

ANALISIS KLASTERISASI PRODUK RETAIL MENGGUNAKAN ALGORITMA K-MEANS SEBAGAI PENDUKUNG KEPUTUSAN MANAGERIAL

Nabilah¹, Denni Pratama².

Program Studi Komputerisasi Akuntansi¹
Program Studi Manajemen Informatika²

STMIK IKMI Cirebon
<https://ikmi.ac.id/page/18/?lang=de>
nbillaan@gmail.com

(*) Corresponding Author : nbillaan@gmail.com

Published : 30 Maret 2026

Abstract—Effective management of sales data is a critical factor in supporting managerial decision-making, particularly in product and inventory management strategies. This study aims to apply the K-Means algorithm to cluster products based on sales performance in a retail store. The dataset consists of 3,202 transaction records with Sales Qty and Sales Net as the primary attributes. The analysis was conducted using Altair RapidMiner Studio software through Z-Score normalization stages and quality evaluation using the Davies-Bouldin Index (DBI). The results indicate that the optimal grouping is achieved with three clusters ($k=3$), yielding a DBI value of 0.828. Cluster 2 represents products with high performance (High Performer), Cluster 0 represents stable performance (Medium Performer), and Cluster 1 represents products with slow turnover (Low Performer). These findings provide a foundation for management to optimize stock, design personalized promotional strategies, and improve the efficiency of resource allocation.

Keywords: K-Means, Clustering, Sales Data, RapidMiner, Managerial Decision Making.

Abstrak—Pengelolaan data penjualan yang efektif merupakan faktor penting dalam mendukung pengambilan keputusan manajerial, khususnya dalam strategi pengelolaan produk dan persediaan. Penelitian ini bertujuan menerapkan algoritma K-Means untuk melakukan klusterisasi produk berdasarkan kinerja penjualan pada toko retail. Data yang digunakan berjumlah 3.201 catatan transaksi dengan atribut utama Sales Qty dan Sales Net. Proses analisis dilakukan menggunakan perangkat lunak Altair RapidMiner Studio melalui tahapan normalisasi Z-Score dan evaluasi kualitas menggunakan Davies-Bouldin Index (DBI). Hasil penelitian menunjukkan bahwa pengelompokan optimal berada pada jumlah tiga kluster ($k=3$) dengan nilai DBI sebesar 0,828. Kluster 2 mewakili produk dengan kinerja tinggi (High Performer), Kluster 0 untuk kinerja stabil (Medium Performer), dan Kluster 1 untuk produk dengan perputaran lambat (Low Performer). Hasil ini memberikan dasar bagi manajemen dalam mengoptimalkan stok, merancang strategi promosi yang personal, dan meningkatkan efisiensi alokasi sumber daya.

Kata Kunci: K-Means, Klusterisasi, Data Penjualan, RapidMiner, Pengambilan Keputusan Manajerial.

INTRODUCTION

Perkembangan teknologi digital pada era Revolusi Industri 4.0 telah mendorong perusahaan untuk mengelola data sebagai aset strategis dalam mendukung keberlanjutan bisnis. Di sektor ritel, data transaksi penjualan tidak lagi hanya berfungsi sebagai arsip historis, melainkan menjadi sumber informasi penting untuk memahami perilaku konsumen, mengevaluasi kinerja produk, serta merumuskan strategi bisnis

yang kompetitif. Pemanfaatan analitik data penjualan memungkinkan organisasi menggali pola konsumsi, mengidentifikasi tren pasar, dan menyusun keputusan manajerial secara lebih akurat dan berbasis fakta [1], [2].

Namun demikian, banyak perusahaan ritel masih menghadapi kendala dalam mengolah data transaksi berskala besar atau *big data* menjadi informasi yang bernilai guna. Metode analisis konvensional sering kali tidak mampu menangkap pola tersembunyi dalam data

penjualan, sehingga berpotensi menyebabkan ketidaktepatan dalam pengelolaan persediaan dan strategi pemasaran[3], [4]. Kondisi ini dapat mengakibatkan inefisiensi alokasi sumber daya serta menurunnya daya saing perusahaan di tengah persaingan pasar yang semakin ketat [5]

Pengambilan keputusan manajerial yang efektif menuntut adanya pemahaman mendalam terhadap performa setiap produk, khususnya dalam mengidentifikasi produk dengan kontribusi pendapatan tinggi dan produk yang mengalami pergerakan lambat (*slow-moving*)[6], [7]. Tanpa adanya klasifikasi produk yang sistematis, manajemen cenderung menerapkan kebijakan yang seragam pada seluruh produk, padahal setiap produk memiliki karakteristik penjualan yang berbeda[8]. Oleh karena itu, diperlukan pendekatan analitis yang mampu mengelompokkan produk secara objektif berdasarkan data historis penjualan [6].

Salah satu teknik yang banyak digunakan dalam data mining untuk pengenalan pola adalah *clustering*. *Clustering* merupakan metode unsupervised learning yang bertujuan mengelompokkan data ke dalam beberapa kluster berdasarkan tingkat kemiripan karakteristiknya, sehingga data dalam satu kluster memiliki kesamaan tinggi dan berbeda secara signifikan dengan kluster lainnya. Algoritma K-Means menjadi salah satu metode *clustering* yang paling populer karena kesederhanaan konsep, efisiensi komputasi, serta kemampuannya dalam menangani dataset berukuran besar [9], [10].

Berbagai penelitian terdahulu telah membuktikan efektivitas algoritma K-Means dalam analisis data penjualan ritel. Hidayat et al. menunjukkan bahwa penerapan K-Means mampu meningkatkan akurasi pengelompokan produk dan mendukung pengendalian persediaan secara lebih responsif [7]. Studi lain juga menegaskan bahwa segmentasi produk berbasis K-Means dapat membantu perusahaan merancang strategi pemasaran yang lebih terarah dan efisien[11].

Selain itu, integrasi analitik data dan pengambilan keputusan manajerial berbasis data terbukti mampu meningkatkan kinerja operasional perusahaan[3], [4]. Pemanfaatan *data mining* memungkinkan organisasi mentransformasikan data historis menjadi wawasan strategis yang aplikatif, sehingga keputusan yang diambil tidak lagi bergantung pada intuisi semata, melainkan pada bukti empiris yang terukur[8].

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk

mengimplementasikan algoritma K-Means dalam mengelompokkan produk berdasarkan data transaksi penjualan menggunakan platform Altair RapidMiner Studio. Pemanfaatan K-Means dinilai efektif dalam analisis penjualan karena mampu mengelompokkan produk secara objektif berdasarkan kemiripan karakteristik data kuantitatif [10], [12].

Data yang dianalisis terdiri dari 3.202 catatan transaksi dengan variabel utama *Sales Quantity* dan *Sales Net*, yang sering digunakan sebagai indikator kinerja produk dalam analisis ritel[9]. Untuk memastikan kualitas hasil klusterisasi, penelitian ini menggunakan *Davies-Bouldin Index (DBI)* sebagai metrik evaluasi, karena DBI mampu mengukur tingkat homogenitas intra-kluster dan heterogenitas antar-kluster secara matematis[13].

Hasil pengelompokan produk yang diperoleh diharapkan dapat memberikan rekomendasi strategis bagi manajemen dalam mengoptimalkan pengelolaan stok serta merancang strategi promosi yang lebih tepat sasaran dan berbasis data [14], [15].

MATERIALS AND METHODS

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimental *Knowledge Discovery in Databases (KDD)*. Pendekatan KDD digunakan karena mampu mengintegrasikan proses pengolahan data secara sistematis mulai dari pemilihan data hingga ekstraksi pengetahuan yang bermanfaat bagi pengambilan keputusan manajerial[16]. Fokus utama penelitian ini adalah penerapan teknik Data Mining untuk mengekstraksi informasi bernilai dari basis data transaksi penjualan berskala besar guna menghasilkan pengetahuan baru yang dapat dimanfaatkan oleh pihak manajemen [17].

Tahapan utama dalam proses klusterisasi menggunakan RapidMiner adalah sebagai berikut:

Read Excel

Tahap awal dimulai dengan membaca dataset penjualan produk menggunakan operator *Read Excel*. Operator ini berfungsi untuk mengimpor data penjualan dari file Microsoft Excel ke dalam lingkungan RapidMiner. Pada tahap ini dilakukan pengecekan struktur data, penamaan atribut, serta tipe data agar sesuai dengan kebutuhan analisis. Dataset yang berhasil dimuat kemudian menjadi dasar bagi seluruh proses klusterisasi [18].

Select Attributes

Setelah data berhasil dimuat, dilakukan pemilihan atribut menggunakan operator *Select Attributes*. Tahap ini bertujuan untuk memilih atribut numerik yang relevan dengan kinerja penjualan produk. Atribut yang digunakan dalam penelitian ini adalah *Sales Quantity (Sales Qty)* dan *Sales Net*, karena kedua variabel tersebut merepresentasikan volume penjualan dan kontribusi pendapatan produk secara langsung. Pemilihan atribut yang tepat sangat penting untuk meningkatkan kualitas hasil klasterisasi [9], [19].

Set Role

Operator *Set Role* digunakan untuk menetapkan atribut kode produk sebagai atribut identitas (*id*). Atribut ini tidak dilibatkan dalam perhitungan jarak pada algoritma K-Means, namun berfungsi untuk mengidentifikasi setiap produk pada klaster yang terbentuk. Penetapan peran atribut ini memudahkan proses interpretasi hasil klasterisasi dalam konteks manajerial[20].

Normalize

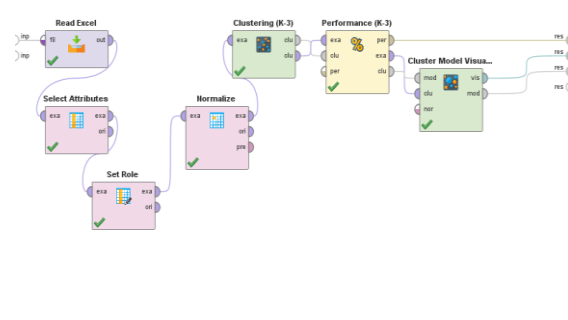
Tahap normalisasi dilakukan menggunakan operator *Normalize* untuk menyamakan skala nilai antar atribut. Normalisasi diperlukan karena perbedaan rentang nilai antar variabel, seperti *Sales Net* yang memiliki skala jauh lebih besar dibandingkan *Sales Qty*, dapat menyebabkan bias dalam perhitungan jarak. Proses ini bertujuan agar setiap atribut memiliki kontribusi yang seimbang dalam pembentukan klaster [13], [21].

K-Means

Tahap utama dalam penelitian ini adalah penerapan algoritma K-Means untuk mengelompokkan produk berdasarkan kemiripan pola penjualannya. Algoritma K-Means bekerja dengan menghitung jarak antara setiap data dan pusat klaster (*centroid*), kemudian mengelompokkan data ke dalam klaster dengan jarak terdekat. Proses ini dilakukan secara iteratif hingga posisi *centroid* mencapai kondisi stabil dan tidak mengalami perubahan signifikan. K-Means dipilih karena efisiensi komputasi serta kemampuannya dalam menangani dataset berukuran besar secara efektif [10], [14].

Untuk memperjelas tahapan proses klasterisasi yang dilakukan dalam penelitian ini, alur proses penerapan algoritma K-Means menggunakan

perangkat lunak Altair RapidMiner Studio ditunjukkan pada Gambar 1.



Gambar 1 Alur Proses Klasterisasi Menggunakan Algoritma K-Means pada Altair RapidMiner Studio

Sebagaimana diilustrasikan pada Gambar 1 proses komputasi diawali dengan operator *Read Excel* untuk memuat 3.201 data transaksi. Atribut kemudian difilter menggunakan *Select Attributes* untuk mengisolasi variabel *Sales Quantity* dan *Sales Net*. Tahap normalisasi dilakukan secara otomatis sebelum data masuk ke mesin K-Means, dan diakhiri dengan operator *Performance* untuk menghasilkan nilai evaluasi DBI.

Sumber Data dan Spesifikasi Atribut

Objek penelitian ini menggunakan data sekunder yang berasal dari catatan transaksi penjualan retail. Total populasi data yang diolah berjumlah 3.201 catatan transaksi. Dalam tahap *Feature Selection*, penelitian ini menetapkan dua atribut kunci yang paling representatif untuk mengukur kinerja produk, yaitu:

1. Sales Quantity (*X*)

Variabel ini menunjukkan volume fisik barang yang terjual dan merepresentasikan tingkat permintaan pasar terhadap suatu produk. Atribut ini umum digunakan dalam analisis penjualan untuk mengidentifikasi produk dengan pergerakan cepat maupun lambat[12].

2. Sales Net (*Y*)

Variabel ini merupakan indikator finansial yang menunjukkan nilai total pendapatan bersih dari penjualan produk, sehingga mencerminkan kontribusi moneter produk terhadap perusahaan. Sales Net sering digunakan sebagai tolok ukur utama dalam evaluasi profitabilitas produk [14], [15].

Tahap Pra-pemrosesan

Normalisasi Z-Score salah satu tantangan utama dalam pengolahan data penjualan adalah perbedaan skala nilai antar atribut. Variabel *Sales Net* umumnya memiliki nilai dalam satuan jutaan rupiah, sedangkan *Sales Quantity* berada pada kisaran puluhan unit. Apabila data dengan skala berbeda ini langsung diproses, maka atribut dengan nilai lebih besar akan mendominasi perhitungan jarak dan menghasilkan kluster yang bias. Oleh karena itu, dilakukan proses normalisasi Z-Score untuk menyamakan skala data sehingga setiap atribut memiliki kontribusi yang seimbang dalam proses klusterisasi [13], [21].

Algoritma K-Means dan Euclidean Distance

Algoritma K-Means digunakan untuk mengelompokkan produk ke dalam k=3 kelompok berdasarkan kemiripan karakteristik. Proses ini melibatkan perhitungan jarak antara titik data dengan pusat kelompok (*centroid*) menggunakan metode Euclidean Distance, dengan rumus:

$$d(p_i, c_j) = \sqrt{\sum_{k=1}^n (p_{ik} - c_{jk})^2}$$

Makna Komponen

1. $d(p_i, c_j)$ melambangkan jarak (*distance*) antara titik data
2. ke-i p_i dengan centroid kelompok ke-j c_j . Semakin kecil nilai ini, semakin besar kemiripan antara data tersebut dengan kelompoknya.
3. Akar Kuadrat Berfungsi untuk mengembalikan satuan jarak ke dimensi aslinya setelah sebelumnya dikuadratkan, sesuai dengan prinsip teorema Pythagoras.
4. Sigma merupakan simbol penjumlahan. Artinya, menjumlahkan selisih nilai pada setiap dimensi atau fitur, mulai dari dimensi pertama $k = 1$ hingga dimensi terakhir (n).
5. $(p_{ik} - c_{jk})$ menghitung selisih nilai antara data dan *centroid* pada dimensi yang sama.
6. Pangkat dua berfungsi untuk menghilangkan nilai negatif (karena jarak tidak pernah

negatif) dan memberikan bobot lebih pada perbedaan yang besar.

Proses iterasi K-Means dilakukan secara otomatis oleh RapidMiner Studio hingga mencapai kondisi konvergen, yaitu ketika posisi centroid tidak lagi mengalami perubahan yang signifikan dan setiap produk telah terpetakan ke dalam kluster yang paling optimal [18].

Evaluasi Klusterisasi

Untuk menguji apakah jumlah kluster yang dipilih ($k = 3$) telah menghasilkan pengelompokan yang optimal dan berkualitas, penelitian ini menggunakan *Davies-Bouldin Index (DBI)* sebagai metrik evaluasi kluster. DBI banyak digunakan dalam penelitian klusterisasi karena mampu menilai kualitas kluster secara objektif tanpa memerlukan data berlabel (*unsupervised evaluation*) [13].

Davies-Bouldin Index mengevaluasi kualitas kluster berdasarkan dua aspek utama, yaitu:

1. Separation

Separation mengukur jarak antar satu kluster dengan kluster lainnya. Semakin besar jarak antar kluster, maka semakin baik tingkat pemisahan antar kelompok data, yang menunjukkan bahwa setiap kluster memiliki karakteristik yang berbeda secara signifikan [21].

2. Compactness

Compactness mengukur tingkat kepadatan data di dalam satu kluster. Nilai compactness yang rendah menunjukkan bahwa anggota kluster memiliki tingkat kemiripan yang tinggi dan tersebar secara minimal dari pusat kluster (*centroid*) [10].

3. Nilai Davies-Bouldin Index yang kecil (mendekati nol) mengindikasikan bahwa hasil klusterisasi memiliki tingkat separation yang baik dan compactness yang optimal, sehingga kluster yang dihasilkan dapat dikatakan valid secara statistik dan layak digunakan sebagai dasar pengambilan keputusan manajerial [14], [15].

RESULTS AND DISCUSSION

Bagian ini menguraikan temuan dari eksperimen data mining menggunakan algoritma K-Means terhadap 3.201 catatan transaksi.

Analisis difokuskan pada validitas pengelompokan secara statistik dan maknanya bagi strategi bisnis perusahaan.

Analisis Pra-pemrosesan Data

Sebelum proses klasterisasi dilakukan, data melalui tahap normalisasi Z-Score. Langkah ini sangat krusial karena terdapat perbedaan skala yang signifikan antara atribut *Sales Quantity* (dalam satuan unit) dan *Sales Net* (dalam nilai rupiah). Tanpa normalisasi, atribut *Sales Net* yang memiliki angka nominal jutaan akan mendominasi perhitungan jarak *Euclidean*, sehingga hasil klasterisasi menjadi tidak akurat. Setelah normalisasi, kedua variabel berada pada skala yang sebanding, memungkinkan algoritma K-Means mengidentifikasi pola berdasarkan proporsi kinerja yang adil.

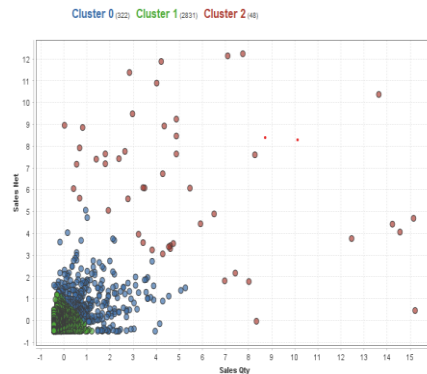
Hasil Klasterisasi Produk

Berdasarkan eksperimen menggunakan Altair RapidMiner Studio dengan parameter $k=3$, sistem berhasil membagi 3.201 data produk ke dalam tiga kelompok utama. Distribusi data dan karakteristik masing-masing klaster dapat dilihat pada tabel berikut:

Tabel 1. Karakteristik Hasil Klasterisasi K-Means

Klaster	Kategori Performa	Jumlah Produk	Persentase
Cluster 2	Tinggi (High)	48	1.50%
Cluster 0	Sedang (Medium)	322	10.10%
Cluster 1	Rendah (Low)	2,831	88.40%
Total		3,201	100%

Setiap klaster menunjukkan tingkat homogenitas yang tinggi di dalam kelompok serta heterogenitas yang jelas antar kelompok, sehingga mencerminkan perbedaan performa penjualan produk secara objektif. Visualisasi hasil klasterisasi produk ditunjukkan pada Gambar 2 dalam bentuk scatter plot, yang menggambarkan sebaran produk berdasarkan atribut penjualan dan pembentukan klaster yang dihasilkan oleh algoritma K-Means.



Gambar 2 Visualisasi Sebaran Klaster (Scatter Plot) dari RapidMiner

Gambar 2 menunjukkan bahwa Klaster 2 menempati area terluar dengan nilai koordinat tertinggi, menandakan produk-produk tersebut adalah penyumbang utama pendapatan. Sebaliknya, Klaster 1 membentuk kepadatan di area koordinat terendah, yang mencerminkan mayoritas produk yang perputarannya lambat.

Evaluasi Model Menggunakan *Davies-Bouldin Index (DBI)*

Validitas dari pengelompokan ini diuji menggunakan metrik *Davies-Bouldin Index (DBI)*. Hasil perhitungan menunjukkan nilai DBI sebesar 0,828.

Davies Bouldin

Davies Bouldin: -0.828

Gambar 3 Hasil Evaluasi *Davies-Bouldin Index (DBI)*

Dalam konteks algoritma K-Means, nilai DBI yang kurang dari 1 (satu) menunjukkan bahwa model memiliki kualitas yang baik. Nilai 0,828 merepresentasikan bahwa setiap klaster memiliki tingkat homogenitas internal yang kuat (anggota dalam satu klaster mirip satu sama lain) dan separasi eksternal yang jelas (perbedaan antar klaster terlihat nyata). Dengan demikian, pengelompokan ini sah secara ilmiah untuk dijadikan acuan pengambilan keputusan.

Pembahasan Strategi Manajerial

Berdasarkan hasil analisis di atas, penelitian ini merekomendasikan tiga skema keputusan manajerial yang berbeda:

1. Prioritas Stok (Klaster 2)

Produk dalam klaster ini merupakan penggerak utama bisnis (*Cash Cows*). Manajemen harus menerapkan kebijakan *Safety Stock* yang ketat dan melakukan pemantauan stok secara harian guna menghindari kehilangan potensi penjualan (*lost sales*).

2. Penjualan (Klaster 0)

Produk di klaster ini memiliki performa stabil. Strategi yang disarankan adalah promosi melalui metode *bundling* dengan produk di klaster 2 atau pemberian *reward poin* lebih untuk mendorong produk ini menjadi kategori *High Performer*.

3. Efisiensi dan Rasionalisasi (Klaster 1)

Mengingat jumlah anggota di klaster ini biasanya cukup banyak namun kontribusinya rendah, manajemen perlu melakukan *Inventory Clearance* atau diskon besar-besaran untuk mengosongkan gudang dan menghindari biaya penyimpanan yang membengkak pada barang yang tidak produktif.

CONCLUSION

Kesimpulan

Berdasarkan hasil penelitian dan pembahasan mengenai implementasi algoritma K-Means untuk pengelompokan produk pada data penjualan, dapat ditarik beberapa kesimpulan utama sebagai berikut:

1. Algoritma K-Means telah berhasil diimplementasikan menggunakan *Altair RapidMiner Studio* untuk mengelompokkan 3.202 data transaksi ke dalam tiga klaster ($k=3$) yang mewakili tingkatan performa produk: *High Performer* (Klaster 2), *Medium Performer* (Klaster 0), dan *Low Performer* (Klaster 1).
2. Pengujian validitas menggunakan *Davies-Bouldin Index* (DBI) menghasilkan nilai sebesar 0,828. Nilai yang berada di bawah angka 1 ini menunjukkan bahwa model klasterisasi yang terbentuk memiliki kualitas yang baik, dengan pemisahan antar-kelompok yang jelas dan kepadatan anggota yang optimal.

3. Hasil klasterisasi ini memberikan kontribusi nyata bagi pengambilan keputusan manajerial. Pihak manajemen kini memiliki basis data yang objektif untuk menentukan prioritas stok pada produk unggulan, merancang promosi bundling pada produk menengah, serta melakukan strategi efisiensi atau pembersihan stok pada produk yang masuk kategori *slow-moving*.

Saran

Untuk pengembangan penelitian maupun implementasi praktis di masa mendatang, penulis menyarankan beberapa hal berikut:

1. Pengembangan Variabel

Penelitian selanjutnya diharapkan dapat menambahkan variabel lain seperti profitabilitas (keuntungan bersih per produk), tingkat retur barang, atau dimensi waktu (*seasonal*) agar profil klaster yang dihasilkan menjadi lebih komprehensif.

2. Perbandingan Algoritma

Disarankan untuk melakukan studi komparasi menggunakan algoritma pengelompokan lain seperti *K-Medoids* atau *Density-Based Spatial Clustering of Applications with Noise (DBSCAN)* untuk melihat metode mana yang paling stabil dalam menangani data *outlier* pada penjualan retail.

3. Integrasi Sistem

Bagi pihak perusahaan, disarankan untuk mengintegrasikan model K-Means ini ke dalam sistem informasi akuntansi atau *Point of Sales* (POS) yang sudah ada, sehingga analisis performa produk dapat dilakukan secara otomatis dan *real-time* setiap akhir periode laporan.

REFERENCE

- [1] R. P. Ashari, A. Rosmaniar, and A. I. Futuwah, "Performa Digital Marketing Pada Tingkat Konversi Penjualan Dan Tingkat Pelanggan Kembali," *Improvement Jurnal Manajemen Dan Bisnis*, vol. 4, no. 1, pp. 99–108, 2024, doi: 10.30651/imp.v4i1.24348.

- [2] R. N. Mukarim, D. F. Subagja, D. E. Basuki, and R. A. Apriani, "Improving Marketing Strategies Using a Clustering and AR-MBA Methods at Indomaret Kaliurang," *Jurnal Teknik Industri Jurnal Hasil Penelitian Dan Karya Ilmiah Dalam Bidang Teknik Industri*, vol. 10, no. 1, p. 42, 2024, doi: 10.24014/jti.v10i1.29288.
- [3] N. S. Abdel Megeid, "The Role of Big Data Analytics in Supply Chain '3Fs': Financial Reporting, Financial Decision Making and Financial Performance 'An Applied Study,'" *□□□□□□□□ □□□□□*, vol. 26, no. 2, pp. 207–268, Jul. 2022, doi: 10.21608/atasu.2022.259858.
- [4] A. Ilmudeen, "Big data analytics capability and organizational performance measures: The mediating role of business intelligence infrastructure," *Business Information Review*, vol. 38, no. 4, pp. 183–192, Dec. 2021, doi: 10.1177/02663821211055321.
- [5] I. F. Ashari, R. Banjarnahor, D. R. Farida, S. P. Aisyah, A. P. Dewi, and N. Humaya, "Application of Data Mining With the K-Means Clustering Method and Davies Bouldin Index for Grouping IMDB Movies," *Journal of Applied Informatics and Computing*, vol. 6, no. 1, pp. 07–15, 2022, doi: 10.30871/jaic.v6i1.3485.
- [6] N. P. Gantara and I. Ali, "PENERAPAN METODE K-MEANS CLUSTERING PADA PENJUALAN BARANG DI SPORTS STATION," *E-Link: Jurnal Teknik Elektro dan Informatika*, vol. 18, no. 1, p. 28, May 2023, doi: 10.30587/e-link.v18i1.5339.
- [7] I. S. Hidayat, S. Defit, and G. W. Nurcahyo, "Simulasi Dalam Optimalisasi Pengadaan Barang Menggunakan Metode K-Mean Clustering," *Jurnal Sistim Informasi Dan Teknologi*, pp. 279–284, 2021, doi: 10.37034/jsisfotek.v3i4.200.
- [8] I. Perdana and U. S. Putro, "Applying an Analytical Hierarchy Process for Strategic Decision-Making of Business Solution to Address Sales Decline in SMEs," *Jurnal Manajemen Bisnis*, vol. 11, no. 2, pp. 2006–2022, 2024, doi: 10.33096/jmb.v11i2.990.
- [9] Y. Primawati, I. Verdian, and G. W. Nurcahyo, "K- Means Clustering on Based Classification Method of Sales Agent," *Journal of Computer Scine and Information Technology*, pp. 1–6, Jun. 2021, doi: 10.35134/jcsitech.v7i2.1.
- [10] I. Ramadhaniati, "PRODUCT CLUSTERING USING K-MEANS METHOD IN CV. JAYA ABADI," *Jurnal TAM (Technology Acceptance Model)*, vol. 14, no. 1, p. 91, Jul. 2023, doi: 10.56327/jurnaltam.v14i1.1418.
- [11] T. T. Alifa, R. Astuti, and F. M. Basysyar, "Implementasi Data Mining Menggunakan Algoritma K- Means Clustering Dalam Analisis Penjualan Produk," *Jati (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 1, pp. 602–607, 2024, doi: 10.36040/jati.v8i1.8340.
- [12] D. B. Santoso, "Analisis Segmentasi Penjualan Pompa Air Menggunakan Algoritma K-Means Segmentation Analysis of Water Pump Sales Using K-Means Algorithm," *Jubikom*, vol. 4, no. 2, pp. 83–89, 2024, doi: 10.33751/jubikom.v4i2.10696.
- [13] C. A. Sugianto and T. P. O. R. Bokings, "K-Means Algorithm For Clustering Poverty Data in Bangka Belitung Island Province," *Journal of Computer Networks, Architecture, and High-Performance Computing*, vol. 3, no. 1, pp. 58–67, Feb. 2021, doi: 10.47709/cnahpc.v3i1.934.
- [14] W. N. Purba and R. Hartanto, "PERBANDINGAN PENERAPAN ALGORITMA K-MEANS DAN FUZZY C-MEANS DALAM ANALISIS CLUSTERING TERHADAP PERGERAKAN HARGA HISTORIS SAHAM BANK RAKYAT INDONESIA," *Jurnal Teknik Informasi dan Komputer (Tekinkom)*, vol. 7, no. 2, p. 865, Dec. 2024, doi: 10.37600/tekinkom.v7i2.1214.
- [15] I. P. Ica, Martanto, Arif Rinaldi Dikananda, and Dede Rohman, "Use of K-Means Algorithm in Model Improvement Production Data Grouping for Determination Convection Production Strategy," *Journal of Artificial Intelligence and Engineering Applications (JAIEA)*, vol. 4, no. 2, pp. 916–926, Feb. 2025, doi: 10.59934/jaiea.v4i2.775.
- [16] S. A. Al-Saad, R. N. Jawarneh, and A. S. Aloudat, "Spatiotemporal cluster analysis of reputable tourist accommodation in Greater Amman Municipality, Jordan," *Journal of Hospitality and Tourism Technology*, vol. 14, no. 4, pp. 579–597, Aug. 2023, doi: 10.1108/JHTT-03-2021-0071.
- [17] J. Astuti and T. Yuniarti, "Data Mining Modeling in Clustering Car Products Sales Data in the Automotive Industry in Indonesia," *Jurnal Manajemen Industri*

- dan Logistik*, vol. 7, no. 2, pp. 261–281, Nov. 2023, doi: 10.30988/jmil.v7i2.1258.
- [18] T. M. Fahrudin, M. H. P. Swari, R. N. Irawan, N. A. V. Ansori, and N. R. A. Putri, “Optimalisasi dashboard analytics dan iklanku shopee sebagai strategi penjualan alat dan perlengkapan dapur secara online,” *Transformasi: Jurnal Pengabdian Masyarakat*, vol. 17, no. 2, pp. 136–150, Dec. 2021, doi: 10.20414/transformasi.v17i2.3754.
- [19] S. Kumar, S. Gupta, and S. Arora, “A Comparative Simulation of Normalization Methods for Machine Learning-Based Intrusion Detection Systems Using KDD Cup’99 Dataset,” *Journal of Intelligent & Fuzzy Systems*, vol. 42, no. 3, pp. 1749–1766, 2022, doi: 10.3233/jifs-211191.
- [20] D. B. Santoso and Y. Wahyuni, “ANALISIS SEGMENTASI PENJUALAN POMPA AIR MENGGUNAKAN ALGORITMA K-MEANS SEGMENTATION ANALYSIS OF WATER PUMP SALES USING K-MEANS ALGORITHM,” *Jurnal Aplikasi Bisnis dan Komputer*, vol. 4, no. 2, pp. 83–89, Sep. 2024, doi: 10.33751/jubikom.v4i2.10696.
- [21] K. Tabianan, S. Velu, and V. Ravi, “K-Means Clustering Approach for Intelligent Customer Segmentation Using Customer Purchase Behavior Data,” *Sustainability*, vol. 14, no. 12, p. 7243, Jun. 2022, doi: 10.3390/su14127243.