

Model Hybrid dalam Penentuan Stok Barang Bangunan Melalui Pendekatan Machine Learning

Intan Bintang Adinda*, Davit Irawan, Joni Karman, Ahmad Sobri

Fakultas Ilmu Teknik, Program Studi Informatika, Universitas Bina Insan, Lubuklinggau, Indonesia
Email: ^{1,*}intan.tc4@gmail.com, ²davit_irawan@univbinainsan.ac.id, ³joni_karman@univbinainsan.ac.id,
⁴ahmadsobri506@gmail.com

Email Penulis Korespondensi: intan.tc4@gmail.com

Submitted: 20/07/2025; Accepted: 30/11/2025; Published: 30/11/2025

Abstrak—Penelitian ini bertujuan untuk mengembangkan sebuah model prediksi stok barang bangunan berbasis machine learning menggunakan pendekatan hybrid yang mengombinasikan K-Means Clustering sebagai metode pengelompokan pola penjualan dan Support Vector Machine (SVM) sebagai metode klasifikasi untuk memprediksi tingkat kelarisan barang. Penelitian ini dilatarbelakangi oleh permasalahan pengelolaan stok di Toko Usaha Jaya Kota Lubuklinggau yang masih dilakukan secara manual, sehingga berpotensi menimbulkan kelebihan stok yang meningkatkan biaya penyimpanan serta kekurangan stok yang dapat menyebabkan hilangnya peluang penjualan dan menurunkan kepuasan pelanggan. Data yang digunakan mencakup nama barang, jumlah stok awal, jumlah terjual, sisa stok, dan harga jual yang dikumpulkan selama periode Januari hingga Desember 2023. Hasil penelitian menunjukkan bahwa model hybrid mampu mengelompokkan barang ke dalam tiga kategori, yaitu sangat laris, cukup laris, dan kurang laris, dengan nilai Silhouette Score sebesar 0,42 yang menunjukkan kualitas clustering yang cukup baik. Selanjutnya, model SVM menghasilkan tingkat akurasi klasifikasi sebesar 99%, yang mencerminkan peningkatan ketepatan prediksi stok dibandingkan dengan metode pengelolaan manual. Temuan ini menunjukkan bahwa penerapan model hibrida K-Means dan SVM dapat meningkatkan efisiensi pengelolaan inventori serta mendukung pengambilan keputusan berbasis data secara lebih akurat dan efektif.

Kata Kunci: Stok Barang; K-Means; SVM; Machine Learning; Clustering; Hybrid Model

Abstract—This study aims to develop a machine learning-based construction material stock prediction model using a hybrid approach that combines K-Means Clustering as a sales pattern grouping method and Support Vector Machine (SVM) as a classification method to predict material sales levels. This research was motivated by the problem of stock management at Toko Usaha Jaya in Lubuklinggau City, which is still done manually, thus potentially causing excess stock that increases storage costs and stock shortages that can lead to lost sales opportunities and decreased customer satisfaction. The data used includes material names, initial stock quantities, quantities sold, remaining stock, and selling prices collected during the period from January to December 2023. The results show that the hybrid model is capable of grouping materials into three categories, namely very popular, fairly popular, and less popular, with a Silhouette Score of 0.42, indicating fairly good clustering quality. Furthermore, the SVM model produced a classification accuracy rate of 99%, reflecting an increase in stock prediction accuracy compared to manual management methods. These findings indicate that the application of the K-Means and SVM hybrid model can improve inventory management efficiency and support more accurate and effective data-driven decision making.

Keywords: Stock Inventory; K-Means; SVM; Machine Learning; Clustering; Hybrid Model

1. PENDAHULUAN

Dunia usaha adalah dunia yang terus berkembang dari waktu ke waktu. Setiap individu yang menjalankan usaha, selalu mencari jalan untuk memperoleh sesuatu yang lebih menguntungkan dari sebelumnya salah satunya Toko Usaha Jaya yang merupakan salah satu usaha yang bergerak dibidang penjualan barang bangunan. Perkembangan dunia usaha tersebut menuntut para pelaku usaha untuk mampu beradaptasi dengan perubahan pasar dan perilaku konsumen yang semakin dinamis. Sebagai seorang pemilik usaha, tentunya harus memiliki strategi dalam mengelola persediaan barang agar tidak mengalami kerugian akibat barang yang menumpuk [1]. Di era perkembangan teknologi yang cukup pesat ini membantu manusia dalam memudahkan setiap kegiatan diberbagai bidang sehingga menjadi lebih efektif dan efisien. Salah satu teknologi yang dapat digunakan pada bidang industri yaitu dalam melakukan persediaan barang [2]. Sistem stok barang merupakan sebuah prosedur dan cara pengelolaan dari aktivitas yang saling berkaitan dalam operasional perusahaan untuk penyimpanan barang sementara di gudang. Aktivitas pengegedalian persediaan barang merupakan salah satu kegiatan utama yang dilaksanakan di dalam perusahaan, karena kegagalan dalam aktivitas pengendalian persediaan stok barang akan mempunyai pengaruh yang cukup besar terhadap masa depan Perusahaan [3].

Permasalahan pengelolaan persediaan tidak hanya terbatas pada pencatatan jumlah barang, tetapi juga berkaitan dengan kemampuan perusahaan dalam menganalisis pola data penjualan historis yang terus bertambah. Data penjualan dan persediaan yang tidak dianalisis secara optimal berpotensi menyebabkan pengambilan keputusan yang kurang tepat. Oleh karena itu, diperlukan suatu pendekatan analitis berbasis data yang mampu mengolah dan mengekstraksi pola dari data penjualan sehingga dapat memberikan gambaran kondisi stok secara sistematis dan terstruktur. Pendekatan data mining dan machine learning menjadi solusi yang relevan dalam mendukung pengambilan keputusan pengelolaan persediaan berbasis data.

Clustering dan klasifikasi merupakan dua teknik yang memiliki fungsi berbeda namun saling melengkapi. Clustering digunakan untuk mengelompokkan data historis berdasarkan kemiripan karakteristik tanpa label

kelas, sedangkan klasifikasi digunakan untuk memprediksi kelas atau kategori dari data baru berdasarkan model yang telah dilatih sebelumnya [4], [5]. Agar tidak terjadi kesalahan dalam perkiraan penjualan yang berdampak pada hilangnya sejumlah pelanggan, untuk itu diperlukan suatu peramalan yang mendukung pengambilan keputusan [6]. Pada penelitian ini, metode K-Means Clustering digunakan untuk melakukan segmentasi data penjualan lama ke dalam kelompok tingkat kelarisan barang, sedangkan Support Vector Machine (SVM) digunakan sebagai metode klasifikasi untuk memprediksi kategori tingkat kelarisan barang baru berdasarkan pola yang telah terbentuk. Dengan demikian, penelitian ini tidak menggunakan pendekatan peramalan berbasis deret waktu (time series), melainkan pendekatan prediksi berbasis klasifikasi.

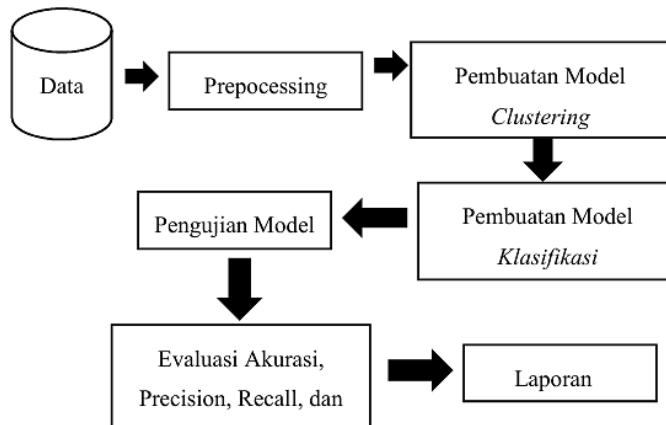
Teknik klasifikasi dan pengelompokan data merupakan bagian dari data mining yang banyak dimanfaatkan untuk menganalisis pola tersembunyi pada data penjualan. Pendekatan ini memungkinkan pihak manajemen untuk memahami karakteristik setiap produk berdasarkan tingkat permintaan konsumen. Melalui proses pengelompokan tersebut, barang dapat dibedakan menjadi kategori tertentu sehingga memudahkan dalam menentukan kebijakan stok yang lebih efektif dan efisien.

Beberapa penelitian terdahulu telah menerapkan metode clustering dalam pengelolaan persediaan. Penelitian oleh Najia Salsabila menerapkan K-Means Clustering untuk pengelompokan produk berdasarkan data penjualan [7]. Penelitian lain oleh Sinaga dkk. memanfaatkan teknik data mining untuk pengelolaan stok barang di apotek menggunakan algoritma Apriori [8]. Penelitian serupa juga dilakukan oleh Tri Wahyudi dan Titi Silfia yang menerapkan K-Means Clustering untuk mengelompokkan data penjualan produk ke dalam beberapa kategori tingkat penjualan. Penelitian oleh Roki Hardianto dkk. juga menggunakan metode K-Means untuk menentukan kategori stok barang menjadi stok besar, sedang, dan rendah [9].

Meskipun K-Means efektif dalam mengelompokkan data historis, metode ini memiliki keterbatasan karena tidak dapat secara langsung memprediksi kategori data baru. Kondisi ini menjadi kurang efisien apabila digunakan sebagai sistem pendukung keputusan yang bersifat dinamis. Oleh karena itu, diperlukan pendekatan hibrida yang mengombinasikan metode clustering dan klasifikasi untuk menghasilkan sistem yang lebih adaptif dan prediktif. Berdasarkan permasalahan tersebut, penelitian ini mengusulkan model hibrida yang mengombinasikan K-Means Clustering dan Support Vector Machine (SVM) dalam pengelolaan stok barang bangunan. Urgensi penerapan model hibrida ini terletak pada kebutuhan akan sistem prediksi stok yang tidak hanya mampu mengelompokkan data historis, tetapi juga mampu memprediksi kategori stok untuk data baru secara otomatis dan akurat. Penerapan model ini diharapkan dapat membantu pelaku usaha dalam meningkatkan efisiensi pengelolaan persediaan, mengurangi risiko kelebihan maupun kekurangan stok, serta mendukung pengambilan keputusan berbasis data secara lebih optimal dan berkelanjutan.

2. METODOLOGI PENELITIAN

Pada saat ini toko Usaha jaya Lubuklinggau mencatat semua barang yang masuk hanya menggunakan buku catatan secara manual, pada akhir bulan baru dilakukan pengecekan seberapa banyak barang masuk dan barang keluar serta melakukan pengecekan terhadap barang apa saja yang terjual, maka analisis data dalam penelitian ini menggunakan pendekatan Machine Learning, dengan tujuan untuk menentukan jumlah stok barang pada Toko Bangunan Usaha Jaya Kota Lubuklinggau. Tahapan analisis data dapat dilihat pada Gambar 1.



Gambar 1. Metode Penelitian

2.1 Pengumpulan Data

Data yang digunakan dalam studi ini terdiri dari data penjualan dan persediaan dari Toko Usaha Jaya selama periode Januari 2023 hingga Desember 2023. Data tersebut diperoleh dalam format Excel dengan beberapa lembar berdasarkan bulan, sehingga diperlukan penggabungan semua lembar untuk membentuk dataset yang lengkap. Atribut penting yang digunakan dalam pemodelan meliputi Nama Barang, Persediaan Barang, Jumlah

yang Dijual, Barang Tersisa, dan Harga Jual. Contoh data pada penelitian ini dapat dilihat pada Tabel 1.

Tabel 1. Contoh Data Penelitian

No	Nama Barang	Stok Barang	Terjual	Sisa Barang	Harga Jual
1	Anak Kunci Silinder B	670	560	11	3600
2	Anak Kunci Silinder K	890	750	14	3360
3	Angkong Plat Merah	510	510	0	3000
4	Angkong Arco Merah	650	470	18	6200
5	Angkong Visco PVC	600	450	15	4400
...

2.2 Preprocessing Data

Proses ini mencakup pembersihan dan persiapan data agar siap digunakan dengan model pembelajaran mesin. Proses ini melibatkan penghapusan data yang tidak relevan, penanganan nilai yang hilang, dan normalisasi data menggunakan min-max scaler. Persamaan min-max scaler dapat dilihat pada persamaan (1) [10].

$$X = \frac{X - X_{min}}{X_{max} - X_{min}} \tag{1}$$

2.3 Clustering Menggunakan K-Means

Algoritma K-Means digunakan untuk menentukan atau mengelompokkan data stok barang. Adapun langkah-langkah Algoritma K-Means, yaitu [11]:

- Tentukan nilai k dalam jumlah total kluster yang akan dibentuk.
- Inisialisasi pusat setiap kluster. Hal ini umumnya dilakukan secara acak dengan menetapkan nilai awal untuk pusat kluster.
- Hitung jarak setiap titik data masukan dan setiap pusat kluster menggunakan rumus jarak Euclidean untuk menemukan jarak terdekat antara setiap titik data dan pusat kluster.
- Hitung ulang pusat kluster berdasarkan anggota saat ini. Pusat dihitung sebagai rata-rata dari semua objek dalam kluster, meskipun ukuran lain seperti median juga dapat diterapkan.
- Perbarui penugasan objek menggunakan pusat kluster baru. Ulangi proses hingga pusat kluster tetap tidak berubah, yang menandakan bahwa proses pengelompokan telah selesai.

Nilai k yang digunakan ditentukan menggunakan metode elbow. Metode elbow adalah metode di mana pada suatu titik tertentu terjadi penurunan yang signifikan dalam grafik, berbentuk lengkungan yang tajam. Nilainya kemudian akan menjadi nilai k atau banyaknya cluster yang baik. Mencari nilai k optimal dapat dilakukan dengan membandingkan nilai Sum of Square Error (SEE) yang disajikan dalam bentuk grafik. Tujuan dari metode elbow yaitu memilih nilai k yang terkecil dan mempunyai nilai internal yang rendah. Penentuan jumlah cluster yang optimal diidentifikasi dengan mempertimbangkan perbandingan perhitungan *Sum of Square Error* (SEE) pada setiap nilai cluster, peningkatan jumlah cluster akan membentuk siku, sehingga semakin besar nilai k, nilai SEE akan semakin kecil [12]. Persamaan metode lebow dapat dilihat pada persamaan 2 [13].

$$SEE = \sum_{k=1}^k \sum_{x_i \in SK} \|x_i - C_k\|_2^2 \tag{2}$$

Setelah melakukan pengelompokan menggunakan algoritma K-Means, langkah selanjutnya adalah mengevaluasi kualitas kelompok yang terbentuk menggunakan Silhouette Score. Silhouette Score adalah metrik yang digunakan untuk mengevaluasi kualitas hasil pengelompokan. Skor Silhouette berkisar antara -1 dan 1, di mana:

- Nilai mendekati 1: Menunjukkan bahwa objek berada di kluster yang benar.
 - Nilai mendekati 0: Objek berada di batas antara dua kluster.
 - Nilai negatif: Objek lebih dekat ke kluster lain daripada kluster yang seharusnya menjadi bagiannya.
- Silhouette Score dapat dihitung menggunakan persamaan (3) [14].

$$s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}} \tag{3}$$

2.4 Klasifikasi Menggunakan Support Vector Machine (SVM)

Setelah pengelompokan, label kluster (Sangat Laris, Cukup Laris, Kurang Laris) yang dihasilkan oleh K-Means akan digunakan sebagai *ground truth* (label target) untuk melatih model SVM agar dapat memprediksi kategori stok baru secara otomatis. Dalam studi ini, metode Support Vector Machine (SVM) akan digunakan untuk mengklasifikasikan jumlah stok. SVM adalah teknik yang digunakan untuk membuat prediksi dalam konteks klasifikasi dan regresi [15]. Prinsip dasar SVM adalah bahwa ia bertindak sebagai klasifikasi linier, artinya ia dapat memisahkan data yang dapat diklasifikasikan secara linier. Namun, SVM telah mengalami perkembangan signifikan, memungkinkan untuk menangani masalah non-linier dengan menerapkan konsep kernel dalam ruang dimensi tinggi [16]. Dalam ruang dimensi tinggi ini, algoritma mencari hiperplane yang memaksimalkan margin

antara kelas data. Secara keseluruhan, algoritma SVM merupakan salah satu metode penambahan data yang efektif untuk menyelesaikan masalah klasifikasi dan regresi, baik data tersebut bersifat linier maupun non-linier [17]

2.5 Evaluasi Model

Dalam penelitian ini, evaluasi kinerja model klasifikasi dilakukan menggunakan confusion matrix berukuran 2×2 . Meskipun hasil klasifikasi terdiri dari tiga kategori, yaitu sangat laris, cukup laris, dan kurang laris, proses evaluasi dilakukan dengan pendekatan One-vs-Rest (OvR). Pada pendekatan ini, setiap kelas dievaluasi secara biner dengan membandingkan satu kelas sebagai kelas positif (positive) dan dua kelas lainnya sebagai kelas negatif (negative). Confusion matrix 2×2 digunakan untuk menghitung nilai True Positive, True Negative, False Positive, dan False Negative pada masing-masing kelas. Pendekatan ini memungkinkan perhitungan metrik evaluasi seperti akurasi, presisi, dan recall secara terpisah untuk setiap kategori kelulusan tanpa harus menggunakan confusion matrix multi-kelas 3×3 . Hasil evaluasi confusion matrix untuk setiap skenario One-vs-Rest disajikan pada Tabel 1 [18].

Tabel 1. Confusion Matriks

	Predicted Negative	Predicted Positive
Actual Negative	True Negative (TN)	False positive (FP)
Actual Positive	False Negative (FN)	True positive (TP)

Evaluasi menggunakan confusion matriks menghasilkan nilai akurasi, presisi, recall, dan F1-score untuk mengukur kinerja model [19], [20].

a. Akurasi : Persentase prediksi yang benar.

$$\text{Akurasi} = \frac{(TP+TN)}{(TP+FP+FN+TN)} \quad (4)$$

b. Presisi : Derajat kebenaran prediksi positif

$$\text{Presisi} = \frac{(TP)}{(TP + FP)} \quad (5)$$

c. Recall: TKemampuan model untuk mendeteksi data positif.

$$\text{Recall} = \frac{(TP)}{(TP + FN)} \quad (6)$$

3. HASIL DAN PEMBAHASAN

3.1 Preprocessing Data

Preprocessing data dalam studi ini dilakukan dalam dua tahap utama, yaitu konversi angka dan normalisasi data. Tahap pertama adalah konversi angka, di mana data numerik yang awalnya muncul sebagai string dalam format lokal (menggunakan titik sebagai pemisah ribuan dan koma sebagai pemisah desimal) dikonversi menjadi tipe data float. Langkah ini bertujuan untuk memastikan bahwa data numerik dapat dikenali dengan akurat oleh sistem dan diproses lebih lanjut dalam analisis statistik atau pembelajaran mesin. Setelah proses konversi selesai, perubahan tersebut diterapkan kembali ke dataset utama (df) sehingga kolom-kolom yang relevan dapat digunakan secara konsisten pada tahap visualisasi dan pemodelan. Tahap kedua adalah normalisasi data menggunakan metode Min-Max Scaler dari `sklearn.preprocessing`, yang menskalakan data ke rentang 0 hingga 1 sehingga setiap fitur berkontribusi secara setara dalam algoritma pembelajaran mesin. Normalisasi ini penting karena perbedaan skala antara fitur, seperti 'Harga Jual' dan 'Stok Tersisa', dapat memengaruhi kinerja model jika tidak diseimbangkan terlebih dahulu.

3.2 Clustering Menggunakan K-Means

3.2.1 Metode Elbow

Penentuan jumlah kluster optimal dalam model K-Means dilakukan menggunakan metode Elbow. Dalam proses ini, *Sum of Squared Errors* (SSE) dihitung untuk berbagai jumlah kluster (k) yang berkisar antara 1 hingga 10. Setiap nilai SSE menunjukkan seberapa baik model mengelompokkan data; semakin rendah nilai SSE, semakin baik kualitas pengelompokan. Dari perhitungan ini, titik "elbow" diamati pada $k = 3$, yang menunjukkan jumlah kluster optimal karena penurunan nilai SSE mulai melambat setelah titik ini.

3.2.2 Proses Clustering Menggunakan K-Means

Hasil proses clustering menggunakan metode K-Means menghasilkan pengelompokan data stok barang bangunan berdasarkan tingkat kelulusan barang. Proses ini bertujuan untuk mengelompokkan data penjualan historis ke dalam beberapa kluster yang memiliki karakteristik serupa. Setiap data barang dikelompokkan

berdasarkan atribut stok awal, jumlah terjual, sisa barang, dan harga jual. Contoh hasil clustering dapat dilihat pada Tabel 2.

Tabel 2. Contoh Hasil Clustering

No	Nama Barang	Stok Barang	Terjual	Sisa Barang	Harga Jual	Cluster
1	Anak Kunci Silinder B	670	560	11	3600	0
2	Anak Kunci Silinder K	890	750	14	3360	0
3	Angkong Plat Merah	510	510	0	3000	2
4	Angkong Arco Merah	650	470	18	6200	2
5	Angkong Visco PVC	600	450	15	4400	2
...

Pada Tabel 2, hasil pengelompokan data menggunakan algoritma K-Means dengan jumlah kluster yang telah ditentukan sebelumnya, yaitu $k=3$, ditampilkan. Proses ini menghasilkan pembagian data menjadi tiga kelompok yang berbeda berdasarkan karakteristik masing-masing. Label kluster yang diperoleh kemudian ditambahkan ke dataset dalam kolom baru bernama “cluster”, sehingga setiap entri data memiliki penanda kelompok yang sesuai. Pembagian ini penting karena memungkinkan analisis lebih lanjut terhadap pola-pola tertentu yang muncul dari data, seperti pengelompokan berdasarkan tingkat persediaan, penjualan, atau barang yang tersisa.

Gambar tersebut juga menampilkan 10 entri data pertama yang dihasilkan dari proses clustering, yang berisi informasi tentang nama produk, stok, penjualan, stok tersisa, harga jual, dan label cluster. Misalnya, produk “Anak kunci silinder B” dengan stok 670 dan penjualan 560 ditempatkan dalam kluster 0. Proses pengelompokan ini membantu mengelompokkan produk dengan karakteristik serupa, memudahkan analisis lebih lanjut di dalam setiap kluster untuk merumuskan strategi yang lebih akurat. Label kluster ini sangat berguna untuk analisis mendalam, seperti mengidentifikasi produk dengan kinerja penjualan terbaik, produk dengan stok melimpah namun penjualan rendah, dan produk yang mungkin memerlukan perhatian untuk restocking atau promosi.

3.2.3 Evaluasi Silhouette Score

Silhouette Score untuk $k=3$: 0.42

Gambar 1. Silhouette Score

Setelah melakukan pengelompokan menggunakan algoritma K-Means dengan jumlah kluster $k=3$, langkah selanjutnya adalah mengevaluasi kualitas kluster yang terbentuk menggunakan Skor Silhouette. Skor Silhouette merupakan metrik yang digunakan untuk mengukur tingkat kesesuaian suatu objek terhadap kluster tempatnya berada dibandingkan dengan kluster lainnya, dengan nilai berkisar antara -1 hingga 1 . Berdasarkan Gambar 2, nilai Skor Silhouette yang diperoleh untuk $k=3$ adalah sebesar $0,42$, yang menunjukkan bahwa struktur kluster yang terbentuk tergolong lemah. Kondisi tersebut dapat terjadi pada data penjualan barang bangunan yang memiliki variasi permintaan yang tinggi dan pola penjualan yang tidak selalu terpisah secara jelas. Meskipun demikian, hasil clustering ini tetap digunakan sebagai dasar segmentasi data penjualan sebelum dilanjutkan ke tahap klasifikasi menggunakan metode Support Vector Machine (SVM).

3.2.4 Analisis Statistik Setiap Cluster

Analisis statistik dilakukan pada setiap kluster yang terbentuk melalui algoritma K-Means untuk memahami karakteristik umum dari setiap kelompok item. Proses ini dilakukan dengan mengelompokkan data berdasarkan label kluster dan menghitung nilai rata-rata untuk variabel yang relevan, yaitu persediaan, penjualan, dan harga jual. Hasilnya memberikan gambaran yang jelas tentang perbedaan pola di antara ketiga kluster yang dihasilkan.

Tabel 3. Output Analisis Setiap Cluster

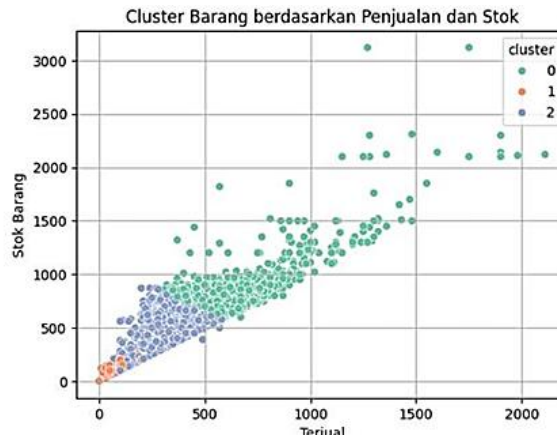
Cluster	Stok Barang	Terjual	Harga Jual
0	845.906	667.718	1,00E+09
1	120.208	90.000	1,63E+13
2	470.533	355.335	1,22E+03

Seperti yang ditunjukkan pada Tabel 3, kluster 0 mewakili kelompok barang dengan rata-rata persediaan 845,91 unit, rata-rata volume penjualan 667,72 unit, dan harga jual rata-rata sekitar Rp1.004.539. Karakteristik ini menunjukkan bahwa kluster 0 didominasi oleh barang-barang dengan persediaan besar dan volume penjualan tinggi, dengan harga jual yang moderat. Cluster 1, di sisi lain, menunjukkan karakteristik yang sangat berbeda, dengan rata-rata stok sebesar 120,21 unit dan rata-rata penjualan sebesar 90 unit, tetapi dengan harga jual yang jauh lebih tinggi, yaitu sekitar Rp16.300.000. Hal ini menunjukkan bahwa meskipun stok dan volume penjualan relatif rendah, nilai ekonomi barang-barang dalam cluster ini sangat tinggi. Sementara itu, Cluster 2 berada di tengah, dengan rata-rata stok 470,53 unit, rata-rata penjualan 355,34 unit, dan harga jual rata-rata sekitar

Rp1.215.168. Karakteristik ini menempatkan Cluster 2 sebagai kelompok dengan stok, penjualan, dan harga jual yang moderat dibandingkan dengan dua cluster lainnya. Berdasarkan hasil ini, analisis statistik setiap cluster memberikan wawasan penting untuk manajemen persediaan dan strategi penjualan. Barang-barang dalam cluster 0 harus diprioritaskan untuk menjaga ketersediaan karena perputarannya yang cepat. Barang-barang dalam cluster 1, meskipun jumlahnya terbatas, memerlukan strategi pemasaran khusus karena nilai ekonominya yang tinggi. Sementara itu, barang-barang dalam cluster 2 memerlukan manajemen yang seimbang untuk menjaga stabilitas baik dalam persediaan maupun penjualan

3.2.5 Visualisasi Cluster 2D dan 3D

a. Visualisasi Cluster 2D




Gambar 2. Visualisasi Cluster 2D

Gambar 2 menampilkan hasil visualisasi kluster menggunakan diagram pencar untuk memetakan hubungan antara jumlah barang yang terjual (Penjualan) dan persediaan yang tersedia (Persediaan). Setiap titik pada grafik mewakili satu barang, dengan sumbu horizontal menunjukkan jumlah unit yang terjual dan sumbu vertikal menunjukkan persediaan yang tersedia.

Cluster yang dibentuk melalui algoritma K-Means ditampilkan dengan palet warna yang berbeda sesuai dengan label kluster masing-masing. Misalnya, kluster 0 (hijau) terdiri dari barang dengan persediaan tinggi dan volume penjualan tinggi, kluster 1 (biru) berisi barang dengan persediaan rendah tetapi volume penjualan sedang, sementara kluster 2 (oranye) mewakili barang dengan persediaan rendah dan volume penjualan rendah.

Visualisasi ini memudahkan untuk mengidentifikasi pola atau hubungan antara persediaan dan penjualan. Hasilnya menunjukkan bahwa kluster 0 didominasi oleh barang-barang dengan ketersediaan dan penjualan yang lebih tinggi, sedangkan kluster 2 terdiri dari barang-barang dengan tingkat persediaan dan penjualan yang relatif rendah. Oleh karena itu, visualisasi ini sangat berguna untuk memahami distribusi barang di dalam setiap kluster, serta sebagai dasar untuk merancang strategi manajemen persediaan dan promosi yang lebih efektif.

b. Visualisasi Cluster 3D



Gambar 3. Visualization of 3D Cluster

Gambar 3 menunjukkan hasil visualisasi kluster dalam ruang tiga dimensi untuk menggambarkan hubungan antara tiga variabel penting: jumlah barang yang terjual (Penjualan), persediaan (Persediaan), dan harga jual (Harga Jual). Setiap titik pada grafik mewakili satu barang, dengan warna titik menunjukkan label kluster yang dihasilkan oleh algoritma K-Means.

Visualisasi ini menyoroti pola distribusi yang berbeda dari setiap kluster berdasarkan tiga variabel. Kluster 0 (merah) terdiri dari barang-barang dengan persediaan yang lebih tinggi dan volume penjualan yang lebih tinggi, kluster 1 (abu-abu) berisi barang-barang dengan harga premium dan volume penjualan yang relatif

rendah, sementara kluster 2 (oranye) mewakili barang-barang dengan persediaan dan volume penjualan yang rendah. Perbedaan harga jual tercermin dalam variasi warna titik-titik, di mana warna yang lebih cerah menunjukkan harga yang lebih tinggi dan warna yang lebih gelap menunjukkan harga yang lebih rendah.

Melalui visualisasi 3D ini, hubungan antar variabel menjadi lebih jelas, dan pola distribusi item di dalam setiap kluster dapat diidentifikasi dengan lebih baik. Temuan ini memberikan wawasan berharga untuk merancang strategi manajemen persediaan, penetapan harga, dan pendekatan pemasaran yang lebih sesuai dengan karakteristik masing-masing kelompok produk.

3.2.6 Centroid Cluster

Pada tahap berikutnya, perhitungan pusat massa (centroid) dilakukan untuk memahami karakteristik umum dari setiap kluster yang terbentuk. Pusat massa mewakili titik pusat dari suatu kluster, dihitung sebagai nilai rata-rata dari atribut-atribut yang dipilih, yaitu stok, penjualan, stok tersisa, dan harga jual, setelah normalisasi data. Dengan mengidentifikasi posisi pusat massa, karakteristik dominan dari setiap kluster dapat diinterpretasikan dengan lebih jelas.

Tabel 4. Centroid Cluster

Cluster	Stok Barang	Terjual	Sisa	Harga Jual
0	0.27	0.32	0.10	0.00
1	0.04	0.04	0.02	0.65
2	0.15	0.17	0.06	0.00

Berdasarkan Tabel 4, hasil perhitungan pusat kluster pada skala yang dinormalisasi menunjukkan perbedaan yang signifikan di antara kluster-kluster. Kluster 0 memiliki nilai pusat massa sebesar 0,27 untuk stok, 0,32 untuk penjualan, 0,10 untuk stok tersisa, dan 0,00 untuk harga. Nilai-nilai ini menunjukkan bahwa kluster 0 terdiri dari barang-barang dengan stok relatif rendah tetapi penjualan relatif tinggi, serta harga jual yang lebih rendah, yang mengindikasikan bahwa produk-produk ini lebih terjangkau dan diminati. Kluster 1, di sisi lain, menunjukkan nilai pusat kluster sebesar 0,04 untuk stok, 0,04 untuk penjualan, 0,02 untuk stok tersisa, dan 0,65 untuk harga. Hal ini menunjukkan bahwa barang-barang dalam kluster 1 memiliki stok dan penjualan yang sangat rendah, namun harga yang relatif tinggi, menunjukkan bahwa ini adalah produk premium yang dijual dalam jumlah kecil. Sementara itu, Cluster 2 ditandai dengan nilai pusat 0,15 untuk stok, 0,17 untuk penjualan, 0,06 untuk stok tersisa, dan 0,00 untuk harga. Hal ini menunjukkan bahwa barang-barang dalam Cluster 2 memiliki tingkat stok dan penjualan yang moderat, dengan harga yang lebih rendah, sehingga menjadi produk yang lebih terjangkau dengan permintaan yang moderat.

Berdasarkan nilai pusat massa (centroid) ini, dapat disimpulkan bahwa kluster 0 mewakili produk-produk terjangkau dengan kinerja penjualan yang lebih tinggi, kluster 1 terdiri dari produk-produk dengan harga premium dan penjualan yang lebih rendah, sementara kluster 2 mencerminkan produk-produk dengan permintaan moderat dan harga yang relatif lebih rendah. Informasi ini memberikan gambaran yang jelas tentang karakteristik masing-masing kluster dan berfungsi sebagai landasan penting untuk pengambilan keputusan terkait manajemen persediaan, strategi penetapan harga, dan pendekatan pemasaran.

3.2.7 Pemetaan Label dan Impikasi Bisnis

Setelah proses pengelompokan dilakukan dan data dibagi menjadi beberapa kluster, langkah selanjutnya adalah mengaitkan label ke masing-masing kluster untuk memberikan interpretasi yang lebih mudah dipahami. Pengaitan ini bertujuan untuk mengkategorikan setiap kluster berdasarkan tingkat permintaan dan karakteristik produk yang terkandung di dalamnya. Misalnya, kluster dengan penjualan tinggi dan persediaan melimpah dapat diberi label “Sangat Laris”, sementara kluster dengan penjualan rendah dan persediaan terbatas dapat diberi label “Kurang Laris.”

Tabel 5. Pemetaan Label dan Rekomendasi untuk Setiap Kluster

No	Nama Barang	Stok Barang	Terjual	Sisa Barang	Harga Jual	Cluster	Label	Rekomendasi
1	Anak Kunci Silinder B	670	560	11	3600	0	Kurang Laris	Kurangi Stok untuk Efisiensi
2	Anak Kunci Silinder K	890	750	14	3360	0	Kurang Laris	Kurangi Stok untuk Efisiensi
3	Angkong Plat Merah	510	510	0	3000	2	Sangat Laris	Tingkatkan Stok Barang
4	Angkong Arco Merah	650	470	18	6200	2	Sangat Laris	Tingkatkan Stok Barang
5	Angkong Visco PVC	600	450	15	4400	2	Sangat Laris	Tingkatkan Stok Barang

Pada Tabel 5, ditampilkan hasil pemetaan label dan rekomendasi berdasarkan kategori kluster. Setiap kluster yang terbentuk tidak hanya diberi label tetapi juga dilengkapi dengan rekomendasi spesifik terkait manajemen persediaan. Misalnya, barang dalam kategori “Kurang Laris” direkomendasikan untuk “Mengurangi persediaan demi efisiensi”, sementara produk dalam kategori “Sangat Laris” direkomendasikan untuk “Meningkatkan persediaan” guna memenuhi permintaan yang tinggi.

Pemetaan ini memiliki implikasi bisnis yang signifikan. Perusahaan dapat mengelola tingkat persediaan dengan lebih akurat, menentukan prioritas restocking, dan mengembangkan strategi pemasaran berdasarkan kinerja penjualan setiap kelompok produk. Oleh karena itu, hasil pemetaan label dan rekomendasi berfungsi sebagai panduan praktis untuk pengambilan keputusan strategis guna meningkatkan efisiensi dan efektivitas manajemen persediaan.

3.3 Klasifikasi Menggunakan Support Vector Machine (SVM)

Tahap klasifikasi menggunakan Support Vector Machine (SVM) merupakan bagian lanjutan dan terintegrasi dari model hibrida yang diusulkan dalam penelitian ini. Setelah proses pengelompokan menggunakan K-Means selesai, setiap data produk memperoleh label kluster berdasarkan tingkat kelarisan. Label kluster tersebut selanjutnya digunakan sebagai kelas target dalam proses klasifikasi menggunakan SVM. Dengan demikian, peran SVM bukan sebagai metode terpisah, melainkan sebagai mekanisme untuk mentransformasikan hasil clustering menjadi model prediksi yang dapat digunakan untuk mengklasifikasikan data produk baru tanpa perlu melakukan proses clustering ulang. Model klasifikasi ini bertujuan untuk menentukan kategori tingkat kelarisan produk berdasarkan karakteristik penjualan dan persediaan, sehingga sistem yang dihasilkan bersifat lebih adaptif dan operasional.

3.3.1 Inisialisasi dan Pelatihan Model

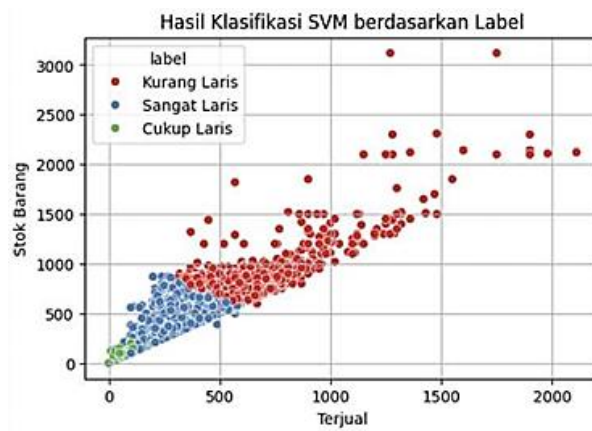
Model SVM diinisialisasi menggunakan kernel Radial Basis Function (RBF) karena kernel ini efektif dalam menangani hubungan non-linear antara fitur data dan label kelas. Penggunaan kernel RBF memungkinkan SVM mempelajari batasan non-linear antar kluster yang sebelumnya dibentuk oleh K-Means. Model kemudian dilatih menggunakan data pelatihan yang telah memiliki label kluster hasil pengelompokan K-Means, sehingga SVM berfungsi untuk mempelajari pola pemisahan antar kluster tersebut.

3.3.2 Prediksi

Setelah proses pelatihan selesai, model SVM digunakan untuk memprediksi kategori kluster pada data uji. Melalui tahap ini, SVM berperan sebagai komponen prediktif dalam model hibrida yang memungkinkan penentuan kategori tingkat kelarisan produk baru secara otomatis tanpa perlu menjalankan ulang proses K-Means. Hasil prediksi menunjukkan kluster yang paling sesuai untuk setiap produk berdasarkan pola yang telah dipelajari.

3.3.3 Visualisasi Hasil Klasifikasi

Setelah prediksi, hasil klasifikasi ditampilkan menggunakan diagram pencar untuk menunjukkan hubungan antara penjualan (*Sold*) dan persediaan (*Stock on Hand*). Visualisasi ini memberikan gambaran yang jelas tentang pengelompokan produk berdasarkan prediksi model SVM.




Gambar 4. Visualisasi Klasifikasi Produk Berdasarkan Penjualan dan Stok

Gambar 4 menunjukkan hasil klasifikasi produk ke dalam tiga kategori tingkat kelarisan, yaitu kurang laris, cukup laris, dan sangat laris. Produk dengan label “Kurang Laris” ditampilkan sebagai titik merah yang merepresentasikan penjualan rendah dengan persediaan relatif tinggi. Produk dengan label “Cukup Laris” ditampilkan sebagai titik hijau yang menunjukkan keseimbangan antara penjualan dan persediaan, sedangkan produk dengan label “Sangat Laris” ditampilkan sebagai titik biru yang merepresentasikan penjualan tinggi

dengan persediaan lebih rendah. Visualisasi ini menunjukkan bahwa model SVM mampu merepresentasikan hasil segmentasi K-Means secara konsisten dan memudahkan interpretasi dalam perumusan strategi pengelolaan stok

3.3.4 Evaluasi Model



Gambar 5. Confusion Matrix

Berdasarkan Gambar 5, confusion matrix menggambarkan kinerja model dalam mengklasifikasikan tingkat penjualan produk ke dalam tiga kategori: sangat laris, sedang laris, dan kurang laris. Untuk kategori sangat laris (kelas 0), model berhasil memprediksi dengan benar 355 titik data, meskipun 2 titik data salah diklasifikasikan sebagai kategori kurang laris. Untuk kategori penjualan sedang (kelas 1), model mencapai prediksi sempurna, dengan semua 12 titik data diklasifikasikan dengan benar tanpa kesalahan klasifikasi. Sementara itu, untuk kategori penjualan rendah (kelas 2), model berhasil memprediksi dengan benar 684 titik data, dengan hanya 6 titik data yang salah diklasifikasikan sebagai kategori penjualan tinggi.

Evaluasi kinerja model dilakukan menggunakan metrik akurasi, presisi, dan recall berdasarkan matriks kebingungan, dengan hasil akurasi sebesar 99,24%, presisi rata-rata 99,35%, dan recall rata-rata 99,52%. Tingginya nilai evaluasi ini perlu dipahami dalam konteks bahwa model SVM dilatih menggunakan label kelas yang dihasilkan oleh metode K-Means pada dataset yang sama, sehingga termasuk dalam pendekatan *self-labeling*. Oleh karena itu, nilai akurasi yang tinggi tidak secara langsung merepresentasikan kemampuan prediksi masa depan, melainkan menunjukkan bahwa SVM berhasil mempelajari dan memetakan batasan non-linear antar kluster yang dibentuk oleh K-Means. Penggunaan kernel Radial Basis Function (RBF) memungkinkan SVM membangun hyperplane non-linear yang kompleks sehingga mampu merepresentasikan struktur kluster secara efektif dan konsisten dalam kerangka model hibrida.

3.4 Pembahasan

Berdasarkan hasil penelitian yang telah dilakukan, tahapan analisis dimulai dengan proses preprocessing data yang bertujuan untuk meningkatkan kualitas data sebelum dilakukan pemodelan. Preprocessing dilakukan melalui konversi data numerik dari format string ke tipe float agar data dapat diproses secara akurat, diikuti dengan normalisasi menggunakan metode Min-Max Scaler untuk menyetarakan skala antar fitur sehingga setiap variabel memiliki kontribusi yang seimbang dalam proses pembelajaran mesin. Tahap selanjutnya adalah pengelompokan data menggunakan algoritma K-Means, di mana penentuan jumlah kluster optimal dilakukan melalui metode Elbow dan menunjukkan bahwa nilai $k = 3$ merupakan jumlah kluster yang paling sesuai berdasarkan pola penurunan nilai Sum of Squared Errors (SSE). Hasil clustering membagi data ke dalam tiga kelompok dengan karakteristik yang berbeda, yang kemudian dievaluasi menggunakan Silhouette Score dan menghasilkan nilai sebesar 0,42, menunjukkan bahwa kualitas kluster yang terbentuk tergolong cukup baik meskipun masih terdapat sedikit tumpang tindih antar kluster. Analisis statistik terhadap masing-masing kluster menunjukkan perbedaan yang signifikan, di mana kluster pertama didominasi oleh produk dengan tingkat persediaan dan volume penjualan yang tinggi serta harga jual yang relatif terjangkau, kluster kedua terdiri dari produk dengan harga premium namun memiliki stok dan penjualan yang rendah, sementara kluster ketiga menunjukkan karakteristik produk dengan tingkat persediaan, penjualan, dan harga jual yang moderat. Pola ini semakin diperjelas melalui visualisasi kluster dalam bentuk dua dimensi dan tiga dimensi yang menggambarkan hubungan antara persediaan, penjualan, dan harga jual secara lebih intuitif. Selain itu, analisis centroid kluster memperkuat interpretasi karakteristik masing-masing kelompok dan menjadi dasar dalam pemetaan label bisnis seperti “Sangat Laris”, “Cukup Laris”, dan “Kurang Laris”, yang selanjutnya digunakan untuk merumuskan rekomendasi strategi pengelolaan persediaan. Untuk memvalidasi hasil klusterisasi, dilakukan tahap klasifikasi menggunakan algoritma Support Vector Machine (SVM) dengan kernel RBF, yang menunjukkan kinerja sangat baik berdasarkan hasil evaluasi menggunakan confusion matrix dan metrik akurasi, presisi, serta recall. Model klasifikasi mencapai tingkat akurasi sebesar 99,24%, yang menandakan bahwa pendekatan model hybrid yang

mengombinasikan K-Means Clustering dan Support Vector Machine mampu memberikan hasil klasifikasi stok barang yang akurat dan dapat dijadikan dasar pengambilan keputusan strategis dalam pengelolaan persediaan barang bangunan secara lebih efektif dan efisien.

4. KESIMPULAN

Model hybrid K-Means dan Support Vector Machine (SVM) berhasil diterapkan sebagai satu kesatuan pendekatan untuk segmentasi dan klasifikasi data stok barang bangunan berdasarkan karakteristik penjualan, persediaan, dan harga. Algoritma K-Means digunakan untuk membentuk struktur kluster awal yang mengelompokkan data ke dalam tiga kategori tingkat kelarisan, yaitu sangat laris, cukup laris, dan kurang laris, dengan jumlah kluster optimal pada $K = 3$. Hasil evaluasi menggunakan Skor Silhouette sebesar 0,42 menunjukkan bahwa struktur kluster yang terbentuk tergolong lemah dan masih memiliki tumpang tindih antar kluster, yang mencerminkan tingginya variasi dan kompleksitas pola penjualan barang bangunan. Selanjutnya, SVM digunakan untuk mempelajari batasan non-linear antar kluster yang dibentuk oleh K-Means dan menggeneralisasikannya ke dalam model klasifikasi yang dapat digunakan untuk data baru. Akurasi klasifikasi yang tinggi menunjukkan bahwa SVM mampu memetakan struktur kluster tersebut secara konsisten dalam kerangka pendekatan *self-labeling*, sehingga hasil ini tidak dimaknai sebagai kemampuan prediksi masa depan secara absolut, melainkan sebagai keberhasilan integrasi metode clustering dan klasifikasi dalam satu model hybrid yang adaptif. Visualisasi hasil pengelompokan dan klasifikasi dalam bentuk dua dan tiga dimensi membantu memberikan pemahaman yang lebih intuitif mengenai distribusi data dan karakteristik setiap kategori kelarisan, sehingga dapat dimanfaatkan sebagai dasar pengambilan keputusan manajemen stok. Penelitian ini menunjukkan bahwa penerapan pendekatan machine learning berbasis model hybrid dapat diterapkan secara praktis pada usaha kecil dan menengah, khususnya dalam mendukung pengelolaan persediaan berbasis data. Integrasi K-Means dan SVM memungkinkan sistem tidak hanya melakukan segmentasi data historis, tetapi juga menyediakan mekanisme klasifikasi yang dapat digunakan secara operasional tanpa perlu proses pengelompokan ulang. Untuk penelitian selanjutnya, disarankan agar model dikembangkan dengan menggunakan data eksternal seperti tren musiman dan dinamika pasar, serta dilakukan perbandingan dengan pendekatan multi-class atau algoritma lain guna memperoleh hasil yang lebih komprehensif dan robust.

REFERENCES

- [1] A. P. Rizkyandri, Jasmir, and Y. Arvita, "Implementasi Metode K-Means Clustering Untuk Menentukan Persediaan Barang Pada Toko SS BabyShop," *J. Inform. Dan Rekayasa Komput.*, vol. 3, no. September, pp. 712–718, 2023, doi: <https://doi.org/10.33998/jakakom.v3i2>.
- [2] D. Ramadhan, G. Dwilestari, R. D. Dana, A. Ajiz, and Kaslani, "Clustering Data Persediaan Barang dengan Menggunakan Metode K-Means," *MEANS (Media Inf. Anal. dan Sist.*, vol. 7, no. 1, pp. 1–9, 2022, doi: http://ejournal.ust.ac.id/index.php/Jurnal_Means/MEANS.
- [3] K. Komariah, R. Dasuki, D. B. Saputra, S. Anwar, and G. Dwilestari, "Klasifikasi Stok Barang Menggunakan Algoritma Naïve Bayes Pada PT.Dharma Electrindo Manufacturing," *J. Ilm. Manaj. Inform. dan Komput.*, vol. 04, no. 02, pp. 35–41, 2020, doi: <https://doi.org/10.32485/kopertip.v4i2.117>.
- [4] H. Siregar, "Klasterisasi Penjualan Alat-Alat Bangunan Menggunakan Metode K-Means (Studi Kasus Di Toko Adi Bangunan)," *J. Teknol. dan Open Source*, vol. 1, no. 2, pp. 83–91, 2018, doi: [10.36378/jtos.v1i2.24](https://doi.org/10.36378/jtos.v1i2.24).
- [5] F. M. Huda and R. Helilintar, "Implementasi Data Mining Pada Hasil Penjualan Barang Menggunakan Metode K-Means Clustering," in *Prosiding Seminar Nasional Inovasi Teknologi*, 2020, p. 61.
- [6] F. Nurdiyansyah and I. Akbar, "Implementasi Algoritma K-Means untuk Menentukan Persediaan Barang pada Poultry Shop," *J. Teknol. dan Manaj. Inform.*, vol. 7, no. 2, pp. 86–94, 2021, doi: <https://doi.org/10.26905/jtmi.v7i2.6377>.
- [7] N. Salsabila, "Klasifikasi Barang Menggunakan Metode Clustering K-Means Dalam Penentuan Prediksi Stok Barang (Studi Kasus : Ukm Mar ' Ah Jilbab Kediri)," Universitas Islam Negeri Maulana Malik Ibrahim, 2019.
- [8] B. Sinaga, M. Marpaung, I. Roseni, B. Tarigan, and K. Tania, "Implementation of Stock Goods Data Mining Using the Apriori Algorithm," *Sinkron*, vol. 7, no. 3, pp. 1980–1992, 2023, doi: <https://doi.org/10.33395/sinkron.v8i3.12852> e-ISSN.
- [9] R. Hardianto, H. Ramadhan, E. P. Pane, and Y. Yunefri, "K-Means Clustering in Determining the Category of Stock Items In Angkasa Mart," *Knowbase Int. J. Knowl. Database*, vol. 02, no. 01, pp. 30–45, 2022, doi: <http://dx.doi.org/10.30983/ijokid.v2i1.5411>.
- [10] J. Chomjinda, J. Piladaeng, and P. Thongnim, "Feature Scaling and Pre-processing Techniques for Machine Learning Analysis of Durian Data in Eastern Thailand," in *ICAS2024*, 2025, pp. 235–249, [Online]. Available: <https://www.researchgate.net/publication/389571761%0A>.
- [11] M. Imron, U. Hasanah, and B. Humaidi, "Analysis of Data Mining Using K-Means Clustering Algorithm for Product Grouping," *Int. J. Informatics Inf. Syst.*, vol. 3, no. 1, pp. 12–22, 2020.

- [12] N. Syahfitri, E. Budianita, A. Nazir, and I. Afrianty, "Pengelompokan Produk Berdasarkan Data Persediaan Barang Menggunakan Metode Elbow dan K-Medoid," *KLIK Kaji. Ilm. Inform. dan Komput.*, vol. 4, no. 3, pp. 1668–1675, 2023, doi: 10.30865/klik.v4i3.1525.
- [13] P. M. Hasugian, B. Sinaga, J. Manurung, and S. A. Al Hashim, "Performance Analysis Of Elbow Algorithms Against The Results Of Clustering K-means Algorithms In The Grouping Of Rice Production Areas In Indonesia," *Int. J. Artif. Intelligence Res.*, vol. 5, no. 1, pp. 102–110, 2021, doi: 10.29099/ijair.v6i1.232.
- [14] A. Punhani, N. Faujdar, and K. K. Mishra, "Binning-Based Silhouette Approach to Find the Optimal Cluster Using K-Means," *IEEE Access*, vol. 10, no. September, pp. 115025–115032, 2022, doi: 10.1109/ACCESS.2022.3215568.
- [15] R. Guido, S. Ferrisi, and D. Lofaro, "An Overview on the Advancements of Support Vector Machine Models in Healthcare Applications: A Review," *Information*, vol. 15, no. 235, pp. 1–36, 2024, doi: <https://doi.org/10.3390/info15040235>.
- [16] D. A. Pisner and D. M. Schnyer, *Support Vector Machine*. Elsevier Inc., 2020.
- [17] F. Pratama, M. Nasir, and S. Sauda, "Implementasi Metode Klasifikasi Dengan Algoritma Support Vector Machine Untuk Menentukan Stok Persediaan Barang Pada Koperasi Karyawan Pangan Utama," *J. Softw. Eng. Ampera*, vol. 1, no. 2, pp. 71–81, 2020, [Online]. Available: <https://journal-computing.org/index.php/journal-sea/index%0AImplementasi>.
- [18] N. Fadhilah and A. Desiani, "Klasifikasi Nyeri Punggung Bawah Menggunakan Algoritma K-Nearest Neighbor Dan Support Vector Machine," *J. Tek. Elektro dan Komputasi Vol.*, vol. 7, no. 1, pp. 91–98, 2025, doi: 10.32528/elkom.v7i1.22767.
- [19] S. Uddin, I. Haque, H. Lu, M. A. Moni, and E. Gide, "Comparative performance analysis of K - nearest neighbour (KNN) algorithm and its different variants for disease prediction," *Sci. Rep.*, vol. 12, pp. 1–11, 2022, doi: 10.1038/s41598-022-10358-x.
- [20] R. Ghezlbash, A. Maghsoudi, M. Shamekhi, B. Pradhan, and M. Daviran, "Genetic algorithm to optimize the SVM and K -means algorithms for mapping of mineral prospectivity," *Neural Comput. Appl.*, vol. 5, 2022, doi: <https://doi.org/10.1007/s00521-022-07766-5>.