

---

## Penerapan Algoritma K-Means Clustering dalam Menganalisis Tren Konsumen E-Commerce

Andika Mahesa Putra<sup>1)</sup>, Rahmaddeni<sup>2)</sup> Candra Saputra<sup>3)</sup> Rahmat Hidayatullah<sup>4)</sup> Safril Irsandi <sup>5)</sup>

<sup>1,2,3,5)</sup>Prodi Teknik Informatika,Fakultas Teknik,Universitas Sains Dan Teknologi Indonesia <sup>4)</sup>Prodi Teknik Informatika,Universitas Dumai

\*Corresponding Email : <sup>1)</sup>[andikamahesa413@gmail.com](mailto:andikamahesa413@gmail.com) <sup>2)</sup>[rahmaddeni@sar.ac.id](mailto:rahmaddeni@sar.ac.id)  
<sup>3)</sup>[akunsaputracandra@gmail.com](mailto:akunsaputracandra@gmail.com) <sup>4)</sup>[boyvatandroid@gmail.com](mailto:boyvatandroid@gmail.com) <sup>5)</sup>[irsandisafril@gmail.com](mailto:irsandisafril@gmail.com)

---

### Abstrak

Penelitian ini membahas penerapan algoritma K-Means untuk menganalisis perilaku konsumen pada platform e-commerce. Dengan menggunakan dataset yang terdiri dari 3.900 entri pelanggan, data diproses melalui tahapan preprocessing, normalisasi Min-Max, dan encoding. Jumlah kluster optimal ditentukan menggunakan metode Elbow dan Silhouette Score, menghasilkan dua segmen utama pelanggan: aktif dan pasif. Visualisasi dengan PCA menunjukkan pemisahan kluster yang jelas. Hasil ini memberikan wawasan strategis bagi perusahaan untuk menyusun pendekatan pemasaran berbasis data yang lebih efektif, serta meningkatkan loyalitas pelanggan dan pendapatan bisnis.

**Kata kunci:** K-Means, e-commerce, segmentasi pelanggan, data mining, PCA

### Abstract

This study explores the application of the K-Means algorithm to analyze consumer behavior on e-commerce platforms. Using a dataset of 3,900 customer entries, the data underwent preprocessing, Min-Max normalization, and label encoding. The optimal number of clusters was determined using the Elbow Method and Silhouette Score, resulting in two primary customer segments: active and passive. Visualization with PCA showed clear cluster separation. These findings offer strategic insights for businesses to develop more effective data-driven marketing approaches, increase customer loyalty, and boost revenue.

**Keywords:** K-Means, e-commerce, customer segmentation, data mining, PCA

---

## PENDAHULUAN

Perkembangan teknologi informasi telah mendorong pertumbuhan signifikan dalam sektor perdagangan digital, khususnya melalui platform *e-commerce*. Di Indonesia, pertumbuhan industri ini terjadi secara pesat, ditandai dengan meningkatnya jumlah transaksi daring, pelaku usaha digital, serta keterlibatan konsumen dalam aktivitas belanja online. Dalam konteks ini, pemahaman terhadap perilaku konsumen menjadi kebutuhan strategis yang tidak dapat diabaikan oleh pelaku bisnis .

1. Data transaksi yang dihasilkan oleh aktivitas konsumen dalam platform *e-commerce* menyimpan potensi informasi yang sangat besar. Apabila dianalisis dengan metode yang tepat, data tersebut dapat mengungkap pola konsumsi, preferensi produk, hingga kecenderungan loyalitas pelanggan . Salah satu pendekatan yang dapat digunakan untuk menggali informasi dari data tersebut adalah teknik *data mining*, khususnya metode *clustering*. Teknik ini memungkinkan pengelompokan data ke dalam beberapa kelompok berdasarkan kemiripan karakteristik.
2. Salah satu algoritma *clustering* yang umum digunakan adalah K-Means. Algoritma ini membagi data ke dalam sejumlah klaster berdasarkan kedekatan nilai atribut terhadap pusat klaster atau *centroid*. Penerapan K-Means dianggap efektif untuk proses segmentasi konsumen karena mampu menyederhanakan struktur data kompleks menjadi kelompok-kelompok yang lebih terstruktur. Segmentasi yang dihasilkan dapat digunakan untuk memahami tren konsumen serta menyusun strategi pemasaran yang lebih personal dan tepat sasaran.
3. Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk menerapkan algoritma K-Means dalam mengelompokkan data konsumen dari platform *e-commerce* dan menganalisis pola atau tren perilaku yang muncul dari hasil klasterisasi. Permasalahan yang dikaji dalam penelitian ini meliputi bagaimana proses penerapan algoritma K-Means dalam mengelompokkan data

konsumen, serta trend perilaku konsumen apa yang dapat diidentifikasi dari hasil tersebut. Hasil dari penelitian ini diharapkan memberikan kontribusi baik secara teoritis maupun praktis, terutama dalam mendukung pengambilan keputusan berbasis data di sektor e-commerce

4. Penelitian ini memberikan manfaat antara lain sebagai alternatif solusi untuk segmentasi pelanggan secara otomatis menggunakan pendekatan algoritma K-Means, serta sebagai referensi bagi perusahaan dalam menyusun strategi bisnis berbasis kluster pelanggan. Dengan adanya segmentasi yang tepat, pelaku bisnis diharapkan dapat meningkatkan efisiensi pemasaran, loyalitas pelanggan, dan relevansi produk yang ditawarkan

## METODOLOGI PENELITIAN

Penelitian ini dilakukan secara sistematis untuk menganalisis perilaku pelanggan pada platform e-commerce menggunakan algoritma K-Means Clustering. Adapun tahapan dalam penelitian ini disusun berdasarkan alur proses yang ditunjukkan pada Gambar 1 berikut:



Gambar 1 Metode Penelitian

### Pengumpulan Data

Data bersumber dari Kaggle yang dimana dataset Pelanggan E-commerce tersebut memiliki 3900 entri dan 15 atribut, seperti :

- |                          |                        |
|--------------------------|------------------------|
| a. Customer Id           | i. Size                |
| b. Age                   | j. Subscription Status |
| c. Gender                | k. review rating       |
| d. Item Purchase         | l. Discount Applied    |
| e. Category              | m. Promo code used     |
| f. Purchase Amount       | n. Previous Purchase   |
| g. Location              | o. Payment Method      |
| h. Frequency of Purchase |                        |

### Preprocessing Data

Preprocessing dilakukan untuk menyiapkan data sebelum proses klusterisasi.

Proses ini meliputi:

- Menghapus nilai kosong (missing value) jika ada, atau mengganti dengan rata-rata/modus.
- Encoding label untuk fitur kategorikal menggunakan LabelEncoder,
- Normalisasi data numerik menggunakan MinMaxScaler agar fitur memiliki skala yang sama dan tidak bias terhadap fitur dengan nilai besar.

Tools Yang digunakan :

- Google Colaboratory: platform cloud-based berbasis Python,
- Pandas: untuk pemrosesan dan analisis data,
- Scikit-learn: untuk normalisasi data, algoritma K-Means, dan PCA,
- Matplotlib & Seaborn: untuk visualisasi grafik dan hasil klusterisasi,
- Excel / OpenPyXL: untuk menyimpan hasil akhir klusterisasi.
- Label Encoder : untuk mengubah data kategorikal menjadi bentuk numerik agar dapat diproses Algoritma K-Means



### Fitur Selection

Fitur yang digunakan dalam proses klasterisasi dibagi menjadi dua kategori: Fitur utama, yang digunakan untuk proses K-Means, yaitu: Previous Purchases, Purchase Amount (USD), Frequency of Purchases, Age, dan Review Rating. Fitur pendukung, yang digunakan untuk profiling karakteristik klaster, seperti: Gender, Shipping Type, Subscription Status, Discount Applied, dan Promo Code Used.

### Menentukan Jumlah Klaster (k)

Penentuan jumlah klaster (k) dilakukan menggunakan **metode Elbow**. Metode ini menghitung nilai WCSS (Within-Cluster Sum of Squares) untuk berbagai nilai k, lalu dipilih nilai k yang memberikan penurunan WCSS yang signifikan terakhir. Selain itu, kualitas pemisahan klaster diuji menggunakan Silhouette Score, yang menunjukkan seberapa baik data dalam satu klaster memiliki kemiripan satu sama lain.

### Klasterisasi K-Means

K-Means digunakan untuk membagi data ke dalam beberapa klaster berdasarkan jarak Euclidean. Proses ini dilakukan dengan:

- Menentukan pusat klaster awal (centroid),
- Menghitung jarak setiap titik ke centroid,
- Memperbarui posisi centroid hingga tidak berubah lagi (konvergen).

### Visualisasi Klaster PCA dan Scatter Plot

Setelah klaster terbentuk, dilakukan:

- Reduksi dimensi menggunakan PCA (Principal Component Analysis) menjadi dua dimensi,
- Visualisasi klaster dalam bentuk scatter plot untuk melihat pemisahan antar klaster secara visual,
- Evaluasi kualitas menggunakan Silhouette Score,

- d. Pembuatan Tabel Profil Klaster untuk menampilkan karakteristik setiap kelompok

### **Profiling Klaster**

Setelah proses klasterisasi dilakukan, setiap klaster dianalisis berdasarkan nilai rata-rata dari fitur-fitur yang digunakan dalam pemodelan maupun fitur pendukung. Tujuan dari interpretasi ini adalah untuk memahami karakteristik unik masing-masing kelompok pelanggan e-commerce.

Analisis dilakukan dengan membuat tabel rata-rata atribut numerik dan kategorikal per klaster, termasuk: Previous Purchases, Purchase Amount (USD), Frequency of Purchases, Age, dan Review Rating. Selain itu, atribut pendukung seperti Gender, Shipping Type, Subscription Status, Discount Applied, dan Promo Code Used juga dianalisis guna memberikan gambaran perilaku dan preferensi konsumen yang lebih mendalam.

Untuk memperkuat pemahaman visual terhadap perbedaan antar klaster, dilakukan visualisasi dalam bentuk bar chart per fitur dan scatter plot hasil PCA (Principal Component Analysis). PCA digunakan untuk mereduksi dimensi data dan menampilkan pemisahan antar klaster dalam ruang dua dimensi, sehingga pola segmentasi dapat diamati secara lebih jelas. Selain itu, dilakukan analisis distribusi jumlah data pada masing-masing klaster untuk menilai keseimbangan segmentasi. Hasil evaluasi ini membantu dalam memahami segmen pelanggan potensial, pelanggan loyal, serta pelanggan yang berisiko churn (berhenti melakukan pembelian)

## **HASIL DAN PEMBAHASAN**


### **Deskripsi Data**

Dataset yang digunakan terdiri dari 3.900 entri pelanggan e-commerce dengan atribut utama seperti Previous Purchases, Purchase Amount (USD), Frequency of Purchases, Age, dan Review Rating serta atribut pendukung seperti Gender, Shipping Type, Subscription Status, Discount Applied, dan Promo Code

Used. Sebelum proses klasterisasi, data dibersihkan dan dilakukan encoding pada atribut kategorikal. Setelah itu, atribut numerik dinormalisasi dengan metode Min-Max Scaling agar seluruh fitur berada pada rentang 1 hingga 2.

### Analisis Korelasi Fitur

Untuk memahami keterkaitan antar variable, dilakukan analisis korelasi menggunakan heatmap. Yang dimana pada gambar akan menunjukan korelasi antar fitur numerik seperti **Age**, **Purchase**, **Amount (USD)**, **Review Rating**, hingga **Frequency of Purchase**



Gambar 2 Korelasi Antar Fitur Menggunakan HeatMap

Beberapa insight penting dari heatmap ini antara lain:

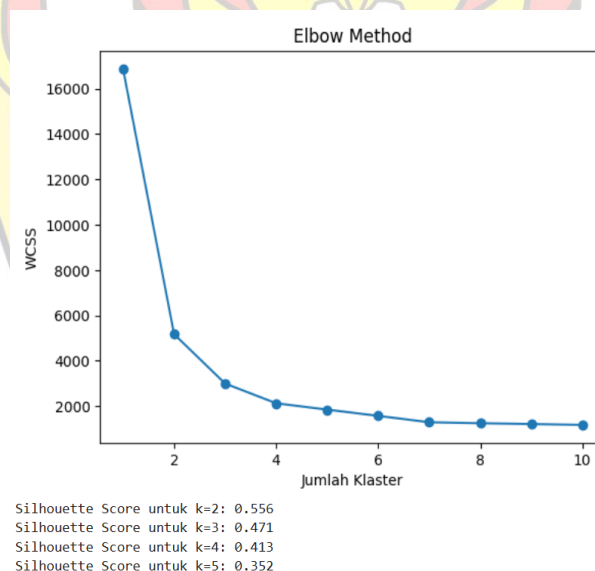
- **Purchase Amount** memiliki korelasi positif dengan **Previous Purchases** dan **Frequency**, menandakan bahwa pelanggan yang lebih sering berbelanja juga memiliki nilai pembelian lebih tinggi.

- **Age** cenderung memiliki korelasi negatif dengan **Frequency of Purchases**, yang menunjukkan bahwa pelanggan lebih muda cenderung berbelanja lebih sering.
- **Review Rating** tidak memiliki korelasi kuat dengan fitur lainnya, menunjukkan bahwa persepsi terhadap produk tidak selalu dipengaruhi oleh nilai pembelian.

Informasi ini membantu dalam menafsirkan hasil klasterisasi dan menyusun strategi pemasaran yang relevan untuk masing-masing segmen pelanggan.

### Penentuan Jumlah Klaster (k)

Penentuan nilai **k** dilakukan dengan metode Elbow. Berdasarkan grafik Elbow Curve yang dihasilkan, terdapat penurunan signifikan pada nilai WCSS hingga  $k = 2$ . Di titik tersebut, kurva mulai mendatar, sehingga  $k = 2$  dipilih sebagai jumlah klaster optimal. Evaluasi menggunakan Silhouette Score menunjukkan nilai tertinggi juga terdapat pada  $k = 2$  dengan skor sebesar 0,556 yang mengindikasikan bahwa klaster cukup terpisah dengan baik.



**Gambar 3. Grafik Elbow Curve untuk Menentukan Jumlah Klaster Optimal (k) Berdasarkan Nilai WCSS**



Untuk memastikan jumlah klaster yang optimal, dilakukan uji coba tambahan dengan nilai  $k=3$  (0,471),  $k=4$  (0,413), dan  $k=5$  (0,352) Namun, hasil menunjukkan Silhouette Score lebih rendah dibanding  $k=2$  (0.556) seperti gambar diatas, dan pemisahan klaster menjadi kurang jelas. Oleh karena itu,  **$k=2$  dipilih sebagai solusi terbaik dari sisi performa dan interpretasi bisnis.**

### Hasil Klasterisasi

Hasil Klasterisasi menunjukan bahwa data terbagi menjadi dua kelompok pelanggan.

Tabel 1 Berikut menampilkan Jumlah dan Presentase pelanggan pada masing – masing Klaster :

Klaster	Jumlah Pelanggan	Persentase (%)
Klaster 1: Pasif / Risiko Churn	1.733	44,4%
Klaster 2: Loyal / Potensial	2.167	55,6%
<b>Total</b>	<b>3.900</b>	<b>100%</b>

**Tabel 1 Jumlah dan Presentase pelanggan per Klaster**

Terlihat bahwa mayoritas pelanggan (55,6%) termasuk kedalam Klaster 2, yang menunjukan potensi loyalitas keterlibatan tinggi. Dibandingkan klaster 1 yang dimana hanya (44,4%), yang cenderung pasif dan berisiko churn.

Untuk memahami lebih dalam perilaku pelanggan dalam setiap klaster, dilakukan analisis statistik deskriptif terhadap sejumlah fitur penting. yang dimana Nilai rata-rata tiap fitur pada masing-masing klaster ditampilkan pada Tabel 2 berikut :

Klaster	Previous Purchase	Purchase Amount (USD)	Frequency of Purchase	Age	Review Rating
1 : Pasif	3.85	464.25	1.38	43.0	3.50
2: Loyal	6.25	1480.68	2.78	35.02	4.37

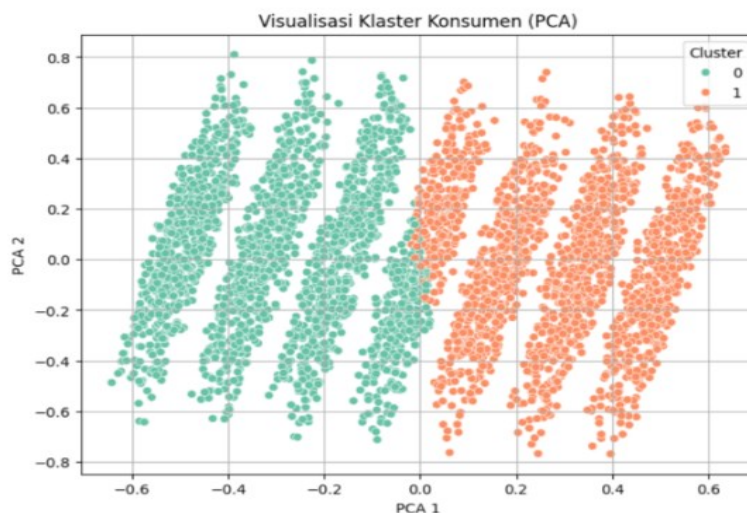
**Tabel 2 Rata-rata Fitur Utama per Klaster**

Dari tabel di atas dapat disimpulkan:

- Klaster 1 didominasi oleh pelanggan dengan frekuensi pembelian rendah dan nilai pembelian yang juga relatif rendah. Usia pelanggan di klaster ini cenderung lebih tua.
- Klaster 2 terdiri dari pelanggan aktif dengan frekuensi dan nominal belanja tinggi serta usia yang lebih muda.

### Visualisasi Klaster

Visualisasi hasil klasterisasi dilakukan dengan PCA, yang mereduksi data menjadi dua dimensi: PCA1 dan PCA2. Scatter plot pada Gambar 3 menunjukkan



**Gambar 4 Scatter Plot Hasil PCA Klasterisasi**

Visualisasi PCA pada Gambar 4 memperlihatkan bahwa kedua klaster terpisah dengan cukup jelas, mendukung validitas hasil klasterisasi secara visual.

### Profiling Klaster

Profil masing-masing klaster dianalisis lebih lanjut dengan atribut tambahan. Ringkasan hasilnya adalah sebagai berikut:

Atribut	Klaster 1:	Klaster 2 :
	Pasif	Loyal
Gender (P=1, L = 0)	0.56	0.45

Subscription Status	0.32	0.82
Discount Applied	0.28	0.65
Promo Code Used	0.30	0.70

Tabel 2 Rata-rata Tambahan per Klaster

Dapat disimpulkan bahwa:

- Pelanggan klaster 2 lebih banyak yang berlangganan, memberikan rating lebih tinggi, dan sering menggunakan diskon maupun promo code.
- Klaster 1 cenderung pasif, tidak berlangganan, dan memiliki aktivitas pembelian serta interaksi yang rendah.

### Interpretasi dan Implikasi Bisnis

Hasil klasterisasi memberikan insight penting sebagai berikut:

- Klaster 2 merepresentasikan pelanggan aktif dan loyal, yang potensial untuk program loyalitas, eksklusif, atau upselling.
- Klaster 1 adalah segmen pelanggan dengan potensi churn tinggi. Strategi re-engagement seperti penawaran personalisasi, reminder, atau diskon mungkin diperlukan.

Dengan informasi ini, perusahaan e-commerce dapat menyusun strategi pemasaran yang lebih personal dan efisien berbasis perilaku masing-masing segmen.

### SIMPULAN

Berdasarkan hasil penelitian mengenai penerapan algoritma K-Means dalam menganalisis tren konsumen e-commerce, dapat disimpulkan hal-hal berikut:

- Proses Klasterisasi Berhasil Mengelompokkan Pelanggan ke dalam Dua Klaster Utama  
Dengan menggunakan atribut utama seperti jumlah transaksi sebelumnya, nominal pembelian, frekuensi pembelian, dan usia, serta ditunjang oleh

fitur-fitur tambahan, algoritma K-Means berhasil mengelompokkan pelanggan menjadi dua klaster yang cukup terpisah. Pemilihan jumlah klaster ( $k = 2$ ) didasarkan pada hasil Elbow Method dan Silhouette Score yang menunjukkan performa optimal.

2. Karakteristik Tiap Klaster Menunjukkan Pola Perilaku yang Berbeda
  - a. Klaster 1 mencerminkan segmen pelanggan pasif, dengan frekuensi dan nominal belanja rendah, serta rating ulasan yang lebih rendah. Mayoritas pelanggan dalam klaster ini tidak berlangganan dan jarang menggunakan diskon atau promo.
  - b. Klaster 2 merepresentasikan segmen pelanggan aktif, loyal, dan berkontribusi tinggi terhadap penjualan. Mereka lebih sering bertransaksi, memberikan rating tinggi, dan memanfaatkan diskon serta promo.
3. Visualisasi dan Evaluasi Mendukung Validitas Segmentasi  
Visualisasi hasil klasterisasi menggunakan PCA menunjukkan pemisahan klaster yang jelas dalam dua dimensi. Evaluasi Silhouette Score memberikan nilai positif yang menunjukkan koherensi dalam masing-masing klaster.
4. Penerapan K-Means Efektif untuk Segmentasi dan Pengambilan Keputusan Pemasaran  
Penelitian ini menunjukkan bahwa metode K-Means dapat digunakan sebagai alat bantu strategis dalam proses segmentasi pelanggan e-commerce. Dengan memahami karakteristik tiap klaster, perusahaan dapat menyusun pendekatan pemasaran yang lebih terarah, meningkatkan retensi pelanggan, dan mengoptimalkan kampanye promosi.

## DAFTAR PUSTAKA

- Amin, F., Anggraeni, D. S., & Aini, Q. (2022). Penerapan Metode K-Means dalam Penjualan Produk Souq.Com. *Applied Information System and Management (AISM)*, 5(1), 7–14. <https://doi.org/10.15408/aism.v5i1.22534>
- Fauziah, R., & Purnamasari, A. I. (2023). Implementasi Algoritma K-Means pada Kasus Kekerasan Anak dan Perempuan Berdasarkan Usia. *Hello World*



Jurnal Ilmu Komputer, 2(1), 34-41.  
<https://doi.org/10.56211/helloworld.v2i1.232>

Hendrastuty, N. (2024). Penerapan Data Mining Menggunakan Algoritma K-Means Clustering Dalam Evaluasi Hasil Pembelajaran Siswa. Jurnal Ilmiah Informatika Dan Ilmu Komputer (JIMA-ILKOM), 3(1), 46-56.  
<https://doi.org/10.58602/jima-ilkom.v3i1.26>

Kusnaldi, M. R., Gulo, T., & Aripin, S. (2022). Penerapan Normalisasi Data Dalam Mengelompokkan Data Mahasiswa Dengan Menggunakan Metode K-Means Untuk Menentukan Prioritas Bantuan Uang Kuliah Tunggal. Journal of Computer System and Informatics (JoSYC), 3(4), 330-338.  
<https://doi.org/10.47065/josyc.v3i4.2112>

Maori, N. A., & Evanita, E. (2023). Metode Elbow dalam Optimasi Jumlah Cluster pada K-Means Clustering. Simetris: Jurnal Teknik Mesin, Elektro Dan Ilmu Komputer, 14(2), 277-288. <https://doi.org/10.24176/simet.v14i2.9630>

Nugroho, M. R., Hendrawan, I. E., & Purwantoro, P. P. (2022). Penerapan Algoritma K-Means Untuk Klasterisasi Data Obat Pada Rumah Sakit ASRI. Nuansa Informatika, 16(1), 125-133. <https://doi.org/10.25134/nuansa.v16i1.5294>

Prasetyo, R. B. (2023). Pengaruh E-Commerce dalam Dunia Bisnis. JMEB Jurnal Manajemen Ekonomi & Bisnis, 1(01), 1-11.  
<https://doi.org/10.59561/jmeh.v1i01.92>

Sulaiman Asyuti, Ahmad Aji Setyawan. (2022). Data Mining Dalam Penggunaan Presensi Karyawan Denga Cluster Means. Jurnal Ilmiah Sains Teknologi Dan Informasi, 1(1), 1-10. <https://doi.org/10.59024/jiti.v1i1.6>

Faujia, R. A., Setianingsih, E. S., & Pratiwi, H. (2022). Analisis Klaster K-Means Dan Agglomerative Nesting Pada Indikator Stunting Balita Di Indonesia. Seminar Nasional Official Statistics, 2022(1), 1249-1258.  
<https://doi.org/10.34123/semnasoffstat.v2022i1.1511>

Homepage, J., Dzaki Salman, M., Rizki Pratama, N., Nakhlah Farid, M. A., Agung Setiawan, A., Zalianti, fenisya, & Bil Huda, I. (2025). MALCOM: Indonesian Journal of Machine Learning and Computer Science Comparison of K-Means and K-Medoids Clustering Algorithm Performance in Grouping Schools in Riau Province Based on Availability of Facilities and Infrastructure Perbandingan Kinerja Algor. 5(July), 797-806.

Jabnabillah, F., Aswin, A., & Fahlevi, M. R. (2023). Efektivitas Situs Web Pemerintah Sebagai Sumber Data Sekunder Bahan Ajar Perkuliahan Statistika. Sustainable Jurnal Kajian Mutu Pendidikan, 6(1), 59-70.  
<https://doi.org/10.32923/kjmp.v6i1.3373>

- Joshua, B. (2017). No 主観的健康感を中心とした在宅高齢者における 健康関連指標に関する共分散構造分析Title. 3(1), 111.
- Mardi, Y. (2017). Data Mining : Klasifikasi Menggunakan Algoritma C4.5. Edik Informatika, 2(2), 213–219. <https://doi.org/10.22202/ei.2016.v2i2.1465>
- Novi Rudiyaniti, Mela Aprillia, Fanesha Rahma Fitri, & Pupung Purnamasari. (2025). Pengaruh Strategi Pemasaran Terhadap Penambahan Segmen Pasar Baru Di Restoran Kopi Express. JISOSEPOL: Jurnal Ilmu Sosial Ekonomi Dan Politik, 3(1), 132–138. <https://doi.org/10.61787/zk322946>
- Ramadhani, J., Safitra Anugraha, Y., Fauzan, A., & Efrizoni, L. (2024). Perbandingan Algoritma K-Means Clustering Dan K-Medoids Dalam Mengelompokkan Tingkat Kemiskinan Di Provinsi Riau. Jurnal Jaringan Sistem Informasi Robotik (Jsr), 8(1), 114–125. <https://ojsamik.amikmitragama.ac.id/index.php/js/article/view/393>
- Ranjan, G. S. K., Kumar Verma, A., & Radhika, S. (2019). K-Nearest Neighbors and Grid Search CV Based Real Time Fault Monitoring System for Industries. 2019 IEEE 5th International Conference for Convergence in Technology, I2CT 2019, 4(January), 273–281. <https://doi.org/10.1109/I2CT45611.2019.9033691>
- Ratnasari, S. L., Buulolo, M., & Nasrul, H. W. (2020). Analisis Karakteristik Individu, Lingkungan Kerja, Iklim Organisasi, Motivasi, Dan Kompensasi Terhadap Kinerja Karyawan. Jurnal Manajemen & Organisasi Review (Manor), 2(1), 15–25. <https://doi.org/10.47354/mjo.v2i1.175>
- Setiawan, D. (2018). Impact of Information Technology Development and Communication on Culture. Jurnal SIMBOLIKA Research and Learning in Communication Study, 4(1), 62–72. <http://ojs.uma.ac.id/index.php/symbolika>
- Takdirillah, R. (2020). Penerapan Data Mining Menggunakan Algoritma Apriori Terhadap Data Transaksi Sebagai Pendukung Informasi Strategi Penjualan. Edumatic : Jurnal Pendidikan Informatika, 4(1), 37–46. <https://doi.org/10.29408/edumatic.v4i1.2081>