

PENERAPAN ALGORITMA K-MEDOIDS UNTUK SEGMENTASI PELANGGAN BERDASARKAN PERILAKU TRANSAKSIONAL PADA GERAJ MAKANAN CEPAT SAJI

Melinda Putri Azzahra^{1*}, Wahyu Syaifullah J.S², Muhammad Nasrudin³

^{1,2,3}Program Studi Sains Data, UPN “Veteran” Jawa Timur, Surabaya, Indonesia

*Penulis korespondensi: 22083010035@student.upnjatim.ac.id

ABSTRAK

Kondisi persaingan yang semakin ketat pada industri makanan cepat saji menuntut setiap gerai untuk memahami perilaku pelanggan secara lebih akurat agar strategi pemasaran dapat dirumuskan dengan tepat sasaran. Meskipun data transaksi tersedia dalam jumlah besar, pemanfaatannya seringkali belum optimal sehingga pola pembelian pelanggan tidak teridentifikasi dengan baik dan menghambat pengambilan keputusan pemasaran. Penelitian ini bertujuan untuk menghasilkan segmentasi pelanggan berdasarkan perilaku transaksional dengan menerapkan algoritma K-Medoids sebagai metode pengelompokan. Algoritma K-Medoids digunakan karena mampu membentuk *cluster* yang stabil melalui pemilihan objek aktual sebagai pusat *cluster*. Penelitian ini menggunakan data sekunder berupa 6.386 baris data transaksi yang diambil dari sistem *Point of Sale* (POS) salah satu gerai makanan cepat saji pada bulan Maret 2025. Proses analisis mencakup pra-pemrosesan data, normalisasi, perhitungan jarak menggunakan Euclidean, serta pembentukan *cluster* menggunakan algoritma K-Medoids, sementara validitas *cluster* dievaluasi menggunakan *Silhouette Score*. Data transaksi yang dianalisis menghasilkan lima kelompok pelanggan dengan karakteristik yang berbeda, yang menggambarkan keragaman pola pembelian pada masing-masing segmen. Setiap *cluster* merepresentasikan perilaku pembelian yang unik, mulai dari transaksi sangat kecil hingga transaksi bernilai sangat tinggi. Hasil ini menunjukkan bahwa proses *clustering* berhasil mengungkap perbedaan perilaku pelanggan secara jelas. Kesimpulan penelitian menegaskan bahwa algoritma K-Medoids mampu menghasilkan segmentasi pelanggan yang informatif, relevan, dan dapat digunakan sebagai dasar penyusunan strategi pemasaran yang lebih efektif, seperti promosi terarah pada gerai makanan cepat saji.

Kata kunci: Segmentasi pelanggan, K-Medoids, Data transaksi, *Clustering*, Strategi pemasaran.

1 PENDAHULUAN

Persaingan yang ketat di industri makanan cepat saji menuntut setiap pelaku usaha untuk tidak hanya menawarkan produk yang berkualitas, tetapi juga mampu merumuskan strategi pemasaran yang sangat personal dan terarah (Putri, 2024). Dalam konteks ini, data transaksi pelanggan yang terekam secara masif melalui sistem *Point of Sale* (POS) menjadi aset berharga yang dapat dimanfaatkan untuk memahami perilaku konsumen secara mendalam. Dengan mengintegrasikan data POS, perusahaan dapat mengungkap pola pembelian, preferensi produk, dan tren pelanggan yang sebelumnya tidak terlihat melalui analisis tradisional (Kholod et al., 2024). Meskipun data tersedia berlimpah, banyak gerai makanan cepat saji belum optimal dalam mengolah dan mengambil informasi dari data tersebut, yang mengakibatkan pola pembelian pelanggan tidak teridentifikasi secara jelas. Ketidadaan pemahaman yang akurat mengenai karakteristik dan preferensi segmen pelanggan ini menghambat perumusan pemasaran yang efisien dan efektif, seperti program loyalitas atau penawaran promosi yang sesuai.

Segmentasi pelanggan merupakan salah satu teknik fundamental dalam pemasaran modern untuk membagi pasar heterogen menjadi kelompok-kelompok homogen yang memiliki kebutuhan dan perilaku serupa (Prasetya, 2025). Segmentasi yang didasarkan pada perilaku transaksional memiliki relevansi tinggi, terutama pada bisnis ritel dan jasa makanan, karena secara langsung mencerminkan nilai dan potensi keuntungan dari setiap pelanggan (Prasetya, 2025). Berbagai studi telah menggunakan *data mining* untuk tujuan segmentasi, dengan algoritma *clustering* menjadi metode yang dominan. Algoritma K-Means sering digunakan, namun kelemahannya terletak pada sensitivitas terhadap *outlier* dan pemilihan *mean* sebagai pusat *cluster* yang mungkin bukan merupakan objek data aktual (Rahmah, 2024). Sebagai alternatif, algoritma K-Medoids menawarkan solusi yang lebih robust karena menggunakan medoid (objek data aktual yang berada di pusat *cluster*) sebagai representasi *cluster*, sehingga menghasilkan *cluster* yang lebih stabil (Agustin et al., 2025). Penerapan K-Medoids pada data transaksional diharapkan dapat mengatasi keterbatasan metode sebelumnya dan menghasilkan segmentasi yang lebih akurat (Mirantika & Rijanto, 2025).

Beberapa penelitian terdahulu telah mengaplikasikan *clustering* untuk segmentasi. Misalnya, penelitian oleh Setia Rahayu dan Sulianta (2025) menggunakan *clustering* untuk mengelompokkan gaji karyawan berdasarkan penilaian kinerja, sementara Nurmilayanti dan Hartono (2023) menerapkan K-Medoids untuk segmentasi pelanggan ritel. Meskipun demikian, eksplorasi mendalam terhadap segmentasi pelanggan gerai makanan cepat saji secara spesifik, yang mana karakteristik transaksinya sangat bervariasi, mulai dari pembelian tunggal hingga transaksi yang bernilai sangat tinggi, menggunakan algoritma K-Medoids masih perlu diperkuat untuk membuktikan kemampuannya dalam mengungkap pola pembelian yang kompleks. Berdasarkan kesenjangan penelitian yang ada, penelitian ini menghadapi permasalahan utama terkait penerapan algoritma K-Medoids pada data transaksi gerai makanan cepat saji untuk menghasilkan kelompok pelanggan dengan perilaku pembelian yang teridentifikasi secara jelas dan berbeda, dengan hipotesis bahwa algoritma K-Medoids mampu mengidentifikasi beberapa kelompok pelanggan yang memiliki perbedaan signifikan dalam perilaku transaksional, mulai dari pelanggan bernilai sangat rendah hingga pelanggan bernilai sangat tinggi.

Dengan mempertimbangkan kesenjangan penelitian dan kebutuhan praktis di industri makanan cepat saji, penelitian ini bertujuan untuk menerapkan algoritma K-Medoids untuk menghasilkan segmentasi pelanggan berdasarkan perilaku transaksional pada gerai makanan cepat saji, serta mengevaluasi validitas *cluster* yang terbentuk untuk memberikan dasar yang kuat bagi perumusan strategi pemasaran yang lebih efektif dan terarah.

2 METODE

2.1 Pengumpulan Data

Penelitian ini menggunakan data sekunder yang diperoleh dari sistem *Point of Sale* (POS) pada salah satu gerai makanan cepat saji. Data yang digunakan merupakan data transaksi penjualan yang telah diizinkan untuk diakses dan dianalisis dalam konteks penelitian ini. Proses pengumpulan data dilakukan melalui pengambilan data dari sistem POS gerai terkait selama periode operasional bulan Maret 2025, dengan tetap menjaga kerahasiaan informasi internal perusahaan dan tidak menampilkan identitas pribadi pelanggan.

2.2 Pra-pemrosesan Data

2.2.1 Transformasi Tipe Data

Transformasi tipe data dilakukan untuk memastikan seluruh atribut numerik berada dalam format yang sesuai. Atribut jumlah pembelian dan nilai transaksi dikonversi ke dalam tipe numerik agar dapat diproses secara matematis pada tahap *clustering* berbasis jarak.

2.2.2 Agregasi Data

Data transaksi diagregasi berdasarkan nomor transaksi untuk membentuk representasi perilaku pelanggan. Proses agregasi menghasilkan variabel utama berupa total jumlah item yang dibeli dan total nilai transaksi. Agregasi ini bertujuan untuk menyederhanakan data dan memfokuskan analisis pada karakteristik pembelian pelanggan.

2.2.3 Pembentukan Variabel '*Item_Sales*'

Pada penelitian ini, variabel *Item_Sales* dibentuk sebagai representasi nilai penjualan pelanggan. Variabel *Item_Sales* disetarakan dengan total nilai transaksi (*total amount*), karena mencerminkan besarnya kontribusi pelanggan terhadap penjualan pada setiap transaksi. Variabel ini digunakan sebagai salah satu atribut dalam proses *clustering* untuk membedakan pelanggan berdasarkan tingkat nilai pembelian.


2.2.4 Normalisasi Data

Normalisasi data dilakukan untuk menyamakan skala antar variabel yang digunakan dalam proses *clustering*. Metode normalisasi yang diterapkan adalah standardisasi data, di mana setiap variabel ditransformasikan sehingga memiliki nilai rata-rata nol dan simpangan baku satu. Normalisasi ini diperlukan karena perhitungan jarak Euclidean yang sensitif terhadap perbedaan skala, sehingga setiap variabel dapat berkontribusi secara seimbang dalam pembentukan *cluster*.

2.3 Implementasi K-Medoids

Metode yang digunakan dalam penelitian ini adalah algoritma K-Medoids dengan pendekatan *Partitioning Around Medoids* (PAM). Algoritma K-Medoids dipilih karena mampu membentuk *cluster* yang lebih stabil dibandingkan K-Means, terutama pada data transaksi yang berpotensi mengandung *outlier*, karena pusat *cluster* ditentukan dari objek data aktual (medoid) (Orisa & Faisol, 2025).

Proses *clustering* diawali dengan penentuan jumlah *cluster* (k) yang akan diuji. Untuk setiap nilai k , algoritma K-Medoids melakukan inisialisasi medoid secara acak, kemudian menghitung jarak antara setiap data pelanggan dengan medoid menggunakan jarak Euclidean. Setiap data akan dikelompokkan ke dalam *cluster* dengan medoid terdekat (Yosia & Siregar, 2024). Selanjutnya, algoritma melakukan pembaruan medoid dengan cara memilih objek dalam setiap *cluster* yang meminimalkan total jarak terhadap seluruh anggota *cluster* tersebut. Proses ini dilakukan secara iteratif hingga tidak terjadi perubahan medoid atau telah mencapai jumlah iterasi maksimum (Saderisa et al., 2025).



Gambar 1. Proses algoritma K-Medoids

2.4 Uji Validitas

Uji validitas hasil *clustering* dilakukan menggunakan *Silhouette Score*. Metode ini digunakan untuk mengukur tingkat kesesuaian suatu data terhadap *cluster* tempat data tersebut berada dibandingkan dengan *cluster* lainnya. Nilai *Silhouette* berada pada rentang -1 hingga 1 , di mana nilai yang mendekati 1 menunjukkan kualitas *clustering* yang semakin baik (Hasan, 2024). *Silhouette Score* dihitung untuk setiap nilai k yang diuji, kemudian nilai k dengan nilai *Silhouette* tertinggi dipilih sebagai jumlah *cluster* terbaik. *Silhouette Score* dihitung dengan rumus berikut (Januzaj et.al., 2023):

$$s(i) = \frac{d(i) - d(i)}{max(d(i), d(i))}$$

dimana $d(i)$ adalah jarak rata-rata dari sampel i ke sampel lain dalam suatu *cluster*, dan $d(i)$ adalah jarak minimum suatu sampel dari sampel i ke *cluster* lain.

2.5 Analisis Hasil

Analisis hasil digunakan untuk menganalisis dan menginterpretasikan hasil segmentasi pelanggan yang diperoleh dari penerapan algoritma K-Medoids. Analisis dilakukan dengan mengevaluasi hasil pengelompokan data ke dalam sejumlah *cluster* untuk memahami pola kesamaan dan perbedaan karakteristik pelanggan pada setiap *cluster* yang terbentuk. Hasil segmentasi kemudian dianalisis secara deskriptif guna memberikan makna terhadap masing-masing segmen pelanggan serta memastikan bahwa *cluster* yang dihasilkan memiliki keterkaitan yang logis, sehingga dapat digunakan sebagai dasar dalam penyusunan kesimpulan dan rekomendasi strategis

3 HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Dataset yang digunakan terdiri dari 6.386 baris data transaksi, di mana setiap baris merepresentasikan satu aktivitas transaksi pelanggan. Data transaksi tersebut memuat informasi

yang berkaitan dengan perilaku pembelian pelanggan, meliputi waktu transaksi, identitas transaksi, informasi menu yang dibeli, jumlah pembelian, harga satuan, serta total nilai transaksi.

Tabel 1. Dataset

tanggal	nomor	kode_menu	menu	qty	unit_price	total_price
2025-03-01	1740794457	48	DADA + NASI	1	17500	17500
2025-03-01	1740794507	9	NASI	2	5000	10000
2025-03-01	1740794804	1521	PAHA BAWAH + ORI + NASI + SAMBAL GEPREK	1	15000	15000
...	...	...	...	...	...	...
2025-03-28	1743160396	7808	AYAM BEKAKAK	1	55000	55000
2025-03-28	1743162791	7808	AYAM BEKAKAK	1	55000	55000
2025-03-28	1743162791	10718	BEEF CHEESE BURGER	1	14000	14000

3.2 Pra-pemrosesan Data

3.2.1 Transformasi Tipe Data

Beberapa atribut pada dataset awal masih tersimpan dalam format yang kurang sesuai, seperti kolom tanggal dan waktu transaksi yang masih berupa teks (*string*). Kolom tersebut kemudian dikonversi ke dalam tipe data *datetime* agar dapat digunakan untuk analisis berbasis waktu, seperti pengelompokan transaksi berdasarkan hari tertentu. Selain itu, kolom numerik seperti jumlah pembelian (*qty*), harga satuan (*unit_price*), dan total nilai transaksi (*total_price*) dipastikan berada dalam format numerik. Proses ini bertujuan untuk menghindari kesalahan perhitungan serta memastikan data dapat diproses dengan benar pada tahap agregasi dan normalisasi.

3.2.2 Agregasi Data

Pada tahap ini, data dikelompokkan berdasarkan identitas transaksi atau pelanggan untuk memperoleh ringkasan informasi transaksi. Proses agregasi menghasilkan data yang lebih ringkas dan representatif, seperti total jumlah item yang dibeli dan total nilai transaksi dalam satu transaksi. Dengan adanya agregasi ini, analisis pola pembelian dapat dilakukan secara lebih efektif karena unit analisis tidak lagi berupa item tunggal, melainkan satu kesatuan aktivitas transaksi pelanggan.

3.2.3 Pembentukan Variabel ‘*Item_Sales*’

Setelah proses agregasi dilakukan, dibentuk variabel baru bernama *Item_Sales*. Variabel ini merepresentasikan kombinasi item atau total penjualan item dalam satu transaksi, yang digunakan sebagai dasar untuk analisis pola pembelian pelanggan. Pembentukan variabel *Item_Sales* bertujuan untuk menyederhanakan struktur data sekaligus menonjolkan informasi utama terkait perilaku pembelian.

3.2.4 Normalisasi Data

Tahap normalisasi data dilakukan untuk menyamakan skala antar variabel numerik agar tidak terjadi dominasi nilai tertentu pada proses analisis. Variabel seperti total jumlah item dan total nilai transaksi memiliki rentang nilai yang cukup besar dan berbeda satu sama lain. Oleh karena itu, normalisasi dilakukan menggunakan metode *Min-Max Scaling* yang mengubah nilai data ke dalam rentang 0 hingga 1.

3.3 Implementasi K-Medoids

Berdasarkan hasil implementasi algoritma K-Medoids dengan pendekatan *Partitioning Around Medoids (PAM)*, diperoleh jumlah *cluster* sebanyak 5 *cluster* ($k = 5$) dengan indeks medoid terpilih yaitu [573, 318, 2838, 668, dan 38]. Proses *clustering* menghasilkan nilai total *cost* sebesar 333,9071, yang merepresentasikan jumlah jarak seluruh data terhadap medoid *cluster* masing-masing. Nilai total *cost* ini digunakan sebagai indikator kualitas *clustering*, di mana nilai yang lebih kecil menunjukkan bahwa data dalam setiap *cluster* semakin kompak dan medoid yang terbentuk semakin representatif terhadap kelompoknya.

Distribusi jumlah data pada setiap *cluster* menunjukkan perbedaan yang cukup signifikan, yaitu *Cluster 0* sebanyak 1 data, *Cluster 1* sebanyak 558 data, *Cluster 2* sebanyak 2.326 data, *Cluster 3* sebanyak 24 data, dan *Cluster 4* sebanyak 1.429 data. *Cluster* dengan jumlah anggota terbesar mencerminkan pola dominan dalam data, sedangkan *cluster* dengan anggota sangat sedikit mengindikasikan adanya pola khusus atau data yang berpotensi sebagai *outlier*. Hal ini menunjukkan bahwa algoritma K-Medoids mampu membentuk segmentasi data yang stabil dan efektif, terutama pada data yang memiliki variasi karakteristik yang tinggi. Adapun ringkasan hasil pengelompokan data menggunakan algoritma K-Medoids dapat dilihat pada Gambar 2.

```
=== Hasil Clustering K-Medoids ===
Jumlah cluster (k)      : 5
Indeks medoid terpilih  : [ 573  318 2838  668  38]
Nilai total cost       : 333.9071
Jumlah data tiap cluster:
Cluster 0 : 1 data
Cluster 1 : 558 data
Cluster 2 : 2326 data
Cluster 3 : 24 data
Cluster 4 : 1429 data
```

Gambar 2. Hasil *clustering* K-Medoids

3.4 Uji Validitas

Uji validitas dilakukan untuk mengevaluasi apakah nilai k merupakan jumlah *cluster* yang paling optimal. Pengujian dilakukan pada *cluster* dengan nilai $k = 2$ sampai dengan nilai $k = 5$. Dari Tabel 2 yang disajikan, didapatkan nilai *Silhouette* maksimum yaitu 0,5433 menunjukkan bahwa $k = 5$ merupakan jumlah *cluster* yang optimal.

Tabel 2. Validasi *cluster* optimal

Jumlah Cluster (k)	Nilai <i>Silhouette</i>
2	0,5095
3	0,5425
4	0,4973
5	0,5433

3.5 Analisis Hasil

Tahap selanjutnya adalah menganalisis karakteristik dari setiap *cluster* yang terbentuk. Analisis ini dilakukan dengan menghitung ringkasan statistik pada masing-masing *cluster* berdasarkan fitur utama yang digunakan, yaitu *Item_Sales*, *Total_Amount*, dan *Total_Quantities*. Ringkasan statistik tersebut meliputi jumlah data, nilai rata-rata (*mean*), nilai tengah (*median*), dan simpangan baku (*standard deviation*) yang bertujuan untuk menggambarkan pola dan perbedaan perilaku pembelian pelanggan pada setiap segmen. Hasil ringkasan statistik tiap *klaster* disajikan pada Gambar 2.

Ringkasan Cluster (fitur asli):

Item_Sales				Total_Amount			\
cluster	count	mean	median	std	count	mean	
0	1	7380000.00	7380000.0	NaN	1	7380000.00	
1	558	53477.08	48250.0	19454.27	558	53477.08	
2	1429	26399.23	26000.0	5616.10	1429	26399.23	
3	24	356250.00	300000.0	149864.94	24	356250.00	
4	2326	14273.52	14500.0	3599.63	2326	14273.52	

Total_Quantities						
cluster	median	std	count	mean	median	std
0	7380000.0	NaN	1	720.00	720.0	NaN
1	48250.0	19454.27	558	3.96	4.0	1.47
2	26000.0	5616.10	1429	2.21	2.0	0.64
3	300000.0	149864.94	24	22.17	20.0	9.60
4	14500.0	3599.63	2326	1.06	1.0	0.26

Gambar 3. Ringkasan statistik tiap *cluster*

Dari hasil analisis pada Gambar 3 menunjukkan bahwa pelanggan gerai makanan cepat saji dapat dibagi menjadi 5 kelompok atau segmen dengan penjelasan sebagai berikut:

Tabel 3. Validasi *cluster* optimal

Segmen	Tipe	Karakteristik
0	Transaksi Ekstrem/ <i>Outlier</i>	a. Pembelian dalam jumlah sangat besar, kemungkinan pesanan
1	Pelanggan Pembeli Besar/ <i>High Spender</i>	a. Pengeluaran tinggi b. Membeli banyak menu sekaligus c. Transaksi bernilai menengah keatas
2	Pelanggan Pembeli Sedang/ <i>Mid Spender</i>	a. Pengeluaran moderat b. Pembelian 1-2 item c. Sering membeli menu reguler
3	Pelanggan Premium/ <i>Very High Spender</i>	a. Pengeluaran sangat tinggi b. Pembelian dalam jumlah besar c. Nilai transaksi rata-rata jauh diatas pelanggan lain
4	Pelanggan Pembeli Kecil/ <i>Low Spender</i>	a. Pengeluaran rendah b. Rata-rata membeli 1 item c. Transaksi biasa untuk makan pribadi cepat

4 KESIMPULAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa pemanfaatan data transaksi pelanggan dengan pendekatan *data mining* mampu memberikan pemahaman yang lebih mendalam mengenai pola perilaku pembelian pelanggan pada gerai makanan cepat saji. Melalui tahapan pra-pemrosesan yang meliputi transformasi tipe data, agregasi transaksi, pembentukan variabel Item_Sales, serta normalisasi data, diperoleh dataset yang siap dianalisis dan representatif untuk menggambarkan aktivitas transaksi pelanggan secara komprehensif.

Implementasi algoritma K-Medoids dengan pendekatan *Partitioning Around Medoids* (PAM) berhasil membentuk segmentasi pelanggan yang stabil dan bermakna. Hasil evaluasi

menggunakan *Silhouette Score* menunjukkan bahwa jumlah *cluster* optimal adalah lima, yang menandakan bahwa struktur segmentasi yang terbentuk memiliki tingkat kohesi dan separasi yang baik. Segmentasi ini mampu mengelompokkan pelanggan ke dalam beberapa segmen dengan karakteristik pengeluaran dan jumlah pembelian yang berbeda, mulai dari pelanggan dengan pengeluaran rendah hingga pelanggan dengan nilai transaksi sangat tinggi, termasuk transaksi ekstrem atau *outlier*.

Temuan penelitian ini menunjukkan bahwa algoritma K-Medoids efektif digunakan untuk analisis segmentasi pelanggan berbasis data transaksi, terutama pada data yang memiliki variasi nilai yang besar dan potensi *outlier*. Segmentasi yang dihasilkan dapat dimanfaatkan sebagai dasar pengambilan keputusan strategis, seperti penentuan target promosi, penyusunan paket menu, serta pengembangan strategi pemasaran yang lebih tepat sasaran sesuai dengan karakteristik masing-masing segmen pelanggan.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada semua pihak yang telah memberikan dukungan dan bantuan dalam pelaksanaan penelitian ini, baik dalam bentuk dukungan data, perizinan, bimbingan, maupun masukan yang berharga. Secara khusus, penulis menyampaikan apresiasi kepada pihak pengelola gerai makanan cepat saji yang telah memberikan izin dan akses data transaksi, serta kepada dosen pembimbing dan pihak terkait lainnya yang telah memberikan arahan dan saran sehingga penelitian ini dapat diselesaikan dengan baik.

DAFTAR PUSTAKA

- Agustin, E. W., Uthami, K., Ulfa, A. I., Efrizoni, L., & Rahmaddeni, R. (2025). Optimization of customer segmentation in the retail industry using the K-Medoid algorithm. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 5(3).
- Hasan, Y. (2024). Pengukuran *Silhouette Score* dan Davies-Bouldin Index pada Hasil Cluster K-Means dan DBSCAN. *KAKIFIKOM (Kumpulan Artikel Karya Ilmiah Fakultas Ilmu Komputer)*.
- Januzaj, Y., Beqiri, E., & Luma, A. (2023). Determining the Optimal Number of Clusters using *Silhouette Score* as a Data Mining Technique. *i-JOE International Journal of Online Engineering*, 19(04).
- Kholod, M., Celani, A., & Ciaramella, G. (2024). The analysis of customers' transactions based on POS and RFID data using big data analytics tools in the retail space of the future. *Applied Sciences*, 14(24), 11567.
- Mirantika, N., & Rijanto, E. (2025). Implementasi metode clustering partisi (K-Means dan K-Medoids) dalam menentukan segmentasi pelanggan. *Jurnal Tata Kelola dan Kerangka Kerja Teknologi Informasi*, 10(1).
- Nurmilayanti, & Hartono, N. (2023). Implementasi metode clustering sebagai penunjang strategi dalam manajemen pelanggan. *Jurnal Ilmu Komputer (JIK)*, Fakultas Ilmu Komputer, Universitas Muhammadiyah Riau.
- Orisa, M., & Faisol, A. (2025). Analisis algoritma Partitioning Around Medoid untuk penentuan klasterisasi. *Jurnal Teknologi Informasi dan Terapan*, 8(2).
- Prasetya, Y. R. (2025). Systematic literature review: Customer segmentation and its strategic importance in retail marketing. *TechnovAsia Journal*.
- Putri, Y. (2024). Retail marketing strategy optimization: Customer segmentation using K-Means & RFM. *Sinkron Journal*, 2024.

- Rahmah, S. A. (2024). Sensitivitas metode K-Means terhadap outlier dan tantangan dalam klasterisasi data. *Djtechno: Jurnal Teknologi Informasi*, 5(2).
- Saderisa, S., Syaripuddin, & Raming, I. (2025). Penerapan algoritma K-Medoids pada pengelompokan kabupaten/kota berdasarkan indikator kemiskinan. *Jurnal Matematika dan Terapan*, 7(1).
- Setia Rahayu, Y. P., & Sulianta, F. (2025). Data Mining Gaji Karyawan Berdasarkan Penilaian dengan K-Medoids Clustering.
- Yosia & Siregar, B. (2024). Comparative analysis of K-Means and K-Medoids algorithms for product sales and customer clustering. *Journal of Mathematics, Computations and Statistics*, 7(2).