaik pada kedua algoritma sehingga digunakan untuk menganalisis karakteristik pelanggan.

Hasil K-Means menunjukkan adanya perbedaan karakteristik yang jelas antara kedua kelompok sebagaimana disajikan pada Tabel 3.

Tabel 3. Karakteristik Segmen Pelanggan K-Means

Cluster	Recency	Frequency	Monetary	Karakteristik
0	0,110122	0,019813	0,008968	Pelanggan relatif aktif dan bernilai lebih tinggi
1	0,664726	0,002936	0,002317	Pelanggan dengan aktivitas transaksi lebih rendah

Cluster 0 memiliki nilai Recency lebih rendah serta Frequency dan Monetary lebih tinggi dibandingkan Cluster 1. Karakteristik tersebut menunjukkan bahwa pelanggan pada Cluster 0 melakukan transaksi dalam waktu yang relatif lebih baru, bertransaksi lebih sering, dan menghasilkan nilai transaksi lebih tinggi. Sebaliknya, Cluster 1 mempunyai Recency lebih tinggi serta Frequency dan Monetary lebih rendah sehingga menggambarkan pelanggan yang sudah relatif lama tidak bertransaksi dengan intensitas dan nilai pembelian yang lebih rendah.

Hierarchical Clustering menghasilkan pola segmentasi yang searah. Cluster 0 juga menggambarkan pelanggan dengan Recency lebih rendah serta Frequency dan Monetary lebih tinggi, sedangkan Cluster 1 didominasi pelanggan dengan Recency lebih tinggi serta Frequency dan Monetary lebih rendah. Dengan demikian, meskipun mekanisme pembentukan cluster kedua algoritma berbeda, keduanya mampu mengidentifikasi dua pola perilaku pelanggan yang relatif serupa.

Hasil tersebut memperlihatkan bahwa RFM mampu membedakan pelanggan berdasarkan tingkat aktivitas dan kontribusi transaksinya. Temuan ini sejalan dengan penelitian sebelumnya yang menunjukkan bahwa segmentasi berbasis transaksi dapat membantu mengidentifikasi karakteristik kelompok pelanggan sehingga masing-masing kelompok dapat diperlakukan secara berbeda [4], [1]. Hasil segmentasi tersebut memberikan informasi untuk mengenali pelanggan aktif, pelanggan bernilai tinggi, serta pelanggan yang aktivitas transaksinya mulai menurun.

3.3. Perbandingan Performa Algoritma

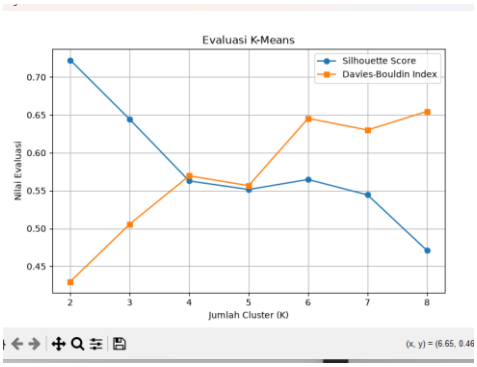
Hasil evaluasi K-Means dan Hierarchical Clustering menggunakan Silhouette Score dan Davies-Bouldin Index (DBI) ditampilkan secara ringkas pada Tabel 4.

Copyright © SENASIF 2026
ISSN: 2598-0076

Tabel 4. Perbandingan Hasil Evaluasi Clustering

K	K-Means Silhouette	K-Means DBI	Hierarchical Silhouette	Hierarchical DBI
2	0,722570	0,429747	0,718027	0,445455
3	0,644307	0,505721	0,632575	0,479209
4	0,562776	0,569563	0,489806	0,626166
5	0,551497	0,556598	0,489069	0,598022
6	0,564720	0,645486	0,477194	0,596211
7	0,544389	0,630105	0,485102	0,614557
8	0,470835	0,654711	0,491998	0,672143

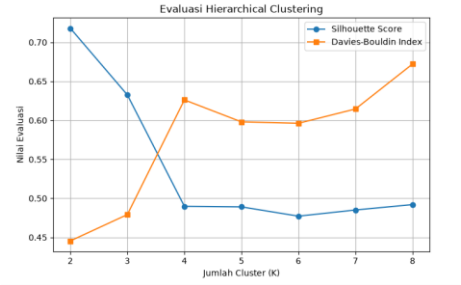
Pada K-Means Clustering, konfigurasi K=2 menghasilkan nilai Silhouette Score tertinggi sebesar 0,722570 dan DBI terendah sebesar 0,429747. Nilai Silhouette Score cenderung menurun ketika jumlah cluster bertambah, sedangkan nilai DBI secara umum meningkat. Kondisi tersebut menunjukkan bahwa pembagian pelanggan ke dalam dua cluster menghasilkan struktur pengelompokan yang lebih baik dibandingkan konfigurasi lainnya.



Gambar 3. Grafik Evaluasi K-Means

Gambar 3 memperlihatkan perubahan nilai Silhouette Score dan Davies-Bouldin Index pada setiap variasi jumlah cluster. Nilai Silhouette Score tertinggi dan DBI terendah berada pada K=2 sehingga konfigurasi tersebut dipilih sebagai jumlah cluster optimal untuk K-Means Clustering.

Selanjutnya, Hierarchical Clustering menunjukkan pola yang relatif serupa. Konfigurasi K=2 menghasilkan Silhouette Score tertinggi sebesar 0,718027 dan DBI terendah sebesar 0,445455. Penambahan jumlah cluster hingga K=8 tidak memberikan peningkatan kualitas pengelompokan, sehingga konfigurasi K=2 juga menjadi konfigurasi terbaik pada Hierarchical Clustering.



Gambar 4. Grafik Evaluasi Hierarchical Clustering

Copyright © SENASIF 2026
ISSN: 2598-0076

Gambar 4 menunjukkan bahwa Silhouette Score Hierarchical Clustering mencapai nilai tertinggi pada K=2 kemudian cenderung menurun pada jumlah cluster berikutnya. Sementara itu, nilai DBI secara umum meningkat ketika jumlah cluster bertambah. Pola tersebut memperkuat hasil pada Tabel 4 bahwa dua cluster merupakan konfigurasi yang paling sesuai untuk data yang digunakan.

Jika dibandingkan secara langsung, K-Means lebih sering menghasilkan Silhouette Score yang lebih tinggi dibandingkan Hierarchical Clustering. Dari sisi DBI, K-Means memperoleh nilai lebih rendah pada beberapa konfigurasi, sedangkan Hierarchical Clustering juga menunjukkan nilai lebih baik pada konfigurasi tertentu. Oleh karena itu, perbedaan performa kedua metode secara deskriptif tidak terlalu besar.

Hasil uji normalitas menunjukkan bahwa data evaluasi K-Means memenuhi asumsi normalitas, sedangkan Hierarchical Clustering tidak. Oleh karena itu, pengujian perbedaan performa dilanjutkan menggunakan Wilcoxon Signed-Rank Test. Hasil pengujian memperoleh p-value sebesar 0,078125, lebih besar dari taraf signifikansi 0,05. Dengan demikian, tidak terdapat perbedaan performa yang signifikan secara statistik antara K-Means dan Hierarchical Clustering. Pada konfigurasi terbaik K=2, selisih Silhouette Score kedua algoritma hanya sekitar 0,63%.

Secara deskriptif, K-Means menunjukkan kecenderungan kualitas cluster yang sedikit lebih baik, tetapi hasil pengujian statistik menunjukkan bahwa performa kedua algoritma relatif sebanding. Temuan tersebut mendukung penelitian Triantara et al. [13] yang menjelaskan bahwa kualitas clustering dapat dipengaruhi oleh karakteristik data, jumlah cluster, tahapan preprocessing, dan metode evaluasi sehingga metode yang memberikan hasil terbaik dapat berbeda pada setiap dataset.

3.4. Implikasi Hasil Segmentasi

Selain membandingkan algoritma, hasil clustering memberikan informasi mengenai karakteristik pelanggan yang dapat digunakan sebagai dasar pengelolaan pelanggan. Cluster 0 menggambarkan pelanggan yang relatif aktif, bertransaksi lebih sering, dan memberikan nilai transaksi yang lebih tinggi sehingga dapat menjadi kelompok yang perlu dipertahankan. Sebaliknya, Cluster 1 menunjukkan pelanggan dengan aktivitas transaksi yang lebih rendah sehingga dapat menjadi kelompok yang perlu mendapat perhatian untuk mendorong aktivitas transaksi kembali. Interpretasi tersebut didasarkan pada perbedaan karakteristik RFM hasil clustering.

Pemanfaatan hasil segmentasi tersebut sejalan dengan Akande et al. [1] yang menyatakan bahwa segmentasi dapat membantu memahami kebutuhan dan perilaku masing-masing kelompok pelanggan sebagai dasar penyusunan pendekatan pemasaran yang lebih sesuai. Awalina dan Rahayu [4] juga menunjukkan bahwa clustering pada data transaksi dapat membantu memahami perilaku pelanggan dan mendukung pengambilan keputusan bisnis.

Copyright © SENASIF 2026
ISSN: 2598-0076

Dalam konteks UMKM yang telah menggunakan transaksi digital, pendekatan ini dapat menjadi referensi untuk memanfaatkan riwayat transaksi sederhana sebagai dasar pengelompokan pelanggan. Hasil pengelompokan dapat membantu membedakan pelanggan yang relatif aktif dan pelanggan dengan aktivitas transaksi yang lebih rendah sehingga pengelolaan pelanggan dapat disesuaikan dengan karakteristik masing-masing kelompok. Namun, penelitian ini menggunakan dataset Online Retail II dan tidak menggunakan data transaksi UMKM secara langsung. Oleh karena itu, manfaat bagi UMKM diposisikan sebagai potensi penerapan hasil penelitian, bukan sebagai bukti empiris bahwa karakteristik dua cluster tersebut secara langsung mewakili pelanggan UMKM.

IV. SIMPULAN

Penelitian ini menunjukkan bahwa pendekatan RFM dapat digunakan untuk membentuk segmentasi pelanggan berdasarkan pola transaksi dengan menggunakan K-Means Clustering dan Hierarchical Clustering. Kedua algoritma mampu menghasilkan kelompok pelanggan dengan karakteristik yang berbeda, yaitu pelanggan yang relatif aktif dengan frekuensi dan nilai transaksi lebih tinggi serta pelanggan dengan aktivitas transaksi yang lebih rendah. K-Means menunjukkan kecenderungan menghasilkan kualitas pengelompokan yang sedikit lebih baik pada data yang digunakan, tetapi secara keseluruhan performa kedua algoritma relatif sebanding sehingga K-Means tidak dapat dinyatakan secara mutlak lebih unggul dibandingkan Hierarchical Clustering.

Hasil segmentasi dapat memberikan informasi mengenai perbedaan karakteristik pelanggan sehingga dapat digunakan sebagai referensi dalam pengelolaan pelanggan dan penyusunan strategi pemasaran yang lebih terarah. Pendekatan ini juga berpotensi dimanfaatkan oleh usaha yang telah memiliki pencatatan transaksi digital, termasuk UMKM, untuk membantu mengelompokkan pelanggan berdasarkan riwayat transaksinya. Namun, karena penelitian menggunakan data transaksi e-commerce dan bukan data UMKM secara langsung, penerapannya pada UMKM perlu disesuaikan dengan karakteristik data dan kondisi masing-masing usaha.

DAFTAR RUJUKAN

[1] O. Akande, E. O. Asani, and B. Dautare, “Customer Segmentation Through RFM Analysis and K-Means Clustering: Leveraging Data-Driven Insights for Effective Marketing Strategy,” *Ceddi Journal of Information System and Technology (JST)*, vol. 3, no. 1, pp. 14–25, 2024, doi: 10.56134/jst.v3i1.81.

[2] M. Alves Gomes and T. Meisen, “A review on customer segmentation methods for personalized customer targeting in e-commerce use cases,” *Information Systems and E-Business Management*, vol. 21, no. 3, pp. 527–570, 2023, doi: 10.1007/s10257-023-00640-4.

[3] F. Amalia Maresti, G. Mustika Anugraheni, R. A. Hargiyanto, and K. Mustaqim, “Penerapan Exploratory Data Analysis (EDA) dan Analisis Recency, Frequency, and Monetary (RFM) untuk Segmentasi Pelanggan E-Commerce,” *Competitive*, vol. 19, no. 1, pp. 14–25, 2024, doi: 10.36618/competitive.v19i1.4059.

[4] E. F. L. Awalina and W. I. Rahayu, “Optimalisasi Strategi Pemasaran dengan Segmentasi Pelanggan Menggunakan Penerapan K-Means Clustering pada Transaksi Online Retail,” *Jurnal Teknologi dan Informasi*, vol. 13, no. 2, pp. 122–137, 2023, doi: 10.34010/jati.v13i2.10090.

Copyright © SENASIF 2026

ISSN: 2598-0076

[5] E. Ernawati, S. S. K. Baharin, and F. Kasmin, "A review of data mining methods in RFM-based customer segmentation," *Journal of Physics: Conference Series*, vol. 1869, no. 1, p. 012085, 2021, doi: 10.1088/1742-6596/1869/1/012085.

[6] R. M. Fauzan and G. Alfian, "Segmentasi Pelanggan E-Commerce Menggunakan Fitur Recency, Frequency, Monetary (RFM) dan Algoritma Klasterisasi K-Means," *JISKA (Jurnal Informatika Sunan Kalijaga)*, vol. 9, no. 3, pp. 170–177, 2024.

[7] R. Hidayati, A. Zubair, A. H. Pratama, and L. Indana, "Analisis Silhouette Coefficient pada 6 Perhitungan Jarak K-Means Clustering," *Techno.Com*, vol. 20, no. 2, pp. 186–197, 2021, doi: 10.33633/tc.v20i2.4556.

[8] Z. Muhammad, "Analisis Perbandingan Algoritma K-Means dan Hierarchial Clustering untuk Pengelompokan Data Penduduk Indeks Pembangunan Manusia pada Kecamatan Percut Sei Tuan," Ph.D. thesis, Universitas Medan Area, 2024. Available: https://repositori.uma.ac.id/jspui/handle/123456789/25388

[9] F. M. Pranata, S. H. Wijoyo, and N. Y. Setiawan, "Analisis performa algoritma K-Means dan DBSCAN dalam segmentasi pelanggan dengan pendekatan model RFM," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 8, no. 7, 2024. Available: https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/13962

[10] R. Siagian, P. S. P. Sirait, and A. Halima, "E-commerce customer segmentation using k-means algorithm and length, recency, frequency, monetary model," *Journal of Informatics and Telecommunication Engineering*, vol. 5, no. 1, pp. 21–30, 2021.

[11] A. Srirahayu and L. S. Pribadie, "Review Paper Data Mining Klasifikasi Data Mining," *Jurnal Ilmiah Informatika Global*, vol. 14, no. 1, 2023, doi: 10.36982/jiig.v14i1.2981.

[12] K. Tabianan, S. Velu, and V. Ravi, "K-Means Clustering Approach for Intelligent Customer Segmentation Using Customer Purchase Behavior Data," *Sustainability*, vol. 14, no. 12, p. 7243, 2022, doi: 10.3390/su14127243.

[13] I. K. Y. Triantara, M. A. Raharja, and I. B. G. Sarasvananda, "Segmentasi Pelanggan Berbasis RFMT Menggunakan K-Means dan Hierarchical Clustering," *Jurnal Nasional Teknologi Informasi dan Aplikasinya*, vol. 3, no. 4, pp. 917–924, 2025.

[14] A. Wasilewski, "Customer segmentation in e-commerce: A context-aware quality model for comparing clustering algorithms," *Journal of Internet Services and Applications*, vol. 15, no. 1, pp. 160–178, 2024.

[15] H. J. Wilbert, A. F. Hoppe, A. Sartori, S. F. Stefenon, and L. A. Silva, "Recency, frequency, monetary value, clustering, and internal and external indices for customer segmentation from retail data," *Algorithms*, vol. 16, no. 9, p. 396, 2023.

Copyright © SENASIF 2026
ISSN: 2598-0076