

Implementasi Gaussian Naive Bayes untuk Klasifikasi Permintaan dan Simple Additive Weighting untuk Pemilihan Supplier Pengadaan Barang

Arya Kusumadewa^{1*}, Faulinda Ely Nastiti², Eko Purwanto³

¹Program Studi Sistem Informasi

Universitas Duta Bangsa

^{1*}220101045@mhs.udb.ac.id

²Program Studi Sistem Informasi

Universitas Duta Bangsa

²faulinda_ely@udb.ac.id

³Program Studi Sistem Informasi

Universitas Duta Bangsa

³eko_purwanto@udb.ac.id

Abstrak— Proses pengadaan barang memerlukan pengambilan keputusan yang tepat untuk memastikan ketersediaan barang sesuai dengan kebutuhan serta pemilihan supplier yang mampu memenuhi kriteria organisasi. Pengambilan keputusan yang hanya didasarkan pada pengalaman atau pertimbangan subjektif berpotensi menyebabkan ketidaksesuaian jumlah persediaan maupun pemilihan supplier yang kurang optimal. Penelitian ini bertujuan mengimplementasikan algoritma Gaussian Naive Bayes untuk mengklasifikasikan tingkat permintaan barang serta metode Simple Additive Weighting (SAW) untuk menentukan supplier terbaik berdasarkan beberapa kriteria. Dataset yang digunakan merupakan Indonesia E-Commerce Sales and Shipping Dataset 2023–2025 yang diperoleh dari Kaggle dengan jumlah data awal sebanyak 20.848 transaksi. Setelah melalui tahap *preprocessing*, diperoleh 16.239 data yang digunakan dalam proses klasifikasi. Kategori permintaan dibentuk menjadi tiga kelas, yaitu Low, Medium, dan High, menggunakan metode kuantil (*quantile*). Model Gaussian Naive Bayes dievaluasi menggunakan *confusion matrix* dengan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Hasil pengujian menunjukkan nilai *accuracy* sebesar 60,07%, *precision* 65,95%, *recall* 60,07%, dan *F1-score* 57,44%. Selanjutnya, hasil klasifikasi dimanfaatkan sebagai dasar dalam proses pemilihan supplier menggunakan metode SAW berdasarkan kriteria harga, ketepatan waktu pengiriman, kualitas, dan responsivitas. Hasil perhitungan SAW menunjukkan bahwa PT. Mahkota Bisnis memperoleh nilai preferensi tertinggi sebesar 0,9000, sehingga direkomendasikan sebagai supplier terbaik. Hasil penelitian menunjukkan bahwa integrasi Gaussian Naive Bayes dan SAW dapat mendukung proses pengambilan keputusan pengadaan barang secara lebih objektif dan sistematis.

Kata kunci— Gaussian Naive Bayes, Simple Additive Weighting, Klasifikasi Permintaan, Pemilihan Supplier, Pengadaan Barang.

Abstract— The procurement process requires sound decision-making to ensure the availability of goods in line with needs and the selection of suppliers capable of meeting the organization's criteria. Decision-making based solely on experience or subjective considerations has the potential to lead to inventory discrepancies or suboptimal supplier selection. This study aims to implement the Gaussian Naive Bayes algorithm to classify demand levels for goods and the Simple Additive Weighting (SAW) method to determine the best supplier based on several criteria. The dataset used is the Indonesia E-Commerce Sales and Shipping Dataset 2023–2025, obtained from Kaggle, with an initial dataset of 20,848 transactions. After preprocessing, 16,239 data points were used in the classification process. Demand categories were divided into three classes—Low, Medium, and High—using the quantile method. The Gaussian Naive Bayes model was evaluated using a confusion matrix with the metrics accuracy, precision, recall, and F1-score. Test results showed an accuracy of 60.07%, precision of 65.95%, recall of 60.07%, and an F1-score of 57.44%. Subsequently, the classification results were used as the basis for the supplier selection process using the SAW method based on the criteria of price, on-time delivery, quality, and responsiveness. The SAW calculation results showed that PT. Mahkota Bisnis obtained the highest preference score of 0.9000 and was therefore recommended as the best supplier. The research results indicate that the integration of the Gaussian Naive Bayes algorithm and the SAW method can support a more objective and systematic decision-making process for procurement.

Keywords— Gaussian Naive Bayes, Simple Additive Weighting, Demand Classification, Supplier Selection, Procurement.

I. PENDAHULUAN

Pengadaan barang merupakan salah satu proses penting dalam mendukung kelancaran operasional organisasi maupun perusahaan. Keputusan yang kurang tepat dalam menentukan jumlah kebutuhan barang maupun memilih supplier dapat menyebabkan terjadinya kelebihan

atau kekurangan persediaan, meningkatnya biaya operasional, serta menurunkan efisiensi rantai pasok. Oleh karena itu, proses pengadaan perlu didukung oleh pengambilan keputusan yang objektif dan berbasis data agar mampu meningkatkan efektivitas operasional serta meminimalkan risiko kesalahan dalam pemilihan supplier [1]. Seiring berkembangnya aktivitas

perdagangan elektronik (*e-commerce*), volume data transaksi yang dihasilkan terus meningkat dan menjadi sumber informasi yang bernilai dalam mendukung proses pengambilan keputusan berbasis data. Analisis terhadap data historis transaksi memungkinkan organisasi mengidentifikasi pola permintaan sehingga perencanaan pengadaan dapat dilakukan secara lebih efektif [2].

Salah satu aspek penting dalam proses pengadaan barang adalah kemampuan organisasi dalam memahami pola permintaan (*demand classification*) berdasarkan data historis transaksi. Informasi mengenai tingkat permintaan dapat digunakan sebagai dasar dalam menentukan jumlah persediaan yang optimal sehingga risiko *overstock* maupun *stockout* dapat diminimalkan [3]. Klasifikasi permintaan juga membantu organisasi dalam menyusun perencanaan pengadaan yang lebih efektif karena setiap kategori permintaan dapat ditangani dengan strategi yang berbeda sesuai karakteristik kebutuhan barang [4].

Berbagai penelitian telah menunjukkan bahwa algoritma *Naive Bayes* merupakan salah satu metode klasifikasi yang efektif untuk mengolah data historis dan menghasilkan informasi yang mendukung proses pengambilan keputusan. Algoritma ini bekerja berdasarkan Teorema Bayes dengan asumsi bahwa setiap atribut bersifat independen terhadap atribut lainnya, sehingga memiliki proses komputasi yang sederhana namun tetap mampu memberikan performa klasifikasi yang baik pada berbagai jenis data [4]. Pada penelitian ini digunakan varian *Gaussian Naive Bayes* karena mampu menangani atribut numerik yang mengikuti distribusi normal, sehingga sesuai dengan karakteristik dataset transaksi penjualan yang digunakan. Hasil klasifikasi permintaan yang diperoleh selanjutnya dimanfaatkan sebagai dasar dalam proses pemilihan supplier agar keputusan pengadaan tidak hanya mempertimbangkan kualitas supplier, tetapi juga mempertimbangkan tingkat permintaan barang yang diprediksi [5].

Selain ketepatan dalam mengklasifikasikan tingkat permintaan, proses pengadaan barang

juga memerlukan mekanisme yang objektif dalam menentukan supplier terbaik. Pemilihan supplier tidak dapat didasarkan hanya pada satu kriteria, seperti harga, tetapi perlu mempertimbangkan berbagai aspek lain, seperti kualitas produk, ketepatan waktu pengiriman, dan responsivitas supplier agar keputusan yang dihasilkan lebih optimal [6]. Salah satu metode *Multi-Criteria Decision Making* (MCDM) yang banyak digunakan untuk menyelesaikan permasalahan tersebut adalah *Simple Additive Weighting* (SAW). Metode SAW melakukan proses normalisasi nilai setiap alternatif berdasarkan bobot masing-masing kriteria sehingga menghasilkan nilai preferensi yang dapat digunakan sebagai dasar dalam menentukan supplier terbaik secara objektif dan terukur [7].

Berbagai penelitian sebelumnya telah menerapkan algoritma *Naive Bayes* untuk melakukan klasifikasi data penjualan maupun prediksi permintaan barang, sementara penelitian lainnya memanfaatkan metode *Simple Additive Weighting* (SAW) sebagai pendekatan dalam pemilihan supplier berdasarkan berbagai kriteria penilaian [4]. Namun, kedua metode tersebut umumnya masih diterapkan secara terpisah sehingga hasil klasifikasi permintaan belum dimanfaatkan sebagai dasar dalam proses pengambilan keputusan pemilihan supplier [6]. Berdasarkan permasalahan tersebut, penelitian ini mengimplementasikan algoritma *Gaussian Naive Bayes* untuk mengklasifikasikan tingkat permintaan barang dan mengintegrasikan hasil klasifikasi tersebut dengan metode *Simple Additive Weighting* (SAW) dalam proses pemilihan supplier pengadaan barang. Melalui pendekatan tersebut diharapkan proses pengambilan keputusan pengadaan dapat dilakukan secara lebih objektif, terstruktur, dan sesuai dengan tingkat permintaan barang.


II. METODOLOGI PENELITIAN

A. Tahapan Penelitian

Penelitian ini menerapkan pendekatan berbasis data-driven decision making untuk mendukung proses pengambilan keputusan pengadaan barang [8]. Tahapan penelitian dimulai dari

pengumpulan dataset transaksi penjualan, dilanjutkan dengan proses preprocessing untuk meningkatkan kualitas data, kemudian dilakukan feature engineering guna membentuk atribut yang lebih representatif terhadap pola permintaan. Selanjutnya dilakukan pembentukan label tingkat permintaan menjadi tiga kategori, yaitu Low, Medium, dan High, yang digunakan sebagai target klasifikasi.

Tahap berikutnya adalah proses pelatihan model menggunakan algoritma Gaussian Naive Bayes dengan skema pembagian data 80% data pelatihan dan 20% data pengujian. Kinerja model dievaluasi menggunakan Confusion Matrix, Accuracy, Precision, Recall, dan F1-Score. Hasil klasifikasi tingkat permintaan kemudian digunakan sebagai dasar simulasi proses pemilihan supplier menggunakan metode Simple Additive Weighting (SAW) berdasarkan empat kriteria penilaian, yaitu harga, kualitas, ketepatan waktu pengiriman, dan responsivitas supplier. Tahapan penelitian secara keseluruhan ditunjukkan pada Gambar 1.



Gambar 1. Tahapan Penelitian

B. Dataset

Penelitian ini menggunakan dataset transaksi penjualan yang diperoleh dari platform Kaggle dengan nama Indonesia E-Commerce Sales and Shipping Dataset 2023–2025. Dataset tersebut berisi informasi transaksi penjualan pada platform e-commerce di Indonesia yang mencakup berbagai atribut, seperti identitas produk, kategori produk, jumlah penjualan

(quantity), harga satuan (unit price), nilai transaksi, metode pembayaran, lokasi pelanggan, serta waktu transaksi. Dataset transaksi e-commerce dipilih karena merepresentasikan aktivitas penjualan yang mencerminkan pola historis permintaan barang, sehingga sesuai digunakan sebagai sumber data dalam proses klasifikasi tingkat permintaan. [9].

Dataset awal terdiri dari 20.848 data transaksi. Setelah dilakukan proses *preprocessing* untuk meningkatkan kualitas data, jumlah data yang digunakan dalam penelitian menjadi 16.239 data. Selanjutnya dilakukan proses *feature engineering* sehingga diperoleh 19 fitur yang digunakan sebagai atribut masukan (*input features*) pada proses klasifikasi menggunakan algoritma Gaussian Naive Bayes. Ringkasan karakteristik dataset yang digunakan dalam penelitian ditunjukkan pada Tabel 1.

Tabel 1 Karakteristik Dataset


Komponen	Keterangan
Nama Dataset	Indonesia E-Commerce Sales and Shipping 2023–2025
Sumber Dataset	Kaggle
Jumlah Data Awal	20.848 data
Jumlah Data Setelah <i>Preprocessing</i>	16.239 data
Jumlah Fitur	19
Target Klasifikasi	Low, Medium, High

Dataset ini dipilih karena memiliki informasi yang mampu merepresentasikan pola permintaan barang melalui aktivitas transaksi, pembayaran, pengiriman, dan karakteristik produk [9]. Informasi tersebut menjadi dasar dalam pembentukan fitur pada tahap feature engineering, yang selanjutnya digunakan untuk membangun model klasifikasi permintaan menggunakan algoritma Gaussian Naive Bayes.

C. Preprocessing

Tahap preprocessing dilakukan untuk meningkatkan kualitas data sebelum digunakan pada proses klasifikasi [10]. Proses ini bertujuan menghilangkan data yang tidak valid, menyeragamkan tipe data, serta memastikan kualitas dan konsistensi atribut sehingga data siap digunakan pada proses pelatihan algoritma Gaussian Naive Bayes [11]. Dataset awal terdiri dari 20.848 data transaksi, kemudian diproses

melalui beberapa tahapan hingga diperoleh 16.239 data yang layak digunakan sebagai data penelitian. Tahapan *preprocessing* yang dilakukan ditunjukkan pada Gambar 2.



Gambar 2 Tahapan Preprocessing Data.

Proses *preprocessing* diawali dengan pembacaan dataset berformat CSV dan validasi struktur data untuk memastikan kesesuaian atribut yang digunakan. Selanjutnya dilakukan konversi tipe data pada atribut tanggal menggunakan format *datetime* agar informasi waktu dapat diproses lebih lanjut, sedangkan atribut numerik dikonversi ke format numerik menggunakan mekanisme validasi untuk menghindari kesalahan pembacaan data. Tahap berikutnya adalah pembersihan data dengan mengganti nilai tak hingga (*infinity*) menjadi nilai kosong (*NaN*), kemudian menghapus seluruh baris yang masih memiliki nilai kosong pada atribut prediktor maupun variabel target. Selain itu, dilakukan validasi terhadap nilai target agar seluruh data dapat diproses sebagai data numerik. Berdasarkan proses tersebut, jumlah data berkurang dari 20.848 menjadi 16.239 data, sedangkan proses penghapusan data duplikat, normalisasi (*scaling*), *encoding*, maupun *feature scaling* tidak diterapkan karena tidak diperlukan pada implementasi penelitian ini.

Hasil dari tahap *preprocessing* berupa dataset yang telah bersih, konsisten, dan siap digunakan pada proses *feature engineering*. Dataset hasil *preprocessing* selanjutnya menjadi masukan utama dalam pembentukan fitur serta proses klasifikasi tingkat permintaan menggunakan algoritma Gaussian Naive Bayes.

D. Feature Engineering

Tahap *feature engineering* dilakukan untuk membentuk atribut baru yang lebih representatif terhadap pola permintaan barang sehingga dapat meningkatkan kemampuan model dalam proses klasifikasi [12]. Proses ini dilakukan dengan memanfaatkan informasi yang terdapat pada data transaksi untuk menghasilkan fitur-fitur yang memiliki nilai prediktif terhadap tingkat permintaan barang. Pada penelitian ini, *feature engineering* dilakukan setelah proses *preprocessing* dengan memanfaatkan informasi waktu transaksi, karakteristik produk, aktivitas pengiriman, serta nilai transaksi. Tujuan dari tahapan ini adalah meningkatkan kualitas atribut masukan sehingga model Gaussian Naive Bayes mampu mengenali pola permintaan barang secara lebih baik.

Proses pembentukan fitur dilakukan secara otomatis berdasarkan atribut yang tersedia pada dataset. Beberapa atribut baru diperoleh melalui ekstraksi informasi dari waktu transaksi, sedangkan atribut lainnya dibentuk menggunakan perhitungan rasio maupun kombinasi beberapa atribut transaksi. Hasil proses *feature engineering* menghasilkan 30 atribut, namun hanya 19 fitur prediktor yang dipilih sebagai variabel masukan (*input features*) pada proses pelatihan model. Variabel target (*demand category*) diperlakukan sebagai keluaran (*output*) sehingga tidak termasuk dalam himpunan fitur prediktor. Daftar fitur yang digunakan pada penelitian ini disajikan pada Tabel 3.

Tabel 2 Fitur Prediktor yang Digunakan pada Penelitian

No	Nama Fitur	Deskripsi
1	day_of_week	Hari transaksi dalam satu minggu
2	day_of_month	Tanggal transaksi dalam satu bulan
3	month	Bulan transaksi
4	quarter	Kuartal transaksi
5	hour_of_day	Jam transaksi
6	is_weekend	Indikator transaksi pada akhir pekan
7	num_product_categories	Jumlah kategori produk dalam satu transaksi
8	total_weight_gr	Total berat produk (gram)
9	total_returned_qty	Jumlah produk yang diretur

10	total_diskon	Total nilai diskon transaksi
11	ongkos_kirim_dibayar_pembeli	Biaya pengiriman yang dibayarkan pembeli
12	estimasi_potongan_biaya_pengiriman	Estimasi potongan biaya pengiriman
13	total_pembayaran	Total nilai pembayaran transaksi
14	perkiraan_ongkos_kirim	Estimasi biaya pengiriman
15	weight_per_item	Rata-rata berat setiap item
16	returned_ratio	Rasio jumlah barang yang diretur terhadap total pembelian
17	discount_ratio	Rasio nilai diskon terhadap total pembayaran
18	shipping_gap	Selisih antara estimasi dan biaya pengiriman aktual
19	payment_per_item	Rata-rata nilai pembayaran per item

Berdasarkan karakteristiknya, fitur-fitur tersebut dapat dikelompokkan menjadi lima kategori utama, yaitu fitur temporal, karakteristik produk, transaksi, logistik, dan rasio transaksi. Fitur temporal digunakan untuk menangkap pola permintaan berdasarkan waktu transaksi, sedangkan fitur karakteristik produk menggambarkan kompleksitas transaksi melalui jumlah kategori produk dan total berat barang. Fitur transaksi dan logistik merepresentasikan aspek finansial serta biaya distribusi yang berkaitan dengan aktivitas penjualan, sementara fitur rasio digunakan untuk menggambarkan hubungan antaratribut sehingga informasi yang diperoleh menjadi lebih representatif dibandingkan menggunakan data mentah secara langsung.

Pemilihan ke sembilan belas fitur prediktor tersebut didasarkan pada kemampuannya dalam merepresentasikan berbagai faktor yang berpotensi memengaruhi tingkat permintaan barang. Dengan memanfaatkan kombinasi informasi temporal, transaksi, logistik, dan karakteristik produk, model diharapkan mampu mengidentifikasi pola permintaan secara lebih akurat dibandingkan apabila hanya menggunakan atribut transaksi asli. Hasil dari tahap *feature engineering* selanjutnya digunakan sebagai masukan pada proses pembentukan label dan pelatihan model Gaussian Naive Bayes.

E. Pembentukan Label Permintaan (Demand Labeling)

Tahap pembentukan label dilakukan untuk mengubah nilai jumlah permintaan (*quantity*) menjadi variabel kategorikal yang digunakan sebagai target pada proses klasifikasi. Proses ini bertujuan agar algoritma Gaussian Naive Bayes dapat melakukan klasifikasi terhadap tingkat permintaan barang berdasarkan kategori yang telah ditentukan [13]. Variabel target yang digunakan pada penelitian ini adalah *total_qty*, yaitu jumlah barang yang terjual pada setiap transaksi. Sebelum proses pembentukan label, atribut *total_qty* dikonversi ke format numerik dan dilakukan validasi untuk menghapus data yang memiliki nilai kosong (*missing value*). Selanjutnya, pembentukan label dilakukan menggunakan fungsi *label_demand()* yang diimplementasikan pada pipeline pelatihan model.

Penentuan kategori permintaan dilakukan menggunakan pendekatan quantile dengan membagi distribusi data menjadi tiga kelompok berdasarkan nilai kuantil ke-33% (q_{33}) dan kuantil ke-66% (q_{66}). Berdasarkan hasil perhitungan pada dataset penelitian, diperoleh nilai $q_{33} = 1,0$ dan $q_{66} = 2,0$. Nilai tersebut kemudian digunakan sebagai batas interval untuk membentuk tiga kategori tingkat permintaan, yaitu Low, Medium, dan High. Aturan pembentukan kategori ditunjukkan pada Persamaan (1).

$$\text{Demand}(x) = \begin{cases} \text{Low}, & x \leq q_{33} \\ \text{Medium}, & q_{33} < x \leq q_{66} \\ \text{High}, & x > q_{66} \end{cases} \quad (1)$$

dengan:

- (x) = nilai *total_qty*,
- (q_{33}) = kuantil ke-33,
- (q_{66}) = kuantil ke-66.

Berdasarkan implementasi yang digunakan pada penelitian ini, nilai kuantil yang diperoleh adalah $q_{33} = 1,0$ dan $q_{66} = 2,0$, sehingga data dengan $\text{total_qty} \leq 1$ dikategorikan sebagai Low, data dengan $1 < \text{total_qty} \leq 2$ dikategorikan sebagai Medium, sedangkan data dengan $\text{total_qty} > 2$ dikategorikan sebagai High.

Distribusi data pada masing-masing kategori disajikan pada Tabel 3.

Tabel 3 Distribusi Kelas Permintaan

Kategori	Jumlah Data	Persentase
Low	9.564	58,89%
Medium	3.627	22,34%
High	3.048	18,77%
Total	16.239	100%

Pendekatan berbasis *quantile* dipilih karena mampu membentuk kategori berdasarkan distribusi aktual data, sehingga batas antar kelas tidak ditentukan secara subjektif. Dengan pendekatan ini, proses pembentukan label menjadi lebih adaptif terhadap karakteristik dataset serta menghasilkan kategori permintaan yang dapat digunakan sebagai target pada proses klasifikasi menggunakan algoritma Gaussian Naive Bayes.

F. Algoritma Gaussian Naive Bayes

Algoritma Gaussian Naive Bayes merupakan salah satu metode klasifikasi berbasis probabilitas yang menerapkan Teorema Bayes dengan asumsi bahwa setiap atribut bersifat saling independent [5]. Berbeda dengan Naive Bayes untuk data kategorikal, Gaussian Naive Bayes digunakan pada atribut numerik dengan mengasumsikan bahwa setiap fitur mengikuti distribusi normal (Gaussian) [14]. Pada penelitian ini, algoritma *Gaussian Naive Bayes* digunakan untuk mengklasifikasikan tingkat permintaan barang ke dalam tiga kategori, yaitu Low, Medium, dan High, berdasarkan fitur hasil *feature engineering*.

Probabilitas posterior suatu kelas dihitung menggunakan Teorema Bayes sebagaimana ditunjukkan pada Persamaan (2).

$$P(C_k|X) = \frac{P(X|C_k) \times P(C_k)}{P(X)} \quad (2)$$

dengan:

- $(P(C_k|X))$ = probabilitas posterior data (X) termasuk ke dalam kelas (C_k),
- $(P(X|C_k))$ = probabilitas kemunculan data (X) pada kelas(C_k),

- $(P(C_k))$ = probabilitas awal (*prior probability*) dari kelas(C_k),
- $(P(X))$ = probabilitas kemunculan data(X).

Karena seluruh atribut prediktor pada penelitian ini berupa data numerik, probabilitas setiap fitur dihitung menggunakan fungsi distribusi Gaussian sebagaimana ditunjukkan pada Persamaan (3).

$$P(x_i|C_k) = \frac{1}{\sqrt{2\pi\sigma_k^2}} \exp\left(-\frac{(x_i - \mu_k)^2}{2\sigma_k^2}\right) \quad (3)$$

dengan:

- (x_i) = nilai fitur ke-(i),
- (μ_k) = rata-rata fitur pada kelas(C_k),
- (σ_k^2) = varians fitur pada kelas(C_k).

Pada tahap implementasi, dataset hasil *preprocessing* dan *feature engineering* dibagi menggunakan metode hold-out dengan komposisi 80% data pelatihan dan 20% data pengujian. Sebanyak 12.991 data digunakan sebagai data pelatihan, sedangkan 3.248 data digunakan sebagai data pengujian. Model kemudian dilatih menggunakan algoritma Gaussian Naive Bayes dari pustaka *scikit-learn* dengan parameter bawaan (*default parameter*). Selanjutnya, model digunakan untuk memprediksi kategori permintaan pada data pengujian dan hasil prediksi dievaluasi menggunakan *Confusion Matrix*, *Accuracy*, *Precision*, *Recall*, dan *F1-Score*.

Tabel 4 Konfigurasi Pelatihan Gaussian Naive Bayes

Parameter	Nilai
Algoritma	Gaussian Naive Bayes
Library	scikit-learn (GaussianNB)
Jumlah Data	16.239
Data Pelatihan	12.991
Data Pengujian	3.248
Jumlah Fitur Prediktor	19
Variabel Target	<i>demand_category</i>
Jumlah Kelas	3 (Low, Medium, High)
Rasio Pembagian Data	80% : 20%
Parameter Model	Default

G. Evaluasi Model

Evaluasi model dilakukan untuk mengukur kemampuan algoritma Gaussian Naive Bayes dalam mengklasifikasikan tingkat permintaan

barang. Pada penelitian ini, evaluasi dilakukan menggunakan Confusion Matrix yang menghasilkan nilai Accuracy, Precision, Recall, dan F1-Score sebagai indikator performa model klasifikasi [15]. Matriks ini memberikan informasi mengenai jumlah prediksi yang benar maupun salah pada setiap kategori sehingga dapat digunakan untuk menganalisis performa model secara lebih rinci.

Berdasarkan nilai yang diperoleh dari *Confusion Matrix*, dilakukan perhitungan beberapa metrik evaluasi, yaitu Accuracy, Precision, Recall, dan F1-Score. Penggunaan beberapa metrik tersebut bertujuan memberikan gambaran yang lebih komprehensif terhadap kinerja model, khususnya pada dataset yang memiliki distribusi kelas yang tidak sepenuhnya seimbang [16].

Nilai Accuracy digunakan untuk mengukur proporsi keseluruhan prediksi yang berhasil diklasifikasikan dengan benar terhadap seluruh data pengujian. Nilai accuracy dihitung menggunakan Persamaan (4).

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

dengan:

- TP (True Positive) = jumlah data positif yang diprediksi benar;
- TN (True Negative) = jumlah data negatif yang diprediksi benar;
- FP (False Positive) = jumlah data negatif yang diprediksi sebagai positif;
- FN (False Negative) = jumlah data positif yang diprediksi sebagai negatif.

Selanjutnya, Precision digunakan untuk mengukur ketepatan model dalam memberikan prediksi pada suatu kelas. Semakin tinggi nilai precision, semakin kecil kemungkinan model menghasilkan prediksi positif yang salah. Precision dihitung menggunakan Persamaan (5).

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

Sementara itu, Recall digunakan untuk mengukur kemampuan model dalam menemukan seluruh data yang benar-benar termasuk ke dalam suatu kelas. Nilai recall dihitung menggunakan Persamaan (6).

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

Untuk memberikan penilaian yang lebih seimbang antara precision dan recall digunakan metrik F1-Score, yaitu rata-rata harmonik dari kedua metrik tersebut. Nilai F1-Score dihitung menggunakan Persamaan (7).

$$F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (7)$$

Keempat metrik evaluasi tersebut digunakan untuk memberikan gambaran menyeluruh mengenai performa model klasifikasi. Hasil pengukuran kemudian dianalisis pada bagian hasil dan pembahasan untuk mengetahui kemampuan algoritma *Gaussian Naive Bayes* dalam mengklasifikasikan tingkat permintaan barang berdasarkan data transaksi e-commerce.

H. Metode Simple Additive Weighting (SAW)

Metode Simple Additive Weighting (SAW) merupakan salah satu metode Multi-Criteria Decision Making (MCDM) yang digunakan untuk menentukan alternatif terbaik berdasarkan sejumlah kriteria yang telah diberikan bobot [7]. Metode ini melakukan proses normalisasi terhadap setiap nilai alternatif agar seluruh kriteria berada pada skala yang sama, kemudian menghitung nilai preferensi melalui penjumlahan terbobot dari seluruh kriteria [6].

Pada penelitian ini, metode SAW digunakan sebagai tahap lanjutan setelah proses klasifikasi permintaan menggunakan algoritma *Gaussian Naive Bayes*. Hasil klasifikasi digunakan sebagai dasar dalam proses pengadaan barang, sedangkan metode SAW digunakan untuk menentukan supplier yang paling sesuai berdasarkan beberapa kriteria evaluasi. Dengan demikian, penelitian ini tidak hanya menghasilkan informasi mengenai

tingkat permintaan barang, tetapi juga memberikan rekomendasi supplier yang dapat mendukung proses pengambilan keputusan pengadaan.

Kriteria yang digunakan pada proses pemilihan supplier terdiri atas empat aspek, yaitu harga, kualitas, ketepatan waktu pengiriman, dan responsivitas supplier. Supplier dengan nilai preferensi terbesar direkomendasikan sebagai alternatif terbaik dalam proses pengadaan barang karena memiliki tingkat kesesuaian paling tinggi terhadap seluruh kriteria yang digunakan [17]. Masing-masing kriteria diberikan bobot sesuai tingkat kepentingannya sebagaimana ditunjukkan pada Tabel 5.

Tabel 5 Kriteria dan Penilaian Supplier

Kriteria	Jenis	Bobot
Harga	Cost	35%
Kualitas	Benefit	30%
Ketepatan Waktu	Benefit	25%
Responsivitas	Benefit	10%

Tahap pertama dalam metode SAW adalah melakukan normalisasi terhadap nilai setiap alternatif agar seluruh kriteria berada pada skala yang sama. Untuk atribut bertipe *benefit*, normalisasi dilakukan menggunakan Persamaan (8), sedangkan atribut bertipe *cost* menggunakan Persamaan (9).

1. Atribut Benefit

$$r_{ij} = \frac{x_{ij}}{\max(x_{ij})} \quad (8)$$

2. Atribut Cost

$$r_{ij} = \frac{\min(x_{ij})}{x_{ij}} \quad (9)$$

dengan:

- $(r_{\{ij\}})$ = nilai hasil normalisasi alternatif ke-(i) pada kriteria ke-(j);
- $(x_{\{ij\}})$ = nilai awal alternatif ke-(i) pada kriteria ke-(j).

Setelah seluruh nilai dinormalisasi, dilakukan perhitungan nilai preferensi menggunakan penjumlahan terbobot sebagaimana ditunjukkan pada Persamaan (10).

$$V_i = \sum_{j=1}^n w_j r_{ij} \quad (10)$$

dengan:

- (V_i) = nilai preferensi alternatif ke-(i);
- (w_j) = bobot kriteria ke-(j);
- $(r_{\{ij\}})$ = nilai normalisasi alternatif ke-(i) pada kriteria ke-(j).

Alternatif supplier kemudian diurutkan berdasarkan nilai preferensi yang diperoleh. Supplier dengan nilai preferensi tertinggi direkomendasikan sebagai supplier terbaik karena memiliki tingkat kesesuaian paling tinggi terhadap seluruh kriteria yang digunakan. Pada penelitian ini, proses perhitungan SAW dilakukan menggunakan empat kriteria dengan bobot masing-masing sebesar 35% untuk harga, 30% untuk kualitas, 25% untuk ketepatan waktu pengiriman, dan 10% untuk responsivitas supplier. Hasil perhitungan metode SAW selanjutnya dianalisis pada bagian hasil dan pembahasan untuk menunjukkan proses perankingan supplier berdasarkan nilai preferensi yang diperoleh.

Tahapan metode SAW yang telah dijelaskan menjadi dasar dalam proses simulasi pemilihan supplier pada penelitian ini. Hasil perhitungan nilai preferensi setiap alternatif kemudian digunakan untuk menyusun peringkat supplier sebagai bahan pendukung pengambilan keputusan pengadaan barang.

III. HASIL DAN PEMBAHASAN

A. Hasil Preprocessing Data

Tahap *preprocessing* dilakukan untuk meningkatkan kualitas dataset sebelum digunakan pada proses pelatihan model *Gaussian Naive Bayes*. Proses ini meliputi validasi tipe data, konversi atribut numerik dan tanggal, penanganan nilai tidak valid, serta penghapusan data yang memiliki *missing value*. Setelah seluruh tahapan *preprocessing* selesai dilakukan, diperoleh dataset yang telah memenuhi kebutuhan proses *feature engineering* dan klasifikasi.

Hasil *preprocessing* menunjukkan bahwa jumlah data mengalami pengurangan dari 20.848 data menjadi 16.239 data. Pengurangan tersebut terjadi karena terdapat data yang tidak memenuhi kriteria validasi sehingga dihapus dari dataset. Ringkasan hasil *preprocessing* disajikan pada Tabel 6.

Tabel 6 Hasil Preprocessing Data


Keterangan	Jumlah
Jumlah Data Awal	20.848
Jumlah Data Setelah <i>Preprocessing</i>	16.239
Data yang Dihapus	4.609

Setelah proses *preprocessing*, dilakukan pembentukan label permintaan (*demand category*) menggunakan pendekatan *quantile* sehingga diperoleh tiga kategori kelas, yaitu Low, Medium, dan High. Distribusi jumlah data pada setiap kategori ditunjukkan pada Tabel 7.

Tabel 7 Distribusi Kelas Permintaan

Kategori	Jumlah Data	Persentase
Low	9.564	58,89%
Medium	3.627	22,34%
High	3.048	18,77%
Total	16.239	100%

Berdasarkan distribusi kelas pada Tabel 7, kategori Low memiliki jumlah data paling banyak, yaitu 58,89% dari keseluruhan dataset, sedangkan kategori High memiliki jumlah data paling sedikit, yaitu 18,77%. Perbedaan distribusi tersebut menunjukkan bahwa data penelitian tidak sepenuhnya seimbang (*imbalanced*), sehingga evaluasi model tidak hanya menggunakan nilai *accuracy*, tetapi juga *precision*, *recall*, dan *F1-score* untuk memperoleh gambaran performa klasifikasi yang lebih komprehensif.



Gambar 3 Analisis Data Distribusi

Gambar 3 menunjukkan bahwa distribusi kelas permintaan didominasi oleh kategori Low, sedangkan kategori High memiliki proporsi paling kecil. Kondisi ini mengindikasikan bahwa dataset memiliki distribusi kelas yang tidak sepenuhnya seimbang. Oleh karena itu, pada tahap evaluasi model tidak hanya digunakan metrik *accuracy*, tetapi juga *precision*, *recall*, dan *F1-score* untuk memperoleh penilaian yang lebih komprehensif terhadap kemampuan model dalam mengklasifikasikan setiap kategori permintaan.

B. Hasil Klasifikasi Menggunakan Gaussian Naive Bayes

1. Pembagian Data *Training* dan *Testing*

Setelah proses *preprocessing* dan *feature engineering* selesai dilakukan, dataset dibagi menjadi dua bagian menggunakan metode *hold-out*, yaitu data pelatihan (*training data*) dan data pengujian (*testing data*). Pembagian data dilakukan dengan rasio 80% : 20%, di mana sebanyak 12.991 data digunakan untuk melatih model *Gaussian Naive Bayes*, sedangkan 3.248 data digunakan untuk menguji kemampuan model dalam mengklasifikasikan tingkat permintaan pada data yang belum pernah dipelajari sebelumnya.

Pembagian data dengan rasio 80% : 20% dipilih untuk memberikan jumlah data pelatihan yang cukup bagi model dalam mempelajari pola dari setiap kategori permintaan, sekaligus menyediakan data pengujian yang representatif untuk mengevaluasi kemampuan generalisasi model. Ringkasan pembagian data disajikan pada Tabel 8.

Tabel 8 Pembagian Data Pelatihan dan Pengujian


Jenis Data	Jumlah	Persentase
Data Pelatihan (<i>Training</i>)	12.991	80%
Data Pengujian (<i>Testing</i>)	3.248	20%
Total	16.239	100%

Data pelatihan digunakan untuk membangun model klasifikasi menggunakan algoritma *Gaussian Naive*

Bayes, sedangkan data pengujian digunakan untuk mengukur performa model melalui *Confusion Matrix*, *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Hasil evaluasi tersebut menjadi dasar dalam menilai kemampuan model untuk mengklasifikasikan tingkat permintaan barang pada dataset penelitian.

2. Hasil Confusion Matrix

Setelah model *Gaussian Naive Bayes* dilatih menggunakan data pelatihan, langkah berikutnya adalah melakukan prediksi terhadap data pengujian yang berjumlah 3.248 data. Hasil prediksi kemudian dibandingkan dengan label sebenarnya menggunakan *Confusion Matrix* untuk mengetahui jumlah prediksi yang benar maupun yang salah pada setiap kategori permintaan. Visualisasi hasil *Confusion Matrix* ditunjukkan pada Gambar 4.



Gambar 4 Confusion Matrix Gaussian Naive Bayes

Berdasarkan Gambar 4, model berhasil mengklasifikasikan 1.568 data kategori Low dengan benar. Namun, masih terdapat 344 data kategori Low yang diprediksi sebagai Medium, serta 1 data yang diprediksi sebagai High. Hasil tersebut menunjukkan bahwa model memiliki kemampuan yang cukup baik dalam mengenali kategori Low, meskipun masih terdapat sebagian kecil kesalahan klasifikasi.

Pada kategori Medium, model berhasil mengklasifikasikan 312 data dengan benar. Akan tetapi, sebanyak 401 data diprediksi sebagai Low dan 12 data diprediksi sebagai High. Hal ini menunjukkan bahwa karakteristik data pada kategori Medium masih memiliki kemiripan dengan kategori Low, sehingga model lebih sering mengklasifikasikan data tersebut ke dalam kelas Low.

Sementara itu, kategori High merupakan kelas dengan performa prediksi terendah. Dari 610 data kategori High, model hanya mampu mengklasifikasikan 71 data dengan benar, sedangkan 377 data diprediksi sebagai Medium dan 162 data diprediksi sebagai Low. Kondisi ini mengindikasikan bahwa pola karakteristik kategori High belum dapat dipelajari secara optimal oleh model sehingga sebagian besar data masih mengalami kesalahan klasifikasi.

Secara keseluruhan, *Confusion Matrix* menunjukkan bahwa model memiliki kemampuan yang baik dalam mengenali kategori Low, namun masih mengalami kesulitan dalam membedakan kategori Medium dan High. Hal tersebut terlihat dari tingginya jumlah kesalahan prediksi pada kedua kategori tersebut, terutama kecenderungan data High yang diprediksi sebagai Medium. Oleh karena itu, diperlukan evaluasi lebih lanjut menggunakan metrik *Accuracy*, *Precision*, *Recall*, dan *F1-Score* untuk memperoleh gambaran performa model secara lebih komprehensif.

3. Hasil Evaluasi Model

Setelah dilakukan pengujian menggunakan data *testing*, performa model *Gaussian Naive Bayes* dievaluasi menggunakan empat metrik utama, yaitu *Accuracy*, *Precision*, *Recall*, dan *F1-Score*. Keempat metrik tersebut dipilih untuk memberikan gambaran yang lebih menyeluruh mengenai kemampuan model dalam mengklasifikasikan tingkat permintaan barang, terutama karena

distribusi data pada setiap kelas tidak sepenuhnya seimbang. Hasil evaluasi model disajikan pada Tabel 9.

Tabel 9 Hasil Evaluasi Model Gaussian Naive Bayes

Metrik	Nilai
Accuracy	60,07%
Precision (Weighted Avg.)	65,95%
Recall (Weighted Avg.)	60,07%
F1-Score (Weighted Avg.)	57,44%

Berdasarkan Tabel 9, model *Gaussian Naive Bayes* memperoleh nilai accuracy sebesar 60,07%, yang menunjukkan bahwa model berhasil mengklasifikasikan 1.951 dari 3.248 data pengujian dengan benar. Hasil tersebut menunjukkan bahwa model mampu mengenali pola permintaan pada sebagian besar data, meskipun masih terdapat kesalahan klasifikasi pada beberapa kategori.

Performa tersebut menunjukkan bahwa *Gaussian Naive Bayes* mampu mempelajari pola umum pada data transaksi, namun masih mengalami keterbatasan dalam membedakan kelas yang memiliki karakteristik serupa. Hal ini disebabkan oleh prinsip kerja *Gaussian Naive Bayes* yang mengasumsikan independensi antar fitur serta distribusi *Gaussian* pada setiap fitur dalam masing-masing kelas. Ketika distribusi data antar kelas saling tumpang tindih (*overlapping*), probabilitas posterior yang dihasilkan menjadi kurang mampu memisahkan setiap kelas secara optimal. Kondisi tersebut menyebabkan meningkatnya kesalahan klasifikasi, khususnya pada kategori Medium dan High.

Nilai precision sebesar 65,95% menunjukkan bahwa sebagian besar hasil prediksi yang diberikan model telah sesuai dengan kelas sebenarnya. Sementara itu, nilai recall sebesar 60,07% menunjukkan kemampuan model dalam menemukan kembali data pada setiap kategori permintaan. Adapun F1-Score sebesar 57,44% menunjukkan keseimbangan antara nilai *precision* dan *recall*, sehingga

memberikan gambaran performa model secara lebih komprehensif.

Analisis yang lebih rinci terhadap performa model pada setiap kategori permintaan ditunjukkan melalui *Classification Report* pada Tabel 10.

Tabel 10 Classification Report Gaussian Naive Bayes

Kelas	Precision	Recall	F1-Score	Support
Low	0,73	0,82	0,77	1.913
Medium	0,30	0,43	0,35	725
High	0,85	0,12	0,21	610
Accuracy			0,60	3.248
Macro Average	0,63	0,46	0,44	3.248
Weighted Average	0,66	0,60	0,57	3.248

Berdasarkan Tabel 10, model menunjukkan performa terbaik pada kategori Low, dengan nilai *precision* sebesar 0,73, *recall* sebesar 0,82, dan *F1-Score* sebesar 0,77. Hal ini menunjukkan bahwa model mampu mengenali sebagian besar data pada kategori Low dengan tingkat ketepatan yang baik.

Sebaliknya, performa model pada kategori Medium dan High masih relatif rendah. Kategori Medium memperoleh nilai *F1-Score* sebesar 0,35, sedangkan kategori High hanya memperoleh nilai *F1-Score* sebesar 0,21. Meskipun kategori High memiliki nilai *precision* yang tinggi (0,85), nilai *recall*-nya hanya 0,12, yang menunjukkan bahwa model hanya berhasil mengidentifikasi sebagian kecil data yang benar-benar termasuk dalam kategori tersebut. Kondisi ini sejalan dengan hasil *Confusion Matrix*, di mana sebagian besar data kategori High diprediksi sebagai kategori Medium.

Secara keseluruhan, hasil evaluasi menunjukkan bahwa algoritma *Gaussian Naive Bayes* memiliki kemampuan yang baik dalam mengklasifikasikan kategori permintaan yang dominan, yaitu Low, namun masih mengalami keterbatasan dalam membedakan kategori Medium dan High. Hal tersebut mengindikasikan bahwa karakteristik antar kelas masih memiliki

tingkat kemiripan yang cukup tinggi, sehingga memengaruhi kemampuan model dalam melakukan klasifikasi secara akurat. Meskipun demikian, hasil klasifikasi yang diperoleh telah mampu memberikan dasar yang memadai untuk digunakan sebagai masukan pada tahap selanjutnya, yaitu proses pemilihan supplier menggunakan metode *Simple Additive Weighting* (SAW).

C. Hasil Pemilihan Supplier Menggunakan Metode SAW

1. Matriks Keputusan

Setelah proses klasifikasi tingkat permintaan menggunakan algoritma *Gaussian Naive Bayes* selesai dilakukan, tahap berikutnya adalah melakukan simulasi pemilihan supplier menggunakan metode *Simple Additive Weighting* (SAW). Metode ini digunakan sebagai teknik pendukung keputusan untuk menentukan supplier terbaik berdasarkan beberapa kriteria yang telah ditetapkan. Dalam penelitian ini, hasil klasifikasi permintaan menjadi dasar dalam proses pengadaan barang, sedangkan metode SAW digunakan untuk mengevaluasi alternatif supplier yang tersedia.

Proses evaluasi dilakukan terhadap tiga alternatif supplier, yaitu PT. Mahkota Bisnis, PT. Graha Persada, dan PT. Berkah Bersama. Masing-masing supplier dinilai berdasarkan empat kriteria, yaitu Harga (C1), Ketepatan Waktu Pengiriman (C2), Kualitas (C3), dan Responsivitas (C4). Bobot setiap kriteria mengacu pada tingkat kepentingannya dalam proses pengadaan barang, yaitu 35% untuk Harga, 25% untuk Ketepatan Waktu Pengiriman, 30% untuk Kualitas, dan 10% untuk Responsivitas.

Nilai awal setiap supplier terhadap seluruh kriteria disusun dalam bentuk matriks keputusan. Matriks ini menjadi dasar dalam proses normalisasi pada metode SAW. Hasil matriks keputusan ditunjukkan pada Tabel 11.

Tabel 11 Matriks Keputusan Supplier

Supplier	Harga	Ketepatan Waktu Pengiriman	Kualitas	Responsivitas
PT. Mahkota Bisnis	700.000	100	100,00	100
PT. Graha Persada	500.000	1	66,67	100
PT. Berkah Bersama	3.000.000	30	100,00	100

Berdasarkan Tabel 11, setiap supplier memiliki karakteristik yang berbeda pada masing-masing kriteria. PT. Graha Persada menawarkan harga paling rendah, sedangkan PT. Mahkota Bisnis memiliki nilai tertinggi pada aspek ketepatan waktu pengiriman dan kualitas. Adapun PT. Berkah Bersama memiliki kualitas yang baik, namun menawarkan harga yang relatif lebih tinggi dibandingkan supplier lainnya. Perbedaan nilai pada setiap kriteria tersebut menjadi dasar dalam proses normalisasi agar seluruh atribut dapat dibandingkan pada skala yang sama.

2. Hasil Normalisasi Matriks Keputusan

Tahap selanjutnya adalah melakukan normalisasi terhadap matriks keputusan. Proses normalisasi bertujuan untuk mengubah seluruh nilai kriteria ke dalam skala yang seragam sehingga dapat dibandingkan secara objektif. Pada penelitian ini, kriteria Harga diperlakukan sebagai atribut *cost*, sedangkan Ketepatan Waktu Pengiriman, Kualitas, dan Responsivitas diperlakukan sebagai atribut *benefit*.

Hasil normalisasi matriks keputusan disajikan pada Tabel 12.

Tabel 12 Hasil Normalisasi Matriks Keputusan

Supplier	Harga	Ketepatan Waktu Pengiriman	Kualitas	Responsivitas
PT. Mahkota Bisnis	0,7143	1,0000	1,0000	1,0000
PT. Graha Persada	1,0000	0,0100	0,6667	1,0000
PT. Berkah Bersama	0,1667	0,3000	1,0000	1,0000

Berdasarkan hasil normalisasi pada Tabel 12, PT. Graha Persada memperoleh nilai tertinggi pada kriteria Harga karena menawarkan biaya terendah. Sebaliknya, PT. Mahkota Bisnis memperoleh nilai maksimum pada kriteria Ketepatan Waktu Pengiriman, Kualitas, dan Responsivitas, sehingga menunjukkan keunggulan pada aspek pelayanan dan mutu. Hasil normalisasi ini kemudian digunakan sebagai dasar dalam perhitungan nilai preferensi setiap supplier.

3. Hasil Perhitungan Nilai Preferensi dan Ranking Supplier


Setelah seluruh nilai dinormalisasi, tahap berikutnya adalah menghitung nilai preferensi setiap alternatif supplier menggunakan bobot pada masing-masing kriteria. Nilai preferensi diperoleh melalui penjumlahan hasil perkalian antara bobot kriteria dengan nilai normalisasi. Supplier dengan nilai preferensi terbesar dipilih sebagai alternatif terbaik dalam proses pengadaan barang.

Hasil perhitungan nilai preferensi dan peringkat supplier ditunjukkan pada Tabel 13.

Tabel 13 Hasil Perhitungan Nilai Preferensi dan Ranking Supplier

Ranking	Supplier	Nilai Preferensi
1	PT. Mahkota Bisnis	0,9000
2	PT. Graha Persada	0,6525
3	PT. Berkah Bersama	0,5333

Untuk mempermudah interpretasi hasil, nilai preferensi setiap supplier divisualisasikan menggunakan diagram batang sebagaimana ditunjukkan pada Gambar 5.



Gambar 5 Grafik Ranking Supplier Metode SAW

Berdasarkan Tabel 13 dan Gambar 5, PT. Mahkota Bisnis memperoleh nilai preferensi tertinggi sebesar 0,9000, sehingga direkomendasikan sebagai supplier terbaik. Meskipun tidak menawarkan harga paling rendah, supplier ini memiliki performa yang sangat baik pada aspek Ketepatan Waktu Pengiriman, Kualitas, dan Responsivitas, yang merupakan kriteria dengan bobot besar dalam proses penilaian.

Sementara itu, PT. Graha Persada menempati peringkat kedua dengan nilai preferensi 0,6525. Walaupun memiliki harga paling kompetitif, nilai yang rendah pada aspek ketepatan waktu pengiriman menyebabkan nilai akhirnya berada di bawah PT. Mahkota Bisnis. Adapun PT. Berkah Bersama memperoleh nilai preferensi 0,5333 dan berada pada peringkat ketiga karena harga yang relatif tinggi serta nilai ketepatan waktu pengiriman yang lebih rendah dibandingkan alternatif lainnya.

Hasil tersebut menunjukkan bahwa metode SAW mampu memberikan rekomendasi supplier secara objektif berdasarkan kombinasi seluruh kriteria yang telah ditentukan. Dengan mempertimbangkan bobot masing-masing kriteria, metode ini menghasilkan peringkat supplier yang dapat digunakan sebagai pendukung pengambilan keputusan dalam proses pengadaan barang.

D. Pembahasan

1. Analisis Hasil Gaussian Naive Bayes

Hasil evaluasi menunjukkan bahwa algoritma *Gaussian Naive Bayes* memperoleh nilai *accuracy* sebesar 60,07%, dengan nilai *precision*, *recall*, dan *F1-score* berturut-turut sebesar 65,95%, 60,07%, dan 57,44%. Nilai tersebut menunjukkan bahwa model telah mampu mengenali pola permintaan barang pada sebagian besar data pengujian, meskipun performanya masih berbeda pada setiap kategori permintaan.

Berdasarkan *Confusion Matrix* dan *Classification Report*, model memberikan performa terbaik pada kategori Low, yang memiliki nilai *recall* sebesar 82% dan *F1-score* sebesar 0,77. Hal ini menunjukkan bahwa sebagian besar data dengan tingkat permintaan rendah berhasil diklasifikasikan dengan benar. Sebaliknya, kategori High memiliki nilai *recall* yang rendah (12%), sehingga sebagian besar data pada kategori tersebut masih diprediksi sebagai kategori Medium maupun Low.

Perbedaan performa antar kelas tersebut menunjukkan bahwa karakteristik data pada kategori Medium dan High masih memiliki pola yang saling berdekatan. Selain itu, distribusi data yang didominasi oleh kategori Low turut memengaruhi kemampuan model dalam mempelajari karakteristik kelas dengan jumlah data yang lebih sedikit. Kondisi tersebut menyebabkan model lebih sering memberikan prediksi pada kelas yang memiliki jumlah data dominan.

Meskipun demikian, hasil klasifikasi yang diperoleh masih mampu memberikan informasi mengenai tingkat permintaan barang sebagai dasar dalam proses pengambilan keputusan pengadaan. Oleh karena itu, hasil prediksi dari algoritma *Gaussian Naive Bayes* tetap dapat dimanfaatkan sebagai masukan pada tahap pemilihan supplier menggunakan metode SAW.

2. Analisis Hasil Metode SAW

Berdasarkan hasil perhitungan metode SAW, PT. Mahkota Bisnis memperoleh nilai preferensi tertinggi sebesar 0,9000, sehingga direkomendasikan sebagai supplier terbaik. Nilai tersebut diperoleh karena supplier memiliki performa yang sangat baik pada kriteria Ketepatan Waktu Pengiriman, Kualitas, dan Responsivitas, yang secara keseluruhan memberikan kontribusi besar terhadap nilai akhir preferensi.

Sebaliknya, PT. Graha Persada memperoleh nilai maksimum pada kriteria Harga, namun memiliki nilai yang sangat rendah pada aspek Ketepatan Waktu Pengiriman. Akibatnya, meskipun menawarkan harga yang paling kompetitif, supplier tersebut hanya menempati peringkat kedua dengan nilai preferensi 0,6525. Adapun PT. Berkah Bersama berada pada peringkat ketiga karena memiliki harga yang relatif tinggi sehingga memengaruhi nilai preferensi akhirnya.

Hasil tersebut menunjukkan bahwa metode SAW mampu memberikan proses evaluasi yang lebih objektif karena keputusan tidak hanya didasarkan pada satu kriteria, melainkan mempertimbangkan seluruh kriteria sesuai bobot yang telah ditentukan. Dengan demikian, supplier yang dipilih merupakan alternatif yang memiliki keseimbangan terbaik terhadap seluruh aspek penilaian.

3. Implikasi Penelitian

Hasil penelitian menunjukkan bahwa kombinasi algoritma *Gaussian Naive Bayes* dan metode *Simple Additive Weighting* dapat digunakan sebagai pendekatan dalam mendukung proses pengambilan keputusan pengadaan barang. Algoritma *Gaussian Naive Bayes* berperan dalam mengklasifikasikan tingkat permintaan barang berdasarkan data historis transaksi, sedangkan metode SAW digunakan untuk menentukan supplier terbaik berdasarkan beberapa kriteria evaluasi.

Integrasi kedua metode tersebut memberikan alur pengambilan keputusan yang lebih sistematis, dimulai dari identifikasi tingkat permintaan hingga pemilihan supplier yang paling sesuai. Pendekatan ini dapat membantu proses pengadaan menjadi lebih terarah karena keputusan yang diambil tidak hanya mempertimbangkan kondisi permintaan barang, tetapi juga kualitas alternatif supplier yang tersedia.

Meskipun demikian, penelitian ini masih memiliki beberapa keterbatasan. Nilai *accuracy* model klasifikasi menunjukkan bahwa masih terdapat ruang untuk meningkatkan performa algoritma, khususnya dalam membedakan kategori Medium dan High. Selain itu, proses pemilihan supplier pada penelitian ini menggunakan empat kriteria penilaian sehingga pada penelitian selanjutnya dapat dipertimbangkan penambahan kriteria lain, seperti kapasitas produksi, fleksibilitas pengiriman, atau tingkat risiko supplier untuk menghasilkan rekomendasi yang lebih komprehensif.

IV. KESIMPULAN

Penelitian ini berhasil mengimplementasikan algoritma *Gaussian Naive Bayes* untuk mengklasifikasikan tingkat permintaan barang serta metode *Simple Additive Weighting* (SAW) untuk melakukan pemilihan supplier pada proses pengadaan barang. Tahapan penelitian meliputi *preprocessing* data, *feature engineering*, proses pelatihan dan pengujian model klasifikasi, evaluasi menggunakan *Confusion Matrix*, serta perankingan supplier berdasarkan beberapa kriteria penilaian.

Hasil pengujian menunjukkan bahwa model *Gaussian Naive Bayes* memperoleh nilai *accuracy* sebesar 60,07%, *precision* sebesar 65,95%, *recall* sebesar 60,07%, dan *F1-score* sebesar 57,44%. Model menunjukkan performa yang baik dalam mengklasifikasikan kategori permintaan Low, namun masih mengalami kesulitan dalam membedakan kategori Medium dan High. Meskipun demikian, hasil klasifikasi yang diperoleh telah mampu memberikan informasi mengenai tingkat permintaan barang yang dapat dimanfaatkan sebagai dasar dalam proses pengadaan.

Berdasarkan hasil perhitungan metode SAW, PT. Mahkota Bisnis memperoleh nilai preferensi tertinggi sebesar 0,9000, sehingga direkomendasikan sebagai supplier terbaik. Hasil tersebut menunjukkan bahwa metode SAW mampu memberikan proses pemilihan supplier secara objektif dengan mempertimbangkan

seluruh kriteria sesuai bobot yang telah ditentukan. Dengan demikian, kombinasi algoritma *Gaussian Naive Bayes* dan metode SAW dapat digunakan sebagai pendekatan untuk mendukung proses pengambilan keputusan pada pengadaan barang.

Sebagai pengembangan pada penelitian selanjutnya, performa klasifikasi dapat ditingkatkan dengan membandingkan algoritma *Gaussian Naive Bayes* dengan algoritma klasifikasi lainnya, seperti *Random Forest*, *Support Vector Machine*, atau *Extreme Gradient Boosting* (XGBoost). Selain itu, metode SAW juga dapat dikembangkan dengan menambahkan kriteria penilaian supplier atau dibandingkan dengan metode *Multi-Criteria Decision Making* (MCDM) lainnya untuk memperoleh hasil rekomendasi yang lebih komprehensif.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Allah SWT atas rahmat dan karunia-Nya sehingga penelitian ini dapat diselesaikan dengan baik. Penulis juga menyampaikan apresiasi kepada dosen pembimbing yang telah memberikan arahan, masukan, dan bimbingan selama proses penelitian. Ucapan terima kasih disampaikan kepada Program Studi Sistem Informasi Universitas Duta Bangsa Surakarta atas dukungan akademik yang diberikan selama penyusunan penelitian ini. Selain itu, penulis mengucapkan terima kasih kepada penyedia dataset Indonesia E-Commerce Sales and Shipping 2023–2025 yang digunakan sebagai sumber data dalam penelitian ini, serta kepada semua pihak yang telah memberikan dukungan dan bantuan sehingga penelitian ini dapat terselesaikan.

REFERENSI

- [1] B. R. Aditama *et al.*, "Sistem Penunjang Keputusan Pemilihan Pemasok Gula Merah Menggunakan Simple Additive Weighting dan Weighted Product," vol. 8, pp. 779–792, 2024.
- [2] P. S. Informatika *et al.*, "Sistem Informasi Prediksi Penjualan E-Commerce Menggunakan Analisis Data Historis dan Algoritma," vol. 1, no. 2021, pp. 893–900, 2023.
- [3] F. D. Wulandari *et al.*, "Evaluating Entropy-Based Feature Selection for Sales Demand Forecasting Using K-Means Clustering and Naive Bayes Classification," vol. 8, no. 2, pp. 387–396, 2025.
- [4] I. M. Sumual, J. Supriadi, E. Effendy, and A. Wijaya, "KLASIFIKASI KATEGORI PRODUK TERLARIS PADA

- E-COMMERCE,” vol. 5, no. 2, pp. 51–60.
- [5] R. Blanquero, E. Carrizosa, and P. Ramírez-cobo, “Computers and Operations Research Variable selection for Naïve Bayes classification,” *Comput. Oper. Res.*, vol. 135, p. 105456, 2021, doi: 10.1016/j.cor.2021.105456.
- [6] P. D. Mardika and A. Fauzi, “SUPPLIER TERBAIK DENGAN METODE SIMPLE ADDITIVE WEIGHT (SAW),” vol. 12, no. 1, pp. 677–682, 2024.
- [7] Y. Muhyidin, T. I. Hermanto, Y. R. Ramadhan, D. Irmayanti, and M. A. Permana, “Implementation of the Simple Additive Weighting (SAW) Method for Supplier Selection,” vol. 5, no. 1, 2024.
- [8] R. Kumar, “Data-Driven Decision Making in Supply Chain Management,” *Innov. Res. Thought*, no. December, pp. 265–281, 2023, [Online]. Available: <https://irt.shodhsagar.com/index.php/j/article/view/1487>
- [9] X. Zhang, F. Guo, T. Chen, L. Pan, G. Beliakov, and J. Wu, “A Brief Survey of Machine Learning and Deep Learning Techniques for E-Commerce Research,” pp. 2188–2216, 2023.
- [10] T. Emmanuel, T. Maupong, D. Mpoeleng, T. Semong, and B. Mphago, *A survey on missing data in machine learning*. Springer International Publishing, 2021. doi: 10.1186/s40537-021-00516-9.
- [11] F. Pedregosa, R. Weiss, and M. Brucher, “Scikit-learn : Machine Learning in Python,” vol. 12, pp. 2825–2830, 2011.
- [12] B. Practices, “Data Preprocessing and Feature Engineering for Data Mining :,” 2025.
- [13] S. Developers, “Scikit Learn,” scikit-learn User Guide. [Online]. Available: https://scikit-learn.org/stable/modules/naive_bayes.html
- [14] M. V. Anand, B. Kiranbala, S. R. Srividhya, C. Kavitha, and M. Younus, “Gaussian Naïve Bayes Algorithm : A Reliable Technique Involved in the Assortment of the Segregation in Cancer,” vol. 2022, 2022, doi: 10.1155/2022/2436946.
- [15] S. Sathyanarayanan and B. R. Tantri, “Confusion Matrix-Based Performance Evaluation Metrics,” vol. 27, no. 4, 2024.
- [16] G. Zeng, “Invariance Properties and Evaluation Metrics Derived from the Confusion Matrix in Multiclass Classification,” no. 1997, 2025.
- [17] D. Rusvinasari, A. Hantoro, R. J. Permana, and J. T. Yudhistira, “SUPPLIER TERBAIK DENGAN METODE SIMPLE ADDITIVE WEIGHTING (SAW) BERBASIS WEBSITE,” pp. 28–39, 2024.