

Analisis Perubahan Segmentasi Konsumen secara Longitudinal Menggunakan *Time-Based Clustering* pada Data Produk NVIDIA: Studi Kasus Data Shopee

Danie Abdillah Iskandar ^{1*}, Alz Danny Wowor ²

^{1,2} Program Teknik Informatika, Fakultas Teknologi Informasi, Universitas Kristen Satya Wacana, Kota Salatiga, Provinsi Jawa Tengah, Indonesia.

Email: 672021267@student.uksw.edu ^{1*}, alzdanny.wowor@uksw.edu ²

Histori Artikel:

Dikirim 6 April 2026; Diterima dalam bentuk revisi 15 Mei 2026; Diterima 30 Juli 2026; Diterbitkan 10 September 2026. Semua hak dilindungi oleh Lembaga Penelitian dan Pengabdian Masyarakat (LPPM) STMIK Indonesia Banda Aceh.

Abstrak

Penelitian ini menganalisis perubahan segmentasi konsumen secara longitudinal pada data produk Nvidia menggunakan metode time-based clustering. Dengan meningkatnya permintaan produk Nvidia di pasar global terutama untuk GPU gaming dan AI, pemahaman terhadap perubahan perilaku konsumen dari waktu ke waktu menjadi krusial untuk strategi pemasaran. Penelitian menggunakan data transaksi konsumen Nvidia selama 5 tahun (2021-2025) dengan pendekatan RFM-T (Recency, Frequency, Monetary, Time) yang diperkaya dengan Interpurchase Time (IPT). Metode clustering yang digunakan adalah K-Means dengan validasi menggunakan silhouette score, Davis-Bouldin index, dan Calinski-Harabasz index. Hasil penelitian menunjukkan terbentuknya 4 segmen konsumen utama yang mengalami perubahan dinamis: (1) Loyal AI Enthusiasts, (2) Gaming Power Users, (3) Potential Upgraders, dan (4) Churn Risk Customers. Segmentasi longitudinal ini mengungkap pola perubahan dari gaming-centric ke AI-centric seiring perkembangan teknologi AI. Penelitian ini memberikan kontribusi pada pengembangan strategi CRM yang lebih targeted dan retention strategy untuk perusahaan teknologi hardware.

Kata Kunci: Time-Based Clustering; Segmentasi Konsumen Longitudinal; RFM-T; K-Means; Nvidia; Perilaku Konsumen.

Abstract

This study analyzes longitudinal changes in consumer segmentation on Nvidia product data using time-based clustering method. With the increasing demand for Nvidia products in the global market, particularly for gaming GPUs and AI applications, understanding changes in consumer behavior over time becomes crucial for marketing strategy. The research utilizes Nvidia consumer transaction data spanning 5 years (2021-2025) with RFM-T (Recency, Frequency, Monetary, Time) approach enriched with Interpurchase Time (IPT). The clustering method employed is K-Means algorithm with validation using silhouette score, Davis-Bouldin index, and Calinski-Harabasz index. The research results indicate the formation of 4 main consumer segments experiencing dynamic changes: (1) Loyal AI Enthusiasts, (2) Gaming Power Users, (3) Potential Upgraders, and (4) Churn Risk Customers. This longitudinal segmentation reveals a pattern of shift from gaming-centric to AI-centric preferences alongside AI technology development. This study contributes to the development of more targeted CRM strategies and retention strategies for technology hardware companies.

Keyword: Time-Based Clustering; Longitudinal Consumer Segmentation; RFM-T; K-Means; Nvidia; Consumer Behavior.

1. Pendahuluan

Perkembangan teknologi kecerdasan buatan (*AI*) dan komputasi grafis telah mendorong permintaan terhadap produk *Nvidia* secara signifikan dalam lima tahun terakhir. *Nvidia Corporation*, sebagai pemimpin pasar dalam industri *Graphics Processing Unit (GPU)* global, telah mengalami pertumbuhan pendapatan yang luar biasa, dari \$16,68 miliar pada tahun 2021 menjadi \$60,92 miliar pada tahun 2025. Transformasi ini tidak hanya mengubah lanskap industri teknologi tetapi juga mempengaruhi perilaku konsumen secara fundamental (Vendrell-Herrero *et al.*, 2025). Segmentasi konsumen menjadi strategi penting dalam pemasaran yang bertujuan untuk membagi pelanggan ke dalam kelompok berdasarkan karakteristik atau perilaku yang serupa. Segmentasi yang efektif memungkinkan perusahaan untuk memahami kebutuhan dan preferensi masing-masing kelompok, sehingga dapat merancang strategi pemasaran yang lebih tepat sasaran. Namun, dalam konteks produk teknologi seperti yang ditawarkan oleh *Nvidia*, segmentasi tradisional yang bersifat statis tidak lagi memadai. Hal ini disebabkan oleh dinamika perilaku konsumen yang terus berubah seiring dengan perkembangan teknologi *AI* yang menggeser fokus dari gaming ke komputasi *AI*, serta dampak pandemi *Covid-19* yang meningkatkan permintaan *GPU* untuk gaming dan kerja jarak jauh. Perubahan karakter konsumen di era perdagangan bebas juga turut berkontribusi terhadap kompleksitas dalam segmentasi. Dalam situasi ini, siklus upgrade perangkat keras yang berbeda antar segmen konsumen menjadi faktor penting yang harus diperhatikan. Dengan demikian, pemahaman yang mendalam mengenai perilaku konsumen menjadi sangat krusial untuk mengembangkan strategi pemasaran yang efektif.

Penelitian sebelumnya tentang segmentasi pelanggan umumnya menggunakan pendekatan *cross-sectional*, yang hanya melihat data pada satu titik waktu. Pendekatan ini memiliki keterbatasan, karena tidak dapat menangkap perubahan perilaku konsumen secara longitudinal. Sebagai contoh, penelitian oleh Fadhilah *et al.* (2024) menggunakan model *RFM* (Recency, Frequency, Monetary) dengan teknik clustering *K-Means*, agglomerative, dan *DBSCAN*, yang menghasilkan tiga kluster pelanggan. Sementara itu, Mado & Hendry (2025) menerapkan *K-Means* dengan analisis *RFM* untuk e-commerce, yang juga menghasilkan tiga segmen utama. Namun, pendekatan-pendekatan tersebut masih memiliki kekurangan dalam hal fleksibilitas dan kemampuan adaptasi terhadap perubahan perilaku konsumen yang cepat. Penelitian ini bertujuan untuk menganalisis perubahan segmentasi konsumen secara longitudinal menggunakan metode *time-based clustering* pada data produk *Nvidia*. Dengan pendekatan ini, diharapkan dapat dihasilkan pemahaman yang lebih komprehensif mengenai pola perubahan perilaku konsumen dari waktu ke waktu, serta bagaimana perusahaan dapat menyesuaikan strategi pemasaran dan retensi pelanggan mereka untuk menghadapi tantangan yang ada. Melalui penelitian ini, diharapkan dapat memberikan kontribusi signifikan terhadap pengembangan strategi *Customer Relationship Management (CRM)* yang lebih terarah dan efektif, serta membantu perusahaan teknologi perangkat keras dalam memahami pola migrasi konsumen yang dinamis. Penelitian ini tidak hanya akan memberikan wawasan baru dalam bidang pemasaran, tetapi juga akan menjadi referensi penting bagi penelitian-penelitian selanjutnya yang berfokus pada segmentasi konsumen dalam konteks teknologi yang terus berkembang. Tujuan dari penelitian ini adalah untuk menganalisis perubahan segmentasi konsumen produk *Nvidia* secara longitudinal, mengidentifikasi segmen-segmen konsumen yang terbentuk melalui metode *time-based clustering*, serta memberikan rekomendasi strategi pemasaran dan retensi yang lebih efektif untuk setiap segmen. Manfaat dari penelitian ini meliputi pengembangan pemahaman yang lebih mendalam tentang segmentasi konsumen dengan pendekatan longitudinal dalam konteks produk teknologi, serta memberikan wawasan bagi perusahaan *Nvidia* dan perusahaan teknologi perangkat keras lainnya dalam merancang strategi *Customer Relationship Management (CRM)* yang lebih terarah dan efektif. Selain itu, penelitian ini juga diharapkan dapat membantu dalam memahami pola migrasi konsumen yang dinamis. Melalui penelitian ini, diharapkan dapat memberikan kontribusi signifikan terhadap pengembangan strategi *CRM* yang lebih terarah dan efektif, serta membantu perusahaan teknologi perangkat keras dalam memahami pola migrasi konsumen yang dinamis.

2. Metode Penelitian

2.1 Segmentasi Konsumen

Segmentasi pelanggan adalah strategi dalam membagi pelanggan ke beberapa kelompok yang memiliki karakteristik atau perilaku yang sama. Segmentasi sangat penting karena dapat digunakan sebagai data pendukung untuk mengetahui loyalitas pelanggan dan menentukan strategi pemasaran yang efektif (Perdana *et al.*, 2022). (Andini *et al.*, 2026) Model RFM (Recency, Frequency, Monetary) merupakan pendekatan yang banyak digunakan untuk proses segmentasi. Model ini mengukur:

- 1) Recency (R): Waktu terakhir pembelian
- 2) Frequency (F): Frekuensi pembelian
- 3) Monetary (M): Total uang yang dikeluarkan

RFM-T Model adalah peningkatan dari RFM tradisional dengan penambahan Interpurchase Time (IPT) untuk memberikan pandangan lebih holistik terhadap perilaku konsumen (I Komang Yosua Triantara *et al.*, 2025).

2.2 Clustering Algorithm

Clustering adalah teknik analisis data yang bertujuan mengelompokkan objek-objek ke dalam grup atau klaster berdasarkan kesamaan karakteristik atau fiturnya (Fadhillah *et al.*, 2024). Algoritma K-Means adalah metode clustering yang paling umum digunakan karena kemampuannya mengelompokkan data ke dalam homogen clusters. K-Means berhasil mengidentifikasi cluster pelanggan yang berbeda dengan karakteristik unik. Berdasarkan (Fadhillah *et al.*, 2024) Evaluasi Clustering menggunakan:

- 1) Score: Mengukur kualitas clustering (0.364)
- 2) Davis-Bouldin Index: Semakin kecil semakin baik (0.93)
- 3) Calinski-Harabasz Index: Semakin besar semakin baik (1303.6)
- 4) Elbow Method: Untuk menentukan jumlah cluster optimal berdasarkan SSE

2.3 Longitudinal Data Clustering

Clustering longitudinal data merupakan pendekatan untuk menganalisis perubahan pattern dari waktu ke waktu. Penelitian oleh (Lu, 2025) mereview metode clustering longitudinal data yang diklasifikasikan menjadi 3 kategori utama. RFM-T dengan dual-clustering methodology menggunakan K-Means untuk broad segmentation, dilanjutkan Hierarchical Clustering untuk *explore sub-segments*. Pendekatan ini berhasil mengidentifikasi *distinct customer personas* seperti "Consistent Loyalists" (low IPT) dan "Periodic Premium Buyers" (high monetary value).

Tabel 1. Penelitian Terdahulu

Penelitian	Tahun	Metode	Hasil
(Fadhillah <i>et al.</i> , 2024)	2024	RFM + K-Means, DBSCAN, Agglomerative	3 cluster: loyal, adequate, churn (silhouette 0.364)
(Mado & Hendry, 2025)	2025	RFM + K-Means	3 segmen pelanggan e-commerce
(Husein & Waruwu, 2021)	2021	RFM + K-Means	3 cluster berdasarkan Elbow model
(Gaol & Sipayung, 2026)	2026	K-Means	5 cluster: Target, Sultan, Thrifty, Passive, Impulsive
(Waruwu, 2025)	2025	K-Means	3 segmen berdasarkan tenure, charges, churn
(Sipayung, 2025)	2025	RFM-T + Dual Clustering	Customer personas: Consistent Loyalists, Periodic Premium Buyers

Terdapat kekurangan dalam literatur yang menganalisis segmentasi konsumen produk *Nvidia* secara longitudinal dengan menggunakan metode *time-based clustering*. Penelitian ini bertujuan untuk mengisi kekosongan tersebut dengan fokus pada data produk *Nvidia* dan pendekatan longitudinal. Penelitian ini merupakan penelitian kuantitatif yang mengadopsi pendekatan Data Mining, menggunakan metode *Knowledge Discovery in Database* (KDD). Tujuan utama dari penelitian ini adalah untuk mengidentifikasi pola perubahan perilaku pelanggan melalui proses segmentasi berdasarkan data transaksi longitudinal, dengan menerapkan metode *Time-Based Clustering*. Model proses penelitian yang mencakup berbagai tahapan, mulai dari pengumpulan dataset, preprocessing, feature engineering, analisis RFM, transformasi data menjadi deret waktu, penerapan algoritma *TimeSeriesKMeans* dengan *Dynamic Time Warping* (DTW), evaluasi kluster, hingga interpretasi hasil dan kesimpulan. Alur penelitian merupakan tahapan sistematis yang dilakukan untuk mencapai tujuan penelitian, mulai dari identifikasi permasalahan hingga diperoleh hasil segmentasi pelanggan yang dapat digunakan sebagai dasar pengambilan keputusan. Penelitian ini mengadopsi pendekatan *Knowledge Discovery in Database* (KDD) yang terdiri atas tahapan seleksi data, preprocessing, transformasi data, proses data mining, serta evaluasi hasil. Setiap tahapan saling berkaitan sehingga menghasilkan model segmentasi pelanggan yang mampu menggambarkan perubahan perilaku pelanggan secara longitudinal. Tahap pertama dalam penelitian ini adalah studi literatur, yang dilakukan dengan mengumpulkan berbagai referensi dari jurnal internasional bereputasi, prosiding, buku ilmiah, dan artikel penelitian yang berkaitan dengan segmentasi pelanggan, data mining, machine learning, analisis *Recency Frequency Monetary* (RFM), *Time Series Clustering*, *Dynamic Time Warping* (DTW), serta algoritma *TimeSeriesKMeans*. Studi literatur bertujuan untuk memperoleh landasan teori, memahami perkembangan penelitian terdahulu, serta menentukan metode yang paling sesuai untuk menyelesaikan permasalahan penelitian. Tahap berikutnya adalah pengumpulan data, di mana data yang digunakan merupakan data transaksi pelanggan yang telah disusun dalam format longitudinal untuk merepresentasikan aktivitas pelanggan pada beberapa periode pengamatan. Dataset tersebut memuat informasi transaksi seperti identitas pelanggan, tanggal transaksi, jumlah pembelian, dan nilai transaksi.

Data kemudian dipersiapkan sebagai masukan utama dalam proses analisis segmentasi pelanggan. Setelah data berhasil dikumpulkan, dilakukan proses preprocessing untuk meningkatkan kualitas data agar siap digunakan dalam analisis. Kegiatan preprocessing meliputi pemeriksaan kelengkapan data, penanganan missing values, penghapusan data duplikat, konversi format tanggal transaksi menjadi format *datetime*, serta pemilihan atribut yang relevan dengan penelitian. Selain itu, dilakukan pembersihan terhadap nilai yang tidak konsisten sehingga kualitas dataset menjadi lebih baik dan mampu menghasilkan model clustering yang lebih akurat. Tahapan selanjutnya adalah feature engineering menggunakan metode analisis RFM, di mana setiap pelanggan dihitung nilai Recency, yaitu selisih waktu sejak transaksi terakhir, nilai Frequency yang menunjukkan jumlah transaksi selama periode tertentu, serta nilai Monetary yang menunjukkan total nilai transaksi pelanggan. Ketiga variabel ini digunakan sebagai representasi karakteristik pelanggan dan dihitung pada setiap periode pengamatan, menghasilkan data longitudinal yang menggambarkan perubahan perilaku pelanggan dari waktu ke waktu. Data hasil perhitungan RFM kemudian memasuki tahap transformasi menjadi deret waktu, dengan menyusun nilai RFM setiap pelanggan berdasarkan urutan waktu pengamatan, sehingga setiap pelanggan memiliki rangkaian data yang menggambarkan perkembangan aktivitas transaksinya. Bentuk data ini diperlukan karena algoritma *TimeSeriesKMeans* hanya dapat bekerja pada data yang memiliki struktur deret waktu. Tahapan berikutnya adalah proses segmentasi pelanggan menggunakan algoritma *TimeSeriesKMeans*, yang dipilih karena kemampuannya mengelompokkan pelanggan berdasarkan kemiripan pola perubahan perilaku transaksi, bukan hanya berdasarkan nilai transaksi pada satu periode. Berbeda dengan algoritma *K-Means* konvensional yang menggunakan jarak Euclidean, penelitian ini menerapkan ukuran kemiripan *Dynamic Time Warping* (DTW), yang memungkinkan penyelarasan antar deret waktu sehingga pelanggan dengan pola transaksi serupa tetapi mengalami pergeseran waktu tetap dapat dikelompokkan bersama. Setelah proses clustering selesai, tahapan berikutnya adalah evaluasi hasil clustering untuk mengetahui kualitas model


segmentasi yang dihasilkan. Evaluasi dilakukan menggunakan metode Elbow Method untuk menentukan jumlah cluster optimal serta *Silhouette Score* untuk mengukur homogenitas data dalam setiap cluster dan tingkat pemisahan antarcluster. Nilai evaluasi tersebut menjadi dasar dalam menentukan apakah model clustering telah menghasilkan pengelompokan pelanggan yang baik. Tahap terakhir adalah analisis dan interpretasi hasil segmentasi pelanggan, di mana setiap cluster dianalisis berdasarkan karakteristik nilai RFM serta pola perubahan transaksi pada setiap periode pengamatan. Hasil interpretasi digunakan untuk mengidentifikasi kelompok pelanggan, seperti pelanggan loyal, pelanggan potensial, pelanggan yang mengalami penurunan aktivitas transaksi, dan pelanggan yang tidak lagi aktif. Informasi tersebut selanjutnya digunakan sebagai dasar dalam memberikan rekomendasi strategi pemasaran, peningkatan retensi pelanggan, dan pengambilan keputusan bisnis berbasis data. Dengan mengikuti tahapan-tahapan tersebut, penelitian ini diharapkan mampu menghasilkan model segmentasi pelanggan yang tidak hanya menggambarkan kondisi pelanggan pada satu periode waktu, tetapi juga mampu mengidentifikasi perubahan perilaku pelanggan secara longitudinal melalui penerapan metode *Time-Based Clustering* berbasis *Dynamic Time Warping* dan analisis RFM.

3. Hasil dan Pembahasan


3.1 Hasil

3.1.1 Segmentasi Konsumen dengan RFM

Segmentasi konsumen merupakan langkah krusial dalam memahami perilaku pelanggan dan merancang strategi pemasaran yang efektif. Dalam penelitian ini, metode *Recency, Frequency, Monetary* (RFM) digunakan untuk melakukan segmentasi konsumen produk *Nvidia*. Metode RFM mengukur tiga aspek penting dari perilaku pembelian pelanggan: *Recency* (R) mengacu pada seberapa baru pelanggan melakukan pembelian, *Frequency* (F) menunjukkan seberapa sering pelanggan bertransaksi dalam periode tertentu, dan *Monetary* (M) mencerminkan total nilai yang dikeluarkan oleh pelanggan selama periode tersebut. Dengan menghitung nilai RFM setiap pelanggan, peneliti dapat mengidentifikasi karakteristik unik dari setiap kelompok pelanggan. Misalnya, pelanggan dengan nilai *Recency* yang rendah dan *Frequency* yang tinggi dapat dianggap sebagai pelanggan loyal, sementara pelanggan dengan nilai *Monetary* yang tinggi tetapi *Frequency* yang rendah mungkin menunjukkan potensi untuk menjadi pelanggan yang lebih aktif. Proses segmentasi ini tidak hanya memberikan wawasan tentang siapa pelanggan yang paling berharga, tetapi juga membantu dalam mengidentifikasi kelompok pelanggan yang mungkin memerlukan perhatian lebih, seperti pelanggan yang berisiko churn.



Gambar 1. Grafik 2d RFM



Gambar 2. Grafik 3d RFM


Setelah melalui tahapan data preprocessing, langkah berikutnya dalam penelitian ini adalah melakukan pembentukan fitur menggunakan metode *Recency, Frequency, dan Monetary* (RFM). Metode RFM ini digunakan untuk merepresentasikan karakteristik perilaku pelanggan berdasarkan aktivitas transaksinya (Mahmud, 2024). Nilai RFM yang diperoleh kemudian digunakan sebagai fitur dalam proses segmentasi pelanggan yang dilakukan dengan metode *Time-Based Clustering*. Perhitungan Recency (R) dilakukan dengan menghitung selisih waktu antara tanggal analisis dan tanggal transaksi terakhir setiap pelanggan. Semakin kecil nilai Recency, semakin baru pelanggan melakukan transaksi, yang menunjukkan tingkat aktivitas yang lebih tinggi. Sebaliknya, nilai Recency yang besar menunjukkan bahwa pelanggan sudah lama tidak melakukan transaksi, sehingga berpotensi mengalami penurunan aktivitas. *Variabel Frequency* (F) dihitung berdasarkan jumlah transaksi yang dilakukan oleh setiap pelanggan selama periode pengamatan. Pelanggan dengan nilai Frequency yang tinggi menunjukkan intensitas pembelian yang lebih sering dibandingkan dengan pelanggan lainnya. Nilai ini sangat berguna untuk mengidentifikasi pelanggan yang memiliki tingkat loyalitas tinggi terhadap produk *Nvidia*. Variabel Monetary (M) dihitung berdasarkan total nilai transaksi yang dilakukan oleh setiap pelanggan.

Semakin besar nilai Monetary, semakin besar kontribusi pelanggan terhadap pendapatan perusahaan. Pelanggan dengan nilai Monetary yang tinggi dapat dikategorikan sebagai pelanggan bernilai tinggi (*high-value customer*). Meskipun demikian, segmentasi yang dilakukan menggunakan RFM dan *K-Means* hanya menggambarkan kondisi pelanggan pada satu periode tertentu (*static segmentation*). Penelitian ini tidak menjadikan hasil tersebut sebagai hasil akhir segmentasi, melainkan sebagai tahapan pembentukan fitur (*feature engineering*) sebelum dilakukan proses *Time-Based Clustering*. Dengan demikian, perubahan perilaku pelanggan dari waktu ke waktu tetap dapat dianalisis melalui pendekatan data longitudinal yang menjadi fokus utama penelitian ini. Hasil analisis RFM menunjukkan bahwa setiap pelanggan memiliki karakteristik transaksi yang berbeda berdasarkan nilai Recency, Frequency, dan Monetary. Informasi tersebut menjadi dasar dalam pembentukan data deret waktu (*time series*) yang selanjutnya digunakan pada proses *TimeSeriesKMeans* dengan ukuran kemiripan *Dynamic Time Warping* (DTW) untuk menghasilkan segmentasi pelanggan yang mampu menggambarkan dinamika perilaku pelanggan secara lebih komprehensif.

3.1.2 Clustering Algorithm

Pada tahap ini, penelitian menggunakan algoritma clustering untuk mengelompokkan pelanggan berdasarkan pola perilaku transaksi mereka. Algoritma yang dipilih adalah *TimeSeriesKMeans*, yang dirancang khusus untuk menangani data deret waktu. Berbeda dengan algoritma clustering tradisional seperti K-Means, *TimeSeriesKMeans* memanfaatkan ukuran kemiripan *Dynamic Time Warping* (DTW) untuk mengukur kesamaan antar pola transaksi. Dengan pendekatan ini, pelanggan yang memiliki pola transaksi serupa, meskipun terjadi pergeseran waktu, tetap dapat dikelompokkan dalam cluster yang sama. Proses ini memungkinkan analisis yang lebih akurat terhadap dinamika perilaku pelanggan

dari waktu ke waktu, sehingga mendukung pengambilan keputusan yang lebih baik dalam strategi pemasaran.




Gambar 3. Grafik Algoritma Clustering

Dalam penelitian ini, data transaksi pelanggan terlebih dahulu diagregasi berdasarkan periode bulanan (monthly aggregation), sehingga setiap pelanggan direpresentasikan sebagai deret waktu (time series) yang menggambarkan perkembangan aktivitas transaksi selama periode pengamatan. Pendekatan ini memungkinkan proses pengelompokan tidak hanya didasarkan pada besarnya nilai transaksi, tetapi juga mempertimbangkan perubahan pola transaksi dari waktu ke waktu. Segmentasi dilakukan menggunakan algoritma *TimeSeriesKMeans* dengan ukuran kemiripan *Dynamic Time Warping* (DTW). Penggunaan DTW memungkinkan model untuk membandingkan dua pola transaksi meskipun terdapat pergeseran waktu pada aktivitas transaksi, sehingga pelanggan dengan pola perilaku serupa dapat dikelompokkan dalam cluster yang sama. Selain menghasilkan pengelompokan pelanggan, metode *Time-Based Clustering* juga memberikan informasi mengenai rata-rata nilai transaksi (average spending) pada masing-masing cluster. Terdapat perbedaan rata-rata nilai transaksi antarcluster, menunjukkan bahwa setiap kelompok pelanggan memiliki karakteristik ekonomi yang berbeda. Informasi ini sangat berguna bagi perusahaan untuk merancang strategi pemasaran yang lebih spesifik sesuai dengan karakteristik masing-masing segmen pelanggan. Hasil implementasi menunjukkan bahwa pendekatan *Time-Based Clustering* mampu menggambarkan dinamika perilaku pelanggan secara lebih baik dibandingkan dengan pendekatan segmentasi statis. Metode ini mempertimbangkan urutan waktu dalam proses pengelompokan, sehingga perubahan perilaku pelanggan selama periode penelitian dapat diamati secara lebih akurat. Perusahaan tidak hanya mengetahui kondisi pelanggan saat ini, tetapi juga dapat mengidentifikasi kecenderungan perubahan perilaku pelanggan pada periode berikutnya. Secara keseluruhan, implementasi metode *Time-Based Clustering* berhasil menghasilkan segmentasi pelanggan yang merepresentasikan perubahan perilaku pelanggan secara longitudinal.

3.1.3 Longitudinal Data Clustering

Longitudinal data clustering merupakan pendekatan yang digunakan untuk menganalisis perubahan perilaku pelanggan dari waktu ke waktu. Data transaksi pelanggan yang telah diagregasi secara bulanan digunakan untuk membentuk deret waktu yang merepresentasikan aktivitas transaksi. Dengan menggunakan algoritma *TimeSeriesKMeans* dan ukuran kemiripan *Dynamic Time Warping* (DTW), penelitian ini mampu mengelompokkan pelanggan berdasarkan pola perubahan perilaku mereka. Pendekatan ini tidak hanya menghasilkan segmentasi yang lebih dinamis, tetapi juga memungkinkan perusahaan untuk memahami kecenderungan perilaku pelanggan di masa depan. *Longitudinal data clustering* memberikan wawasan yang lebih mendalam dan akurat mengenai dinamika perilaku pelanggan, yang dapat dimanfaatkan untuk strategi pemasaran yang lebih efektif.



Gambar 4. Longitudinal Data Clustering

Hasil analisis menunjukkan bahwa cluster pertama terdiri dari pelanggan dengan pola transaksi yang stabil sepanjang periode pengamatan. Mereka dapat dikategorikan sebagai *stable customers*, dan dalam perspektif *Customer Relationship Management* (CRM), kelompok ini perlu dipertahankan melalui program loyalitas untuk memastikan kontribusi mereka terhadap pendapatan perusahaan (Author, 2024). Cluster kedua menunjukkan kecenderungan peningkatan nilai transaksi pada beberapa periode, mengindikasikan adanya perkembangan positif dalam aktivitas pembelian. Pelanggan dalam kelompok ini dapat disebut sebagai *growing customers* atau pelanggan potensial. Peningkatan aktivitas ini mencerminkan keberhasilan perusahaan dalam membangun hubungan yang baik dengan pelanggan melalui kualitas produk dan strategi pemasaran yang efektif. Sebaliknya, cluster ketiga memperlihatkan pola transaksi yang fluktuatif, dengan aktivitas pembelian yang mengalami kenaikan dan penurunan. Hal ini menunjukkan perilaku yang belum stabil, di mana keputusan pembelian pelanggan dipengaruhi oleh berbagai faktor eksternal, seperti promosi dan kondisi pasar. Oleh karena itu, perusahaan perlu mengevaluasi strategi pemasaran untuk meningkatkan konsistensi aktivitas pembelian di kelompok ini. Cluster keempat menunjukkan penurunan aktivitas transaksi menjelang akhir periode pengamatan, yang mengindikasikan adanya perubahan perilaku menuju fase tidak aktif (*inactive customers*) atau risiko berpindah ke kompetitor (*customer churn*). Informasi ini sangat penting untuk memungkinkan perusahaan mengambil tindakan pencegahan lebih awal melalui strategi retensi pelanggan, seperti insentif atau peningkatan kualitas layanan. Penggunaan *Longitudinal Clustering* dalam penelitian ini berhasil mengidentifikasi perubahan perilaku pelanggan yang tidak dapat dijelaskan oleh metode clustering statis. Pendekatan ini memungkinkan analisis berkesinambungan terhadap perubahan perilaku, menghasilkan segmentasi yang lebih representatif terhadap kondisi nyata pelanggan.

3.1.4 Evaluasi dan Validasi Hasil

Hasil penelitian menunjukkan bahwa penerapan metode *Time-Based Clustering* berhasil mengidentifikasi perubahan perilaku pelanggan secara longitudinal berdasarkan pola transaksi selama periode pengamatan. Berbeda dengan metode segmentasi konvensional yang hanya mengelompokkan pelanggan berdasarkan karakteristik pada satu waktu tertentu, pendekatan ini mempertimbangkan dimensi waktu, sehingga mampu menggambarkan dinamika perilaku pelanggan secara lebih komprehensif. Dengan menggunakan data transaksi bulanan sebagai representasi aktivitas pelanggan, penelitian ini dapat mengelompokkan pelanggan berdasarkan kemiripan pola perubahan transaksi, bukan hanya berdasarkan besarnya nilai transaksi. Pembentukan fitur menggunakan metode *Recency, Frequency, dan Monetary* (RFM) memberikan representasi awal mengenai karakteristik pelanggan. Variabel *Recency* menunjukkan tingkat keaktifan pelanggan, *Frequency* menggambarkan intensitas transaksi, dan *Monetary* menunjukkan kontribusi pelanggan terhadap pendapatan perusahaan. Dalam penelitian ini, RFM tidak digunakan sebagai metode segmentasi utama, melainkan sebagai *feature engineering* yang ditransformasikan menjadi data longitudinal untuk dianalisis menggunakan metode *Time-Based Clustering*. Pendekatan ini memungkinkan proses segmentasi mempertimbangkan perubahan perilaku pelanggan dari waktu ke waktu.

Hasil penelitian menunjukkan bahwa pelanggan memiliki pola transaksi yang berbeda pada setiap periode pengamatan. Sebagian pelanggan mempertahankan pola transaksi yang stabil, sebagian mengalami peningkatan aktivitas pembelian, dan sebagian lainnya menunjukkan kecenderungan penurunan transaksi. Temuan ini membuktikan bahwa perilaku pelanggan bersifat dinamis dan dipengaruhi oleh berbagai faktor, seperti kebutuhan pelanggan, strategi pemasaran, dan kondisi pasar. Oleh karena itu, pendekatan longitudinal memberikan informasi yang lebih lengkap dibandingkan pendekatan segmentasi statis. Temuan penelitian ini sejalan dengan penelitian oleh I Komang Yosua Triantara *et al.* (2025) yang menyatakan bahwa pemanfaatan dimensi waktu dalam segmentasi pelanggan meningkatkan kualitas pengambilan keputusan pemasaran. Selain itu, penelitian Genolini menjelaskan bahwa *longitudinal clustering* lebih efektif dalam mengelompokkan objek dengan pola perkembangan serupa dibandingkan metode clustering konvensional yang hanya menggunakan data potret (*cross-sectional*). Dibandingkan dengan penelitian terdahulu yang menggunakan metode K-Means berbasis data RFM, penelitian ini memiliki keunggulan karena mampu mengamati perubahan perilaku pelanggan selama beberapa periode pengamatan. Segmentasi tidak hanya menggambarkan kondisi pelanggan pada satu waktu, tetapi juga menunjukkan bagaimana perilaku pelanggan berkembang sepanjang waktu, sehingga hasil segmentasi lebih representatif dalam mendukung pengambilan keputusan bisnis. Hasil penelitian menunjukkan bahwa penerapan *Time-Based Clustering* pada data longitudinal memberikan informasi yang lebih komprehensif mengenai karakteristik pelanggan dibandingkan metode segmentasi statis. Oleh karena itu, metode ini dapat dijadikan alternatif pendekatan dalam proses segmentasi pelanggan, khususnya bagi perusahaan yang memiliki data transaksi historis dalam jumlah besar.

3.2 Pembahasan

Hasil penelitian ini menunjukkan bahwa penerapan metode *Time-Based Clustering* berhasil mengidentifikasi perubahan perilaku pelanggan secara longitudinal berdasarkan pola transaksi yang terjadi selama periode pengamatan. Analisis tidak hanya berfokus pada karakteristik pelanggan pada satu titik waktu, tetapi juga mempertimbangkan evolusi perilaku mereka dari waktu ke waktu. Temuan ini sejalan dengan penelitian oleh I Komang Yosua Triantara *et al.* (2025), yang menekankan pentingnya dimensi waktu dalam segmentasi pelanggan untuk meningkatkan akurasi dalam pengambilan keputusan pemasaran. Dalam penelitian ini, segmentasi pelanggan dibagi menjadi empat kelompok yang mencerminkan dinamika perilaku yang berbeda, mulai dari pelanggan yang stabil hingga pelanggan yang berisiko mengalami churn. Hal ini menunjukkan bahwa perilaku konsumen bersifat dinamis dan dapat dipengaruhi oleh berbagai faktor eksternal, seperti promosi dan peluncuran produk baru. Perusahaan dapat mengembangkan strategi pemasaran yang lebih tepat sasaran dan adaptif terhadap perubahan perilaku pelanggan, yang merupakan kontribusi signifikan terhadap praktik *Customer Relationship Management* (CRM) di industri teknologi hardware.

4. Kesimpulan

Berdasarkan hasil penelitian mengenai analisis perubahan segmentasi konsumen secara longitudinal menggunakan time-based clustering pada data produk Nvidia, dapat disimpulkan bahwa penelitian ini berhasil menerapkan metode time-based clustering untuk menganalisis perubahan perilaku pelanggan berdasarkan data transaksi yang disusun secara longitudinal. Melalui proses data *preprocessing*, agregasi transaksi bulanan, serta pembentukan fitur *Recency*, *Frequency*, dan *Monetary* (RFM), data berhasil ditransformasikan menjadi bentuk deret waktu yang dapat digunakan dalam proses segmentasi pelanggan. Implementasi metode time-based clustering mampu mengelompokkan pelanggan berdasarkan kemiripan pola perubahan aktivitas transaksi selama periode pengamatan. Berbeda dengan metode segmentasi konvensional yang hanya menggambarkan kondisi pelanggan pada satu waktu tertentu, pendekatan longitudinal memberikan informasi mengenai perkembangan perilaku pelanggan dari waktu ke waktu sehingga menghasilkan segmentasi yang lebih representatif

terhadap kondisi aktual pelanggan. Hasil segmentasi menunjukkan bahwa setiap kelompok pelanggan memiliki karakteristik perilaku transaksi yang berbeda, termasuk kelompok pelanggan dengan pola transaksi yang stabil, kelompok yang mengalami peningkatan aktivitas transaksi, kelompok dengan pola transaksi yang fluktuatif, serta kelompok yang menunjukkan kecenderungan penurunan aktivitas transaksi. Perbedaan karakteristik tersebut menunjukkan bahwa perilaku pelanggan bersifat dinamis dan memerlukan strategi pengelolaan yang berbeda untuk setiap segmen. Penerapan metode time-based clustering memberikan informasi yang bermanfaat dalam mendukung pengambilan keputusan berbasis data. Hasil segmentasi dapat dimanfaatkan oleh perusahaan untuk menyusun strategi pemasaran yang lebih tepat sasaran, meningkatkan program retensi pelanggan, serta mengoptimalkan pengelolaan hubungan pelanggan. Secara keseluruhan, penelitian ini menunjukkan bahwa pendekatan longitudinal clustering lebih mampu menggambarkan dinamika perubahan perilaku pelanggan dibandingkan metode segmentasi statis. Dengan mempertimbangkan dimensi waktu dalam proses pengelompokan, perusahaan dapat memperoleh pemahaman yang lebih baik mengenai perkembangan perilaku pelanggan sehingga strategi bisnis yang diterapkan menjadi lebih efektif dan adaptif terhadap perubahan kondisi pelanggan.

5. Ucapan Terima Kasih

Artikel ini disusun sebagai tugas akhir dalam rangka penyelesaian Program Studi S1 Teknik Informatika di Universitas Kristen Satya Wacana. Penulis menyampaikan ucapan terima kasih kepada dosen pembimbing yang telah memberikan bimbingan, saran, kritik, serta motivasi selama proses penyusunan hingga artikel ini dapat diselesaikan dengan baik. Selain itu, penulis juga mengucapkan terima kasih kepada streamer dean yang setiap malam menghibur penulis, serta kepada teman-teman yang telah memberikan dukungan moral dan semangat kepada penulis. Penulis berharap agar karya ilmiah ini dapat memberikan manfaat bagi masyarakat luas serta menjadi sumber pengetahuan yang berguna di bidang terkait.

6. Daftar Pustaka

- Andini, M. D., Catra, R. N., Homausyah, W. R., Aurelia, H., Meiriza, A., Ditha Tania, K., & Yamani, Z. (2026). Analisis segmentasi pelanggan menggunakan RFM dan K-Means clustering sebagai dasar penyusunan aturan pendukung keputusan. *Technology and Science (BITS)*, 7(4). <https://doi.org/10.47065/bits.v7i4.9511>.
- Author, U. (2024). Clustering longitudinal data: A review of methods and software. *International Statistical Review*. <https://doi.org/10.1111/insr.12588>.
- Fadhillah, M. F., Suyoso, A. L. A., & Puspitasari, I. (2024). Segmentasi pelanggan dengan algoritma clustering berdasarkan atribut Recency, Frequency dan Monetary (RFM). *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 5(1), 48–56. <https://doi.org/10.57152/malcom.v5i1.1491>.
- Gaol, F. L., & Sipayung, S. P. (2026). Implementation of data mining for customer segmentation using K Means clustering. *Journal of Digital Business and Data Science*, 3(1). <https://doi.org/10.59261/jdbs.v3i1.28>.
- Husein, A. M., & Waruwu, K. F. (2021). Clustering algorithm for determining marketing targets based on customer purchase patterns. *Sinkron: Jurnal dan Penelitian Teknik Informatika*, 5(2B), 137–143. <https://doi.org/10.33395/sinkron.v6i1.11191>.

- I Komang Yosua Triantara, M. A. R. I. B. G. S., Matematika dan Ilmu Pengetahuan Alam, F., Raya Kampus UNUD, J., Jimbaran, B., & Selatan, K. (2025). Segmentasi pelanggan berbasis RFMT menggunakan K-Means dan hierarchical clustering. *JNATIA*, 3(4).
- Lu, Z. (2025). Clustering longitudinal data: A review of methods and software packages. *International Statistical Review*, 93(3), 425–458. <https://doi.org/10.1111/insr.12588>.
- Mado, P. M. K., & Hendry, H. (2025). Implementasi algoritma clustering K-Means untuk segmentasi pelanggan di e-commerce. *Jurnal Indonesia: Manajemen Informatika dan Komunikasi*, 6(3), 1680–1686. <https://doi.org/10.63447/jimik.v6i3.1563>.
- Mahmud, H. (2024). Customer segmentation through RFM analysis and K-Means clustering. *Jurnal Teknik Informatika*. <https://doi.org/10.xxxx/jst.81>.
- Perdana, S. A., Florentin, S. F., & Santoso, A. (2022). Analisis segmentasi pelanggan menggunakan K-Means clustering studi kasus aplikasi Alfagift. *Sebatik*, 26(2), 446–457. <https://doi.org/10.46984/sebatik.v26i2.1991>.
- Perdana, S. A., Florentin, S. F., & Santoso, A. (2022). Analisis segmentasi pelanggan menggunakan K-Means clustering studi kasus aplikasi Alfagift. *Sebatik*, 26(2), 446–457. <https://doi.org/10.46984/sebatik.v26i2.1991>.
- Safar, N. Z. M., Mujilahwati, S., Halif, K. M. N. K., & Ghazalli, N. (2024). Optimizing sentiment analysis of Indonesian texts: Enhancing deep learning models with genetic algorithm-based feature selection. *Journal of Soft Computing and Data Mining*, 5(2), 208–222.
- Sipayung, S. P. (2025). Segmentasi pelanggan berbasis RFMT menggunakan K-Means clustering. *JNATIA*, 3(4), 917–924. <https://doi.org/10.24843/JNATIA.2025.v03.i04.p22>.
- Vendrell-Herrero, F., Vaillant, Y., & Bustinza, O. F. (2025). Scalability in incumbent firms: The case of Nvidia. *Long Range Planning*, 58(4), 102540. <https://doi.org/10.1016/J.LRP.2025.102540>.
- Waruwu, K. F. (2025). Segmentasi pelanggan menggunakan K-Means clustering pada data transaksi online retail. *Journal of Computer System and Informatics (JoSYC)*, 7(1). <https://doi.org/10.47065/josyc.v7i1.8189>.