

## Segmentasi Pelanggan Menggunakan Algoritma K-Means Pada Jaringan Telekomunikasi Untuk Optimalisasi Strategi Pemasaran

Adhivia Julian<sup>1</sup>, Ahmad Faqih<sup>2</sup>, Gifthera Dwilestari<sup>3\*</sup>

<sup>1,2,3</sup>STMIK IKMI Cirebon

\*Email: ggdwilestari@gmail.com

### Abstract

*In the digital era, the telecommunications industry faces challenges in understanding increasingly complex customer needs. This study implements the K-Means algorithm for customer segmentation, with the primary objective of identifying behavioral patterns and formulating more effective marketing strategies. Using the Knowledge Discovery in Databases (KDD) approach, this research encompasses the stages of data selection, pre-processing, transformation, data mining, and pattern evaluation. The analyzed data includes information on service types, internet speed, device types, and customer locations. The K-Means algorithm is applied to Cluster customers based on behavioral similarities, with the optimal number of Clusters determined using the Davies-Bouldin Index (DBI) metric. The analysis results reveal three Clusters: customers with basic service needs, users of low-speed internet services who are highly price-sensitive, and intensive internet users who rarely utilize additional features. The proposed marketing strategies include offering budget-friendly packages, bundling promotions, and educating customers about the benefits of additional features. Evaluation using DBI yields a value of 0.055, indicating high-quality Clusters. This study demonstrates the effectiveness of the K-Means algorithm in customer segmentation, providing a foundation for telecommunications companies to enhance customer loyalty and retention through more targeted marketing strategies. Furthermore, it highlights opportunities for further exploration of data mining applications in the telecommunications sector.*

*Keywords: Customer segmentation, K-Means algorithm, telecommunication, marketing strategy, data mining*

### Abstrak

Dalam era digital ini, industri telekomunikasi dihadapkan pada tantangan untuk memahami kebutuhan pelanggan yang semakin kompleks. Penelitian ini mengimplementasikan algoritma *K-Means* untuk segmentasi pelanggan, dengan tujuan utama mengidentifikasi pola perilaku serta merumuskan strategi pemasaran yang lebih efektif. Melalui pendekatan *Knowledge Discovery in Databases (KDD)*, penelitian ini mencakup tahapan seleksi data, pra-pemrosesan, transformasi, penambangan data (data mining), dan evaluasi pola. Data yang dianalisis meliputi informasi mengenai jenis layanan, kecepatan internet, tipe perangkat, dan lokasi pelanggan. Algoritma *K-Means* diaplikasikan untuk mengelompokkan pelanggan berdasarkan kesamaan perilaku, dengan jumlah kluster optimal ditentukan menggunakan metrik *Davies-Bouldin Index (DBI)*. Hasil analisis menghasilkan tiga kluster, yakni pelanggan dengan kebutuhan layanan dasar, pengguna layanan internet berkecepatan rendah yang sensitif terhadap harga, serta pengguna layanan internet intensif yang jarang memanfaatkan fitur tambahan. Strategi pemasaran yang diusulkan mencakup penawaran paket hemat, promosi bundling, dan edukasi tentang manfaat fitur tambahan. Evaluasi menggunakan *DBI* menunjukkan nilai sebesar 0,055, yang mengindikasikan bahwa kluster yang dihasilkan memiliki kualitas yang baik. Penelitian ini menunjukkan efektivitas algoritma *K-Means* dalam segmentasi pelanggan, sekaligus memberikan dasar bagi perusahaan telekomunikasi untuk meningkatkan loyalitas dan retensi pelanggan melalui strategi pemasaran yang lebih terarah. Penelitian ini juga menawarkan peluang untuk eksplorasi lebih lanjut dalam penerapan data mining di sektor telekomunikasi jaringan.

*Kata kunci: Segmentasi pelanggan, algoritma K-Means, telekomunikasi, strategi pemasaran, data mining*

## 1. Pendahuluan

Perkembangan era digital telah menjadikan informatika sebagai penggerak utama transformasi di berbagai sektor. Kemajuan teknologi informasi memengaruhi bisnis, pendidikan, kesehatan, dan komunikasi, dengan dampak signifikan berupa meningkatnya volume data yang membuka peluang analisis lebih mendalam. Dalam industri telekomunikasi, pemanfaatan data menjadi kunci untuk memahami perilaku pelanggan dan mengembangkan strategi pemasaran yang efektif [1]. Algoritma *K-Means*, salah satu metode data mining, digunakan untuk mengelompokkan pelanggan berdasarkan karakteristik dan perilaku, memungkinkan penyedia layanan memberikan solusi yang lebih personal dan relevan [2].

Industri telekomunikasi menghadapi tantangan memahami perilaku pelanggan dengan akurat di tengah meningkatnya volume data. Algoritma *K-Means* sering digunakan untuk segmentasi pelanggan, tetapi menghadapi tantangan dalam menentukan jumlah kluster optimal dan menangani heterogenitas data. Selain itu, perusahaan telekomunikasi sering kali kesulitan memanfaatkan data pelanggan untuk meningkatkan loyalitas dan retensi pelanggan. Meskipun segmentasi *K-Means* telah banyak diterapkan di sektor *e-commerce* dan bisnis digital, studi spesifik dalam industri telekomunikasi masih terbatas [3]. Permintaan layanan personalisasi yang terus meningkat juga menekankan pentingnya segmentasi yang akurat untuk mendukung strategi pemasaran yang lebih relevan [4].

Penelitian terdahulu mendukung efektivitas algoritma *K-Means* dalam berbagai konteks. [5] menunjukkan bahwa metode ini berhasil mengidentifikasi segmen pelanggan berdasarkan pola penggunaan kartu kredit. Penelitian lain oleh [6] menggunakan *K-Means* untuk menganalisis pola penggunaan gadget pada anak usia dini, sementara [7] menemukan *K-Means* unggul dalam segmentasi pelanggan mall dibandingkan metode *K-Medoids*. Hasil-hasil ini menunjukkan bahwa *K-Means* efektif

dalam menangani data besar dan variatif, tetapi masih perlu dikaji lebih lanjut dalam konteks industri telekomunikasi, yang memiliki data pelanggan yang lebih kompleks.

Penelitian ini bertujuan menerapkan algoritma *K-Means* untuk segmentasi pelanggan telekomunikasi guna mengoptimalkan strategi pemasaran. Dengan analisis segmentasi berbasis data, perusahaan telekomunikasi diharapkan dapat mengidentifikasi kelompok pelanggan dengan karakteristik beragam dan merancang kampanye pemasaran yang lebih personal. Penelitian ini juga berkontribusi mengisi kesenjangan dalam literatur terkait penerapan *K-Means* di sektor telekomunikasi, di mana kompleksitas data sering menjadi tantangan [8]. Penyesuaian algoritma terhadap data pelanggan telekomunikasi diharapkan menghasilkan strategi pemasaran yang lebih efisien serta meningkatkan loyalitas pelanggan.


Penelitian menggunakan pendekatan kuantitatif dengan metode *K-Means Clustering* untuk segmentasi pelanggan berdasarkan perilaku penggunaan layanan telekomunikasi. Data meliputi penggunaan layanan, frekuensi komunikasi, dan nilai transaksi, yang diproses untuk menghasilkan kluster pelanggan dengan karakteristik berbeda. Tahapan penelitian mencakup preprocessing data, penerapan algoritma *K-Means*, dan analisis hasil segmentasi guna mengoptimalkan strategi pemasaran, seperti promosi yang terarah dan personalisasi layanan [9]. Pendekatan ini bertujuan membantu perusahaan telekomunikasi meningkatkan loyalitas pelanggan secara efektif.

Jika berhasil, penelitian ini memberikan kontribusi signifikan dalam penerapan *K-Means* di industri telekomunikasi. Hasil segmentasi pelanggan yang akurat memungkinkan perusahaan menargetkan promosi dan layanan sesuai kebutuhan segmen pelanggan. Selain itu, penelitian ini memberikan wawasan bagi pengembangan strategi pemasaran berbasis data [10] dan dapat menjadi dasar bagi studi lanjutan dalam mengembangkan model segmentasi yang lebih

kompleks atau mengeksplorasi metode *Clustering* lainnya.

## 2. Metoda Penelitian

Metode penelitian yang digunakan pada penelitian ini adalah *Knowledge Discovery Database (KDD)*. Adapun alur rancangan penelitian yang dilakukan pada penelitian ini dapat dilihat pada Gambar 1 di bawah ini:



Gambar 1. Tahapan Metode Penelitian

Penelitian ini menggunakan metode *Knowledge Discovery in Databases (KDD)* dengan algoritma *K-Means Clustering* untuk segmentasi pelanggan telekomunikasi. Microsoft Excel digunakan untuk pengelolaan dan pembersihan data, termasuk deteksi nilai hilang, penghapusan data tidak konsisten, dan normalisasi atribut. Selanjutnya, data diolah menggunakan RapidMiner untuk proses clustering, di mana jumlah kluster optimal ditentukan dengan *Davies-Bouldin Index (DBI)*. Hasil segmentasi dievaluasi dan divisualisasikan dalam RapidMiner guna memahami karakteristik setiap kluster. Penelitian ini bertujuan menghasilkan strategi pemasaran berbasis data yang lebih efektif bagi perusahaan telekomunikasi. Berikut adalah tahapan yang digunakan dalam metode penelitian ini:

### 2.1. Selection (Pemilihan Data)

Dalam penelitian ini, proses pemilihan data dilakukan dengan mempertimbangkan variabel yang paling relevan dalam segmentasi pelanggan jaringan telekomunikasi. Data yang digunakan merupakan data primer yang dikumpulkan langsung dari pihak instansi dengan total sebanyak 1.499 entri yang berasal dari 8 daerah berbeda. Variabel utama yang digunakan dalam analisis meliputi jenis layanan

yang digunakan pelanggan (INET dan IPTV), kecepatan internet yang dipilih (10–40 Mbps), jenis perangkat yang digunakan untuk mengakses layanan (ZTE-F609 dan RICHERLINK), serta lokasi pelanggan yang tersebar di berbagai wilayah, seperti Gunung Sari dan Kampung Timur. Pemilihan variabel ini bertujuan memastikan data yang digunakan relevan untuk segmentasi.

Tabel 1. Dataset Jumlah Pelanggan

No.	Daerah	Jumlah Pelanggan
1	Gunung Sari	455
2	Kampung Timur	513
3	Kebun Sayur	123
4	Muara Kapak	101
5	Batakan	83
6	Kopri	66
7	Gunung Steeling	77
8	Sepinggian	81

### 2.2. Preprocessing (Pra-Pemrosesan Data)

Pada tahap ini, data dipersiapkan sebelum dianalisis menggunakan Microsoft Excel dan RapidMiner. Microsoft Excel digunakan untuk pemeriksaan awal data, termasuk deteksi dan penghapusan data yang hilang atau tidak konsisten. Selain itu, Excel juga dimanfaatkan untuk identifikasi dan penghapusan outlier guna meningkatkan akurasi hasil clustering. Setelah itu, data diimpor ke RapidMiner untuk dilakukan proses normalisasi, yaitu penyesuaian skala atribut agar memiliki bobot yang seimbang. Data yang masih dalam format kategori, seperti jenis layanan dan kecepatan internet, dikonversi ke dalam format numerik agar dapat diproses lebih lanjut oleh algoritma *K-Means Clustering*. Dengan kombinasi Microsoft Excel untuk pembersihan awal dan RapidMiner untuk pengolahan lebih lanjut, tahap preprocessing ini memastikan bahwa data yang digunakan berkualitas baik dan siap untuk analisis *clustering*.

### 2.3. Transformation (Tranformasi Data)

Data hasil pra-pemrosesan diubah ke format yang sesuai untuk proses analisis *Clustering*. Proses ini melibatkan perubahan atribut seperti jenis layanan dan kecepatan internet menjadi data numerik, penghapusan

atribut yang tidak relevan, serta penyesuaian skala data untuk memastikan bobot atribut yang seimbang.

#### 2.4. Data Mining

Algoritma *K-Means* digunakan untuk mengelompokkan pelanggan berdasarkan karakteristik tertentu dengan menentukan jumlah kluster optimal menggunakan Davies-Bouldin Index (DBI). Proses dimulai dengan menentukan jumlah kluster ( $K$ ) dan memilih centroid awal secara acak. Setiap data dihitung jaraknya ke centroid terdekat, kemudian dikelompokkan ke dalam kluster yang sesuai. Setelah itu, centroid diperbarui berdasarkan rata-rata posisi data dalam kluster, dan proses ini diulang hingga hasilnya stabil. Penelitian ini menggunakan data sekunder dari perusahaan telekomunikasi dengan 1.499 data pelanggan, mencakup variabel jenis layanan (INET, IPTV), kecepatan internet (10–40 Mbps), jenis perangkat (ZTE-F609, RICHERLINK), dan lokasi pelanggan (Gunung Sari, Kampung Timur). Contoh data pelanggan meliputi pelanggan INET dengan kecepatan 20 Mbps menggunakan perangkat ZTE-F609 di Gunung Sari, serta pelanggan IPTV dengan kecepatan 40 Mbps menggunakan perangkat RICHERLINK di Kampung Timur. Implementasi dalam RapidMiner dilakukan dengan import data, preprocessing (pembersihan data dan normalisasi), penerapan algoritma *K-Means*, evaluasi menggunakan DBI (nilai 0.055), serta visualisasi hasil clustering. Hasil segmentasi menunjukkan tiga kluster utama dengan pola penggunaan layanan yang berbeda, yang dapat digunakan untuk menyusun strategi pemasaran yang lebih efektif dan tepat sasaran..

#### 2.5. Patten Evaluation (Evaluasi Pola)

Evaluasi segmentasi dilakukan menggunakan Davies-Bouldin Index (DBI) untuk mengukur kualitas kluster yang terbentuk. DBI digunakan untuk menilai seberapa baik pemisahan antar-kluster serta keseragaman dalam setiap kluster. Nilai DBI dihitung berdasarkan rasio antara rata-rata jarak

intra-kluster (kesamaan dalam satu kluster) dan jarak antar-kluster (pemisahan antara kluster yang berbeda). Semakin kecil nilai DBI, semakin baik kualitas kluster yang terbentuk, karena menunjukkan bahwa setiap kluster memiliki karakteristik yang lebih seragam dan terpisah dengan baik dari kluster lainnya. Dalam penelitian ini, perhitungan DBI menghasilkan nilai 0.055, yang menunjukkan segmentasi dengan pemisahan kluster yang optimal dan distribusi data yang baik. Visualisasi hasil segmentasi dilakukan dalam bentuk grafik dan diagram untuk memberikan gambaran yang lebih jelas mengenai distribusi pelanggan dalam setiap kluster. Dengan evaluasi ini, dapat dipastikan bahwa *K-Means Clustering* menghasilkan segmentasi yang valid dan dapat digunakan untuk menyusun strategi pemasaran yang lebih tepat sasaran dalam industri telekomunikasi..

#### 2.6. Knowledge (Pemanfaatan Pengetahuan)


Segmentasi yang dihasilkan dievaluasi menggunakan *DBI* untuk mengukur kualitas kluster. Pola-pola segmentasi divisualisasikan dalam bentuk grafik dan diagram untuk memberikan pemahaman yang lebih jelas terkait karakteristik setiap kluster.

### 3. Hasil Penelitian

Penelitian ini bertujuan untuk mengelompokkan pelanggan jaringan telekomunikasi menggunakan algoritma *K-Means* sebagai upaya untuk mengoptimalkan strategi pemasaran. Dengan memanfaatkan data pelanggan terkait jenis layanan, pilihan paket, dan model perangkat di berbagai wilayah, hasil penelitian ini menghasilkan segmentasi yang mengidentifikasi pola preferensi pelanggan.

Mengindikasikan bahwa algoritma *K-Means* mampu mengungkap pola-pola spesifik dalam data pelanggan, memberikan pemahaman lebih dalam mengenai preferensi pelanggan yang relevan dengan penelitian ini [11]. Hasil segmentasi ini diharapkan dapat mendukung penyusunan strategi pemasaran yang lebih efektif dan sesuai dengan kebutuhan tiap segmen pelanggan. Segmentasi pelanggan

yang dilakukan dengan menggunakan *K-Means* dapat menjadi landasan yang baik dalam merancang strategi pemasaran yang sesuai dengan kebutuhan masing-masing segmen[12].



Gambar 2. Model Data Mining

Gambar 2. menggambarkan alur proses data mining dalam RapidMiner, dimulai dengan penggunaan operator Read Excel untuk mengimpor data dari file Excel ke dalam workflow. Selanjutnya, operator Set Role diterapkan untuk menetapkan peran atribut, yang memungkinkan penentuan variabel independen atau label untuk analisis lebih lanjut. Operator Select Attributes kemudian digunakan untuk memilih atribut yang relevan untuk proses *Clustering*, sambil menghapus data yang tidak berkontribusi pada analisis.

Operator *Clustering* selanjutnya menerapkan algoritma *K-Means* untuk mengelompokkan data berdasarkan karakteristik yang telah dipilih, menghasilkan kluster pelanggan. Akhirnya, operator Performance digunakan untuk mengevaluasi hasil *Clustering* dengan memberikan metrik yang menggambarkan kinerja model. Secara keseluruhan, proses ini memfasilitasi segmentasi pelanggan yang efektif serta analisis terhadap hasil segmentasi tersebut.

## PerformanceVector

```
PerformanceVector:
Avg. within centroid distance: 573.812
Avg. within centroid distance_cluster_0: 765.083
Avg. within centroid distance_cluster_1: 0.000
Avg. within centroid distance_cluster_2: 0.000
Davies Bouldin: 0.055
```

Gambar 3. Performance Vector

Gambar 3. menampilkan rata-rata jarak dalam centroid (*Avg. Within-Centroid Distance*) sebesar 573.812 menunjukkan tingkat variasi jarak data dalam *Cluster* yang relatif besar. Hal ini dapat dimaklumi apabila

dataset memiliki dimensi atau jumlah elemen yang besar.


Rincian jarak rata-rata untuk setiap *Cluster*:

- 1) *Cluster\_0* memiliki rata-rata jarak tertinggi, yaitu 765.083, yang mengindikasikan bahwa data dalam *Cluster* ini lebih tersebar dibandingkan *Cluster* lainnya.
- 2) *Cluster\_1* dan *Cluster\_2* menunjukkan nilai rata-rata jarak 0.000, yang kemungkinan besar disebabkan oleh jumlah elemen yang sangat kecil dalam *Cluster* tersebut.

*Davies-Bouldin Index* (DBI) sebesar 0.055 merupakan hasil evaluasi yang sangat baik. Nilai ini menunjukkan bahwa *Cluster* yang dihasilkan memiliki tingkat separasi yang baik serta data dalam masing-masing *Cluster* cukup seragam. DBI dihitung berdasarkan rasio antara jarak intra-kluster (variabilitas dalam satu kluster) dan jarak inter-kluster (variabilitas antar kluster). Semakin kecil nilai DBI, semakin baik kualitas kluster yang terbentuk. Dalam penelitian ini, nilai DBI yang rendah menunjukkan bahwa setiap kluster memiliki homogenitas yang tinggi serta keterpisahan yang jelas dari kluster lainnya. Dengan demikian, penggunaan DBI sebagai metrik evaluasi sangat efektif dalam menilai kualitas *Cluster*, memastikan bahwa data dalam setiap *Cluster* memiliki pemisahan yang jelas dan distribusi yang seragam [13].

Hasil visualisasi dalam proses data mining di RapidMiner merujuk pada cara data direpresentasikan secara visual, seperti dalam bentuk grafik, plot, dan bar. Menyoroti pentingnya peran visualisasi dalam proses analisis *Clustering*, yang menggunakan grafik, diagram, dan bar untuk memperoleh pemahaman yang lebih jelas mengenai perbedaan antar kluster serta untuk menentukan jumlah kluster yang optimal. Visualisasi ini membantu menggambarkan karakteristik data secara lebih rinci, sehingga mempermudah pemahaman terhadap struktur yang terkandung dalam data tersebut [14]. Penggunaan Bar pada penelitian ini bertujuan untuk melihat

karakteristik dari setiap Klaster. seperti yang ditunjukkan pada gambar dibawah ini.



Gambar 4. Hasil Visualisasi

Gambar 4. Menampilkan hasil visualisasi segmentasi pelanggan Bukadri Vision Net. Dari hasil ini cukup untuk melihat karakteristik dari setiap klaster, yang menunjukkan perbedaan penggunaan layanan internet dan perangkat antar klaster. Diterangkan bahwa visualisasi yang melibatkan grafik dan plot sangat berfungsi untuk menggambarkan karakteristik dari setiap klaster yang terbentuk, serta dapat mendukung pengembangan strategi promosi atau pemasaran berdasarkan perbedaan yang terlihat antar klaster [15]. Dengan demikian, hasil visualisasi ini sudah cukup untuk menentukan jumlah klaster optimal dalam segmentasi pelanggan telekomunikasi menggunakan algoritma *K-Means* berdasarkan karakteristik data yang berbeda.

#### 4. Kesimpulan

Penelitian ini membahas penerapan algoritma *K-Means* dalam segmentasi pelanggan telekomunikasi guna meningkatkan loyalitas dan retensi pelanggan. Hasil segmentasi menunjukkan tiga klaster utama berdasarkan jenis layanan, kecepatan internet, dan tipe perangkat. Setiap klaster memiliki karakteristik unik yang dapat digunakan sebagai dasar dalam menyusun strategi pemasaran yang lebih tepat sasaran. Penentuan jumlah klaster optimal menggunakan Davies-Bouldin Index (DBI) menghasilkan nilai 0.055, yang menunjukkan kualitas klaster yang baik. Dengan demikian, penerapan *K-Means* Clustering terbukti efektif dalam membantu perusahaan telekomunikasi memahami

pelanggan dan mengembangkan strategi pemasaran berbasis data yang lebih efisien.

#### 5. Saran

Penelitian dapat diperluas dengan metode *Clustering* lain seperti *K-Medoids* atau DBSCAN, serta memasukkan variabel tambahan (mis. data demografis atau perilaku). Hasil segmentasi dapat digunakan untuk merancang strategi pemasaran yang lebih terfokus dan mengembangkan layanan tambahan sesuai kebutuhan tiap segmen, guna meningkatkan loyalitas dan retensi pelanggan.

#### 6. Daftar Pustaka

- [1] S. F. Djun, I. G. A. Gunadi, and S. Sariyasa, "Analisis Segmentasi Pelanggan pada Bisnis dengan Menggunakan Metode K-Means Clustering pada Model Data RFM," *JTIM J. Teknol. Inf. dan Multimed.*, vol. 5, no. 4, pp. 354–364, 2024, doi: 10.35746/jtim.v5i4.434.
- [2] N. H. Harani, C. Prianto, and F. A. Nugraha, "Segmentasi Pelanggan Produk Digital Service Indihome Menggunakan Algoritma K-Means Berbasis Python," *J. Manaj. Inform.*, vol. 10, no. 2, pp. 133–146, 2020, doi: 10.34010/jamika.v10i2.2683.
- [3] Novi and A. Mubarak, "Penerapan Algoritma K-Means untuk Menentukan Kelas Unggulan di SMP Pelita Bandung," *Infomatek*, vol. 32, no. 2, pp. 97–106, 2021, doi: 10.23969/infomatek.v23i2.4351.
- [4] Y. Wicaksono, "Segmentasi Pelanggan Bisnis Dengan Multi Kriteria Menggunakan K-Means," vol. 1, no. 2, p. 45, 2019, doi: 10.21927/ijubi.v1i2.872.
- [5] F. D. S. Alhamdani, A. A. Dianti, and Y. Azhar, "Segmentasi Pelanggan Berdasarkan Perilaku Penggunaan Kartu Kredit Menggunakan Metode K-Means Clustering," *JISKA (Jurnal Inform. Sunan Kalijaga)*, vol. 6, no. 2, pp. 70–77, 2021, doi: 10.14421/jiska.2021.6.2.70-77.
- [6] K. Anam, R. Rusyana, B. Nurhakim, and D. Pratama, "Analisis Tingkat Penggunaan Gadget pada Anak Usia Dini dengan

- menggunakan K-Mean,” *J. Inform. dan Rekayasa Perangkat Lunak*, vol. 6, no. 1, 2024.
- [7] N. Rohman and A. Wibowo, “Perbandingan Metode K-Medoids dan Metode K-Means Dalam Analisis Segmentasi Pelanggan Mall,” *SINTECH (Science Inf. Technol. J.)*, vol. 7, no. 1, pp. 49–58, 2024, doi: 10.31598/sintechjournal.v7i1.1507.
- [8] K. Z. Wijaya, A. Djunaidi, and F. Mahananto, “Segmentasi Pelanggan Menggunakan Algoritma K-Means dan Analisis RFM di Ova Gaming E-Sports Arena Kediri,” *J. Tek. ITS*, vol. 10, no. 2, 2021, doi: 10.12962/j23373539.v10i2.67707.
- [9] A. H. Fazri, A. Muhammad, P. Ayu, and W. Purnama, “Algoritma K-Means Cluster untuk Segmentasi Pelanggan,” *Cbis J.*, vol. 11, no. 02, pp. 42–51, 2023.
- [10] S. Maulani, O. Herdiana, and E. A. Firdaus, “Strategi Pemasaran Produk Industri Kreatif Menggunakan Algoritma K-Means Clustering Berbasis Particle Swarm Optimization,” *Nuansa Inform.*, vol. 15, no. 2, pp. 1–13, 2021, doi: 10.25134/nuansa.v15i2.4394.
- [11] S. Pujiono, R. Astuti, and F. Muhamad Basysyar, “Implementasi Data Mining Untuk Menentukan Pola Penjualan Produk Menggunakan Algoritma K-Means Clustering,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 1, pp. 615–620, 2024, doi: 10.36040/jati.v8i1.8360.
- [12] S. Sajidah, R. Herdiana, and D. Solihudin, “Segmentasi Pelanggan Salon Nuii Beauty Glow Menggunakan K-Means Clustering,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 7, no. 1, pp. 558–566, 2023, doi: 10.36040/jati.v7i1.6333.
- [13] M. Syam Al ghifari, M. Martanto, and U. Hayati, “Pengelompokan Transaksi Penjualan Aksesoris Hp Dan Pulsa Dengan Metode K-Means Untuk Meningkatkan Strategi Pemasaran Di Toko Bagus Celluler,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 3, pp. 2838–2849, 2024, doi: 10.36040/jati.v8i3.9559.
- [14] M. R. Sulistio, N. Suarna, and O. Nurdiawan, “Analisa Penerapan Metode Clustering X-Means Dalam Pengelompokan Penjualan Barang,” *J. Teknol. Ilmu Komput.*, vol. 1, no. 2, pp. 37–42, 2023, doi: 10.56854/jtik.v1i2.49.
- [15] T. Hartati, O. Nurdiawan, and E. Wiyandi, “Analisis Dan Penerapan Algoritma K-Means Dalam Strategi Promosi Kampus Akademi Maritim Suaka Bahari,” *J. Sains Teknol. Transp. Marit.*, vol. 3, no. 1, pp. 1–7, 2021, doi: 10.51578/j.sitektransmar.v3i1.30.