
PENERAPAN ALGORITMA NAÏVE BAYES DALAM MENGOPTIMALKAN MANAJEMEN INVENTORI PADA PT SOALA GOGO NATAMA

**Andriyan Jonatan Matondang¹, Eben Ezer Seluya Malau², Siti Aisyah³ Amalia⁴,
Muhammad Radhi⁵**

PUI PT Inovasi Teknologi Ilmu Komputer Universitas Prima Indonesia, Medan
e-mail: siti_aisyah@unprimdn.ac.id

Abstract: *The advancement of information technology has encouraged companies to manage data more effectively in decision-making processes, including inventory management. Problems such as overstock, deadstock, and stockout frequently occur due to the lack of data-driven management based on historical transactions. This study aims to analyze and classify inventory demand levels using the Naïve Bayes algorithm to optimize inventory management at PT Soala Gogo Natama. This research employs a quantitative descriptive method with a case study approach. The dataset consists of 300 observations divided into training data (210) and testing data (90) with 9 variables. The analysis process includes data preprocessing, implementation of the Gaussian Naïve Bayes algorithm using Python, and model evaluation using accuracy, confusion matrix, and classification report. The results indicate that the model successfully classifies data into three categories: low, medium, and high, with an accuracy of 78.89%. Model evaluation shows good performance in the low and high classes, while misclassification occurs in the medium class due to overlapping characteristics between classes. This suggests that the model is effective in identifying data patterns but has limitations when handling data with similar distributions. In conclusion, the Naïve Bayes algorithm is effective in supporting inventory management decision-making, particularly in determining stock priorities based on historical data.*

Keywords : *Naïve Bayes, inventory management, classification, data mining, inventory prediction.*

Abstrak: Perkembangan teknologi informasi mendorong perusahaan untuk mengelola data secara lebih efektif dalam pengambilan keputusan, termasuk dalam manajemen inventori. Permasalahan seperti overstock, deadstock, dan stockout masih sering terjadi akibat pengelolaan yang belum berbasis data historis. Penelitian ini bertujuan untuk menganalisis dan mengklasifikasikan tingkat kebutuhan persediaan barang menggunakan algoritma Naïve Bayes guna mengoptimalkan manajemen inventori pada PT Soala Gogo Natama. Metode yang digunakan adalah penelitian deskriptif kuantitatif dengan pendekatan studi kasus. Data yang digunakan terdiri dari 300 observasi yang dibagi menjadi data latih (210) dan data uji (90) dengan 9 variabel. Proses analisis meliputi tahap preprocessing data, penerapan algoritma Gaussian Naïve Bayes menggunakan Python, serta evaluasi model menggunakan accuracy, confusion matrix, dan classification report. Hasil penelitian menunjukkan bahwa model mampu mengklasifikasikan data ke dalam kategori rendah, sedang, dan tinggi dengan nilai akurasi sebesar 78,89%. Evaluasi model menunjukkan performa yang baik pada kelas rendah dan tinggi, namun masih terdapat kesalahan klasifikasi pada kelas sedang akibat adanya kemiripan karakteristik antar kelas. Hal ini menunjukkan bahwa model cukup efektif dalam mengenali pola data, meskipun memiliki keterbatasan pada data yang memiliki distribusi yang tumpang tindih. Kesimpulan penelitian ini adalah algoritma Naïve Bayes dapat digunakan sebagai metode yang efektif dalam mendukung pengambilan keputusan manajemen inventori, khususnya dalam menentukan prioritas persediaan barang secara berbasis data.

Kata Kunci: Naïve Bayes, manajemen inventori, klasifikasi, data mining, prediksi persediaan.

PENDAHULUAN

Perkembangan teknologi digital dalam beberapa tahun terakhir telah membawa perubahan signifikan dalam pola operasional perusahaan, khususnya dalam pengelolaan data dan pengambilan keputusan berbasis informasi. Transformasi digital tidak hanya mendorong perusahaan untuk meningkatkan efisiensi proses bisnis, tetapi juga memperkenalkan pendekatan berbasis analitik dalam pengelolaan sumber daya, termasuk pengelolaan inventori. Inventori merupakan elemen krusial dalam rantai pasok (*supply chain*) karena berkaitan langsung dengan ketersediaan barang bagi pelanggan, tingkat pelayanan, dan biaya penyimpanan (Raharjo et al., 2023). Oleh karena itu, pengelolaan inventori yang efektif tidak hanya dibutuhkan untuk menjaga keseimbangan permintaan dan persediaan, tetapi juga menjadi faktor strategis dalam memastikan daya saing perusahaan.

Manajemen inventori memegang peranan penting dalam menjaga stabilitas operasional perusahaan, terutama pada perusahaan yang bergerak di sektor perdagangan. Ketidaktepatan dalam pengelolaan inventori dapat menimbulkan implikasi serius seperti meningkatnya biaya penyimpanan akibat kelebihan stok (*overstock*), penurunan nilai barang akibat kedaluwarsa atau perubahan tren permintaan, hingga terhambatnya penjualan akibat kekosongan stok (*stockout*) pada barang yang sedang dibutuhkan pelanggan (Fauziah, 2025). Dengan semakin kompleksnya permintaan pasar dan keberagaman jenis produk yang dikelola perusahaan, pendekatan tradisional yang mengandalkan perkiraan manual atau intuisi manajer tidak lagi relevan untuk mendukung keputusan pengadaan.

Dalam konteks modern, optimasi

manajemen inventori menjadi salah satu strategi yang dapat diterapkan untuk meningkatkan efisiensi sumber daya dan kinerja bisnis. Optimasi inventori tidak hanya membahas jumlah persediaan yang harus tersedia, tetapi juga mencakup pemahaman pola permintaan, hubungan antarproduk, serta kemampuan memprediksi kebutuhan masa depan secara akurat (Pasaribu, 2025). Seiring dengan meningkatnya kapasitas data transaksi yang dapat diolah, pendekatan *data mining* mulai banyak digunakan sebagai metode dalam mendukung keputusan inventori yang lebih presisi. Penggunaan metode analitik memungkinkan perusahaan untuk mengidentifikasi pola konsumsi berdasarkan data historis sehingga perencanaan persediaan dapat dilakukan secara sistematis dan berbasis bukti.

Beberapa algoritma *data mining* yang relevan dalam pengelolaan inventori adalah Apriori dan Naïve Bayes. Algoritma Apriori berfungsi untuk menemukan hubungan asosiasi antar barang melalui analisis data transaksi, sehingga perusahaan dapat mengetahui kelompok barang yang sering dibeli bersamaan, tren penjualan, serta keterkaitan pola pembelian pelanggan (Nir et al., 2020). Sementara itu, algoritma Naïve Bayes berperan dalam melakukan klasifikasi dan prediksi permintaan produk berdasarkan probabilitas dan data masa lalu sehingga dapat digunakan untuk menentukan prioritas stok, siklus pemesanan, dan kategori barang yang berpotensi mengalami peningkatan permintaan (Erni & Kamarudin, 2025).

Fenomena permasalahan inventori juga terjadi pada PT Soala Gogo Natama, sebuah perusahaan perdagangan yang berdiri pada tahun 2023 di Kota Medan. Berdasarkan profil perusahaan, PT Soala Gogo Natama mengelola berbagai jenis produk seperti alat kesehatan, alat

laboratorium, komputer, alat tulis kantor, hingga kebutuhan umum lainnya dengan pasar yang mencakup instansi pemerintah, rumah sakit, perusahaan swasta, serta konsumen individu. Kondisi ini menyebabkan struktur inventori perusahaan menjadi kompleks dan variatif. Saat ini, pengelolaan inventori pada PT Soala Gogo Natama masih dilakukan secara manual dan belum memanfaatkan analisis data historis secara optimal. Akibatnya, beberapa permasalahan muncul, seperti barang yang menumpuk di gudang karena jarang terjual (*deadstock*), tingginya biaya penyimpanan, serta keterlambatan pemenuhan permintaan karena keterbatasan stok pada barang tertentu ketika permintaan meningkat.

Penelitian terdahulu menunjukkan bahwa penerapan kombinasi algoritma Apriori dan Naïve Bayes mampu meningkatkan efektivitas perencanaan inventori hingga 62% pada perusahaan distribusi skala menengah (Dewi et al., 2025). Hasil tersebut menunjukkan bahwa penerapan metode *data mining* tidak hanya dapat memperbaiki proses identifikasi pola permintaan, tetapi juga meningkatkan kemampuan prediksi dalam menentukan prioritas stok dan interval pemesanan. Berdasarkan relevansi tersebut, penerapan metode Apriori dan Naïve Bayes pada PT Soala Gogo Natama memiliki potensi besar untuk meningkatkan efisiensi pengelolaan persediaan melalui sistem yang terukur, adaptif, dan berbasis data.

Oleh karena itu, penelitian ini dilakukan untuk menganalisis penerapan algoritma Naïve Bayes dalam mengoptimalkan manajemen inventori pada PT Soala Gogo Natama dengan harapan dapat memberikan solusi sistematis terhadap permasalahan *overstock*, *deadstock*, dan *stockout*, sekaligus meningkatkan efisiensi operasional dan kualitas pelayanan kepada pelanggan.

METODE

Penelitian ini menggunakan pendekatan deskriptif kuantitatif dengan metode studi kasus untuk menganalisis kondisi manajemen inventori pada PT Soala Gogo Natama berdasarkan data historis transaksi. Pendekatan kuantitatif dipilih karena penelitian ini mengolah data numerik secara statistik untuk menghasilkan pola, hubungan, dan prediksi yang objektif (Maidelwita et al., 2024; Damanik et al., 2025). Penelitian ini juga termasuk dalam penelitian terapan karena bertujuan memberikan solusi praktis terhadap permasalahan inventori perusahaan (Suryaningsih, 2025). Data yang digunakan terdiri dari data primer yang diperoleh melalui observasi dan wawancara dengan pihak terkait, serta data sekunder berupa laporan penjualan dan data persediaan perusahaan (Undari Sulung, 2024).

Teknik pengumpulan data dilakukan melalui observasi, wawancara, dan dokumentasi untuk memperoleh data yang relevan dan terukur (Waruwu, 2023; Putri & Murhayati, 2025). Tahapan analisis data dimulai dari preprocessing yang meliputi pembersihan data, penghapusan duplikasi, serta transformasi data ke dalam format yang sesuai untuk pengolahan (Sari, 2025). Selanjutnya dilakukan penerapan algoritma Naïve Bayes menggunakan Python untuk mengklasifikasikan kebutuhan persediaan berdasarkan data historis (Nasution et al., 2024). Tahap akhir dilakukan evaluasi model menggunakan metrik accuracy, confusion matrix, precision, dan recall untuk mengukur kinerja model serta memastikan hasil analisis dapat digunakan sebagai dasar pengambilan keputusan dalam pengelolaan inventori (Kartiko et al., 2021).

HASIL DAN PEMBAHASAN

Deskripsi Data

Data penelitian terdiri dari data latih (210 observasi) dan data uji (90 observasi) dengan total 9 variabel yang

mencakup informasi stok, penjualan, dan distribusi barang. Dataset memiliki kombinasi data numerik dan kategorikal sehingga memerlukan tahap preprocessing sebelum pemodelan. Struktur data awal ditampilkan melalui output Python sebagai representasi dataset.

Tabel 1 Deskripsi Data

No	Variabel	Keterangan
1	id	Kode unik barang
2	cat	Kategori barang (atk, komputer, alkes, umum)
3	stok awal	Jumlah stok awal barang
4	jual	Jumlah barang terjual
5	stok akhir	Jumlah stok akhir/sisa
6	frek	Frekuensi penjualan
7	rata	Rata-rata penjualan
8	lead	Waktu tunggu (lead time)
9	label	Kelas kategori (rendah, sedang, tinggi)

Variabel *label* berperan sebagai variabel target (*dependent variable*) dalam proses klasifikasi menggunakan algoritma *Naïve Bayes*, sedangkan variabel lainnya digunakan sebagai fitur (*independent variables*) dalam pembentukan model. Secara umum, data terdiri dari kombinasi data numerik (*stok awal, jual, stok akhir, frek, rata, lead*) dan data kategorikal (*id* dan *cat*), sehingga dilakukan proses seleksi fitur dengan menghapus variabel yang tidak relevan sebelum pemodelan.

Penerapan Naïve Bayes

Pada tahap ini diterapkan algoritma Gaussian Naïve Bayes untuk mengklasifikasikan data persediaan. Model dibangun menggunakan data latih dengan variabel label sebagai target dan variabel numerik sebagai fitur, serta diimplementasikan menggunakan Python dengan pustaka scikit-learn.

```
# ===== #
MODEL NAIVE BAYES
# =====
model = GaussianNB()
model.fit(X_train, y_train)
```

Berdasarkan kode tersebut, objek model *GaussianNB* dibentuk terlebih dahulu, kemudian dilakukan

proses pelatihan (*training*) menggunakan data latih. Proses ini bertujuan untuk mempelajari pola hubungan antara variabel fitur dan variabel target, sehingga model dapat digunakan untuk melakukan klasifikasi pada data baru. Model yang telah dilatih selanjutnya digunakan untuk melakukan proses prediksi terhadap data uji pada tahap berikutnya.

Hasil Prediksi

Setelah pelatihan model Naïve Bayes, dilakukan prediksi pada data uji untuk mengevaluasi kemampuan klasifikasi berdasarkan pola yang telah dipelajari. Hasil prediksi disajikan secara ringkas pada Tabel berikut

Tabel 2 Data Hasil Prediksi

No	Prediksi
1	sedang
2	rendah
3	rendah
4	sedang
5	rendah
6	sedang
7	sedang
8	tinggi
9	tinggi
...	...
86	sedang
87	rendah
88	tinggi
89	tinggi
90	tinggi

Model Naïve Bayes mampu mengklasifikasikan data uji ke dalam tiga kategori, yaitu rendah, sedang, dan tinggi, serta menunjukkan bahwa pola hubungan antar variabel berhasil dipelajari. Distribusi prediksi didominasi oleh kelas rendah dan sedang, menandakan pola yang lebih sering muncul dalam dataset. Meskipun seluruh data berhasil diprediksi tanpa kegagalan klasifikasi, tingkat ketepatan model tetap perlu dievaluasi lebih lanjut menggunakan metrik seperti accuracy, confusion matrix, dan classification report.

Evaluasi Model

Evaluasi model Naïve Bayes dilakukan menggunakan metrik accuracy, confusion matrix, dan classification report untuk mengukur kinerja klasifikasi. Accuracy menunjukkan tingkat ketepatan keseluruhan, sedangkan confusion matrix dan classification report memberikan analisis lebih rinci melalui nilai precision, recall, dan fl- score.

Akurasi

Akurasi merupakan salah satu metrik evaluasi yang digunakan untuk mengukur tingkat ketepatan model dalam mengklasifikasikan data uji secara keseluruhan. Nilai akurasi menunjukkan proporsi jumlah data yang berhasil diklasifikasikan dengan benar dibandingkan dengan total data uji. Berdasarkan hasil pengolahan menggunakan Python, diperoleh nilai akurasi model *Naïve Bayes* sebagai berikut:

Tabel 3 Nilai Akurasi Model

Metrik	Nilai
Akurasi	0,7889

Berdasarkan Tabel 3, diperoleh nilai akurasi sebesar 0,7889 atau setara dengan 78,89%. Hal ini menunjukkan bahwa model *Naïve Bayes* mampu mengklasifikasikan sekitar 78,89% data uji dengan benar. Secara umum, nilai akurasi tersebut dapat dikategorikan sebagai cukup baik dalam konteks klasifikasi data, mengingat model mampu mengenali pola dari data latih dan menerapkannya pada data uji dengan tingkat ketepatan yang relatif tinggi. Namun demikian, masih terdapat sekitar 21,11% data yang tidak terklasifikasi dengan benar, yang menunjukkan adanya keterbatasan model dalam membedakan beberapa kelas tertentu.

Hal ini kemungkinan disebabkan oleh adanya kemiripan karakteristik antar kelas, khususnya antara kelas *rendah* dan *sedang*, sehingga model mengalami kesulitan dalam melakukan pemisahan secara optimal. Oleh karena itu,

diperlukan analisis lebih lanjut melalui *confusion matrix* dan *classification report* untuk mengetahui secara lebih rinci distribusi kesalahan klasifikasi pada setiap kelas.

Confusion Matrix

Confusion matrix merupakan salah satu metode evaluasi yang digunakan untuk mengetahui kinerja model klasifikasi dengan membandingkan antara hasil prediksi dan label aktual. Melalui *confusion matrix*, dapat diketahui jumlah data yang diklasifikasikan dengan benar maupun yang salah pada setiap kelas. Berdasarkan hasil pengolahan menggunakan Python, diperoleh *confusion matrix* sebagai berikut:

Tabel 4 Confusion Matrix

Aktual \ Prediksi	Rendah	Sedang	Tinggi
Rendah	25	1	0
Sedang	10	23	1
Tinggi	3	4	23

Berdasarkan Tabel 4, hasil *confusion matrix* menunjukkan bahwa pada kelas *rendah* terdapat 25 data yang berhasil diklasifikasikan dengan benar, sementara 1 data lainnya salah diklasifikasikan sebagai *sedang*. Pada kelas *sedang*, sebanyak 23 data berhasil diklasifikasikan dengan tepat, namun terdapat 10 data yang salah diklasifikasikan sebagai *rendah* dan 1 data sebagai *tinggi*. Sementara itu, pada kelas *tinggi*, terdapat 23 data yang berhasil diklasifikasikan dengan benar, sedangkan 3 data salah diklasifikasikan sebagai *rendah* dan 4 data sebagai *sedang*.

Hasil tersebut menunjukkan bahwa model *Naïve Bayes* memiliki performa yang cukup baik dalam mengklasifikasikan kelas *rendah* dan *tinggi*, yang ditunjukkan oleh tingginya jumlah prediksi yang benar pada kedua kelas tersebut. Namun demikian, pada kelas *sedang* masih terdapat kesalahan klasifikasi yang cukup signifikan, terutama yang diprediksi sebagai kelas *rendah*. Hal ini mengindikasikan adanya

kemiripan karakteristik antara kelas *sedang* dan *rendah*, sehingga model mengalami kesulitan dalam membedakan kedua kelas tersebut secara optimal. Selain itu, kesalahan klasifikasi pada kelas *tinggi* yang sebagian diprediksi sebagai *sedang* juga menunjukkan adanya tumpang tindih (*overlap*) karakteristik antar kelas. Dengan demikian, meskipun model memiliki tingkat akurasi yang cukup baik, masih terdapat beberapa kesalahan klasifikasi yang perlu diperhatikan, khususnya pada kelas dengan karakteristik yang saling berdekatan.

Classification Report

Classification report digunakan untuk mengevaluasi kinerja model secara lebih rinci berdasarkan nilai *precision*, *recall*, dan *f1-score* pada masing-masing kelas. Metrik ini memberikan gambaran kemampuan model dalam mengklasifikasikan setiap kelas secara spesifik. Hasil *classification report* ditunjukkan pada Tabel 5 berikut:

Tabel 5 Classification Report

Kelas	Precisi on	Reca ll	F1-Score	Suppo rt
Rendah	0,66	0,96	0,78	26
Sedang	0,82	0,68	0,74	34
Tinggi	0,96	0,77	0,85	30
Accuracy			0,79	90
Macro Avg	0,81	0,80	0,79	90
Weighted Avg	0,82	0,79	0,79	90

Berdasarkan Tabel 5, dapat diketahui bahwa model memiliki performa yang bervariasi pada masing-masing kelas. Pada kelas *rendah*, nilai *recall* yang tinggi (0,96) menunjukkan bahwa model sangat baik dalam mengenali data yang benar-benar termasuk dalam kelas tersebut, meskipun nilai *precision* yang lebih rendah (0,66) mengindikasikan masih adanya kesalahan dalam memprediksi kelas *rendah*. Pada kelas *sedang*, nilai *precision* sebesar 0,82

menunjukkan kemampuan yang cukup baik dalam menghasilkan prediksi yang tepat, namun nilai *recall* yang lebih rendah (0,68) menunjukkan bahwa masih terdapat data kelas *sedang* yang tidak terdeteksi dengan baik oleh model. Sementara itu, pada kelas *tinggi*, model menunjukkan performa terbaik dengan nilai *precision* sebesar 0,96 dan *f1-score* tertinggi (0,85), yang mengindikasikan bahwa model cukup konsisten dalam mengklasifikasikan kelas tersebut.

Nilai *accuracy* sebesar 0,79 menunjukkan bahwa model memiliki kinerja yang cukup baik. Nilai *macro average* dan *weighted average* yang relatif seimbang juga menunjukkan bahwa performa model tidak terlalu bias terhadap salah satu kelas, meskipun masih terdapat ketidakseimbangan performa pada kelas tertentu. Hal ini sejalan dengan hasil *confusion matrix* sebelumnya yang menunjukkan adanya kesulitan model dalam membedakan kelas yang memiliki karakteristik serupa.

Untuk memastikan bahwa hasil evaluasi model yang diperoleh dari pengolahan menggunakan Python telah sesuai, maka dilakukan perhitungan manual terhadap nilai *precision*, *recall*, *f1-score*, dan *support* berdasarkan *confusion matrix* yang dihasilkan. Perhitungan manual ini bertujuan untuk memverifikasi ketepatan hasil keluaran sistem sekaligus menunjukkan bahwa proses evaluasi model *Naïve Bayes* telah dilakukan sesuai dengan rumus yang digunakan dalam teori klasifikasi. Melalui perhitungan manual ini, setiap nilai evaluasi dihitung untuk masing-masing kelas, yaitu *rendah*, *sedang*, dan *tinggi*, sehingga dapat diketahui kesesuaian antara hasil perhitungan teoritis dan hasil yang diperoleh dari Python.

1. Kelas Rendah Ambil nilai:

- TP = 25
- FP = (10 + 3) = 13
- FN = 1

Hitung: Precision

$$\frac{TP}{TP + FP} = \frac{25}{25 + 13} = \frac{25}{38} = 0.66$$

$$\frac{TP}{TP + FN} = \frac{25}{25 + 1} = \frac{25}{26} = 0.96$$

$$2 \times \frac{0.66 \times 0.96}{0.66 + 0.96} = 0.78$$

Recall F1-score

Support = 26

2. Kelas Sedang Ambil nilai:

- a. TP = 23
- b. FP = (1 + 4) = 5
- c. FN = (10 + 1) = 11

Hitung: Precision

$$\frac{TP}{TP + FP} = \frac{23}{23 + 5} = \frac{23}{28} = 0.82$$

$$\frac{TP}{TP + FN} = \frac{23}{23 + 11} = \frac{23}{34} = 0.68$$

$$2 \times \frac{0.82 \times 0.68}{0.82 + 0.68} = 0.74$$

Recall F1-score

Support = 34

3. Kelas Tinggi Ambil nilai:

- a. TP = 23
- b. FP = (0 + 1) = 1
- c. FN = (3 + 4) = 7

Hitung: Precision

$$\frac{TP}{TP + FP} = \frac{23}{23 + 1} = \frac{23}{24} = 0.96$$

Recall

$$\frac{TP}{TP + FN} = \frac{23}{23 + 7} = \frac{23}{30} = 0.77$$

F1-score

$$2 \times \frac{0.96 \times 0.77}{0.96 + 0.77} = 0.85$$

Support = 30

Berdasarkan perhitungan manual menggunakan confusion matrix, diperoleh nilai precision, recall, dan f1-score yang identik dengan hasil pengolahan menggunakan Python. Hal ini menunjukkan bahwa implementasi model dan proses evaluasi yang dilakukan telah

sesuai secara matematis dan tidak terdapat kesalahan dalam perhitungan metrik evaluasi.

Pembahasan

Berdasarkan hasil penelitian, penerapan algoritma Naïve Bayes menghasilkan akurasi sebesar 78,89%, yang menunjukkan bahwa model memiliki performa yang cukup baik dalam klasifikasi data inventori dan layak digunakan pada konteks data bisnis dengan kompleksitas menengah. Evaluasi melalui confusion matrix menunjukkan bahwa model memiliki kinerja yang baik pada kelas rendah dan tinggi, namun masih terdapat kesalahan klasifikasi pada kelas sedang akibat kemiripan karakteristik antar kelas. Hal ini diperkuat oleh classification report, di mana kelas rendah memiliki recall tinggi (0,96) tetapi precision lebih rendah (0,66), sedangkan kelas sedang memiliki recall yang lebih rendah (0,68), dan kelas tinggi menunjukkan performa terbaik dengan precision 0,96 dan f1-score 0,85.

Secara teoritis, hasil ini sejalan dengan karakteristik algoritma Naïve Bayes yang mengasumsikan independensi antar fitur, sehingga kinerjanya sangat dipengaruhi oleh distribusi dan separabilitas data (Nasution et al., 2024). Pada kondisi adanya overlap antar kelas, performa model cenderung menurun dan meningkatkan kesalahan klasifikasi. Penelitian sebelumnya juga menunjukkan bahwa Naïve Bayes

memiliki performa baik dengan akurasi di atas 75%, namun mengalami penurunan pada data dengan distribusi kelas yang tidak seimbang atau memiliki karakteristik yang berdekatan (Kurniawan et al., 2020; Putri & Rahman, 2023).

Dengan demikian, algoritma Naïve Bayes cukup efektif dalam klasifikasi tingkat persediaan barang, terutama pada kelas dengan karakteristik yang jelas, namun masih memerlukan pengembangan lebih lanjut, seperti penambahan data, pemilihan fitur yang lebih diskriminatif, atau perbandingan dengan metode lain

seperti Decision Tree dan K-Nearest Neighbor untuk meningkatkan performa model.

SIMPULAN

Hasil penelitian yang telah dilakukan mengenai penerapan algoritma Naïve Bayes dalam klasifikasi tingkat persediaan barang pada PT Soala Gogo Natama, dapat disimpulkan bahwa algoritma Naïve Bayes mampu memberikan performa klasifikasi yang cukup baik dan relevan dengan tujuan penelitian. Model yang dibangun dengan menggunakan variabel *stok_awal*, jumlah penjualan, *stok_akhir*, frekuensi penjualan, rata-rata penjualan, dan lead time berhasil mengelompokkan data persediaan ke dalam tiga kategori, yaitu rendah, sedang, dan tinggi secara efektif. Hasil evaluasi menunjukkan nilai akurasi sebesar 78,89%, yang mengindikasikan bahwa sebagian besar data uji dapat diklasifikasikan dengan benar. Analisis lebih lanjut melalui confusion matrix dan classification report menunjukkan bahwa model memiliki performa yang baik pada kelas rendah dan tinggi, namun masih mengalami keterbatasan dalam mengklasifikasikan kelas sedang akibat adanya kemiripan karakteristik antar kelas. Secara keseluruhan, algoritma Naïve Bayes terbukti cukup efektif dalam mendukung pengambilan keputusan pengelolaan inventori, khususnya dalam menentukan prioritas stok dan pengendalian persediaan berbasis data historis. Namun demikian, keterbatasan model dalam membedakan kelas dengan karakteristik yang saling berdekatan menunjukkan perlunya pengembangan lebih lanjut untuk meningkatkan performa klasifikasi.

Sehubungan dengan hal tersebut, disarankan agar hasil klasifikasi yang diperoleh dapat dimanfaatkan sebagai dasar dalam pengambilan keputusan pengelolaan persediaan pada PT Soala Gogo Natama. Selain itu, penelitian selanjutnya diharapkan dapat

menggunakan jumlah dan variasi data yang lebih besar agar model yang dihasilkan menjadi lebih representatif dan robust. Pengembangan penelitian juga dapat dilakukan dengan membandingkan algoritma Naïve Bayes dengan metode klasifikasi lain, seperti Decision Tree atau K-Nearest Neighbor, guna memperoleh performa model yang lebih optimal dan meningkatkan akurasi dalam klasifikasi tingkat persediaan barang.

DAFTAR PUSTAKA

- Damanik, M. R., R. L. Manik, and M. Khadafi, "Metode Penelitian Kuantitatif: Konsep, Jenis, Tahapan, dan Kelebihan," *J. Intelek Insa. Cendikia*, vol. 2, no. 7, pp. 13479–13496, 2025.
- Dewi, C. K., D. Hartanti, and A. Farida, "Penerapan Algoritma Apriori pada Sistem Manajemen Persediaan (Studi Kasus Toko Berkah Batam)," *Adopsi Teknol. dan Sist. Inf.*, vol. 4, no. 2, pp. 40–46, 2025.
- Erni, W., Kamarudin, "Klasifikasi Stok Barang Menggunakan Naive Bayes Untuk Optimalisasi Persediaan Toko Ahmad Adam," *J. Ilm. Tek. Mesin, Elektro dan Komput.*, 2025.
- Fauziah, S. Sabrina Nur, "Analisis Manajemen Persediaan Barang Dagang Dalam Meningkatkan Efektivitas Pendapatan Pada Apotek K-24 Pameungpeuk Kabupaten Bandung," *COSTING J. Econ. Bus. Account.*, vol. 8, pp. 2950–2960, 2025.
- Ilma Fahmi Aziza, S. L. Z. R. et al., *Metodologi Penelitian: Pendekatan Kualitatif dan Kuantitatif*. 2024.
- Kartiko, B. A., A. Wibowo, M. Kom, M. Kom, A. A. Permana, and M. Kom, "Sistem Pendukung Keputusan Penentuan Penerima Beasiswa Dengan Metode Simple Additive Weighting di SMPN 19 Tangerang," *JIKA*, pp. 41–53, 2021.
- Kurniawan, R., D. Saputra, & T. Hidayat,

- “Penerapan algoritma naïve bayes dalam klasifikasi data penjualan untuk pengambilan keputusan persediaan barang,” *Jurnal Sistem Informasi*, vol. 16, no. 1, pp. 2020.
- Maidelwita, Y., R. Nopiah, F. Purnama, and S. Indah, *Konsep Penelitian Kuantitatif*. 2024.
- Nir, U., I. K. Gede, D. Putra, and I. P. Arya, “Implementasi Algoritma Apriori untuk Menemukan Pola Pembelian Konsumen pada Perusahaan Retail,” *J. Ilm. Teknol. dan Komput.*, vol. 1, no. 2, 2020.
- Pasaribu, V. L. D., *Menciptakan Daya Saing Melalui Informasi Teknologi*. 2025.
- Putri, H. J., and S. Murhayati, “Metode Pengumpulan Data Kualitatif,” *J. Pendidik. Tambusai*, vol. 9, pp. 13074–13086, 2025.
- Putri, N. A., & A. Rahman, “Implementasi algoritma naïve bayes untuk klasifikasi tingkat persediaan barang pada UMKM,” *Jurnal RESTI*, vol. 7, no. 4, pp. 812–820, 2023.
- Raden Johnny Hadi Raharjo, E. P., Alya Nur Azizah, Adi Bimantoro, Vandra Renanda Zulfian, “Penerapan Enterprise Resource Planning Dalam Supply Chain Management Pada Minimarket Family Cukir,” *J. Ilm. Wahana Pendidik.*, vol. 9, no. 16, pp. 670–683, 2023.
- Rito, G. M., *Penerapan Data Mining Di Berbagai Bidang*. 2023.
- Sari, M. M., “Klasifikasi Data Nasabah Kredit Menggunakan Data Mining Dengan Algoritma Decision Tree,” *J. Glob.Multidiscip.*, vol. 3, no. 3, pp.5095–5100, 2025.
- Sjahrudin, H., *Metodologi Penelitian Ilmiah*. 2024.
- Suryaningsih, C., *Metode Penelitian Ilmiah Modern*. 2025.
- Undari Sulung, M. M., “Memahami Sumber Data Penelitian: Primer, Sekunder, dan Tersier,” *J. Edu Res. Indones.*, vol. 5, no. September, pp. 110–116, 2024.
- Waruwu, M., M. A. Pendidikan, U. Kristen, and S. Wacana, “Pendekatan Penelitian Pendidikan: Metode Penelitian Kualitatif, Kuantitatif dan Mixed Method,” *J. Pendidik. Tambusai*, vol. 7, pp. 2896–2910, 2023.
- Yusuf Ramadhan Nasution, I. H. S., Suhardi, “Penerapan Algoritma Klasifikasi Naïve Bayes Untuk Analisis Sentimen Tentang Pemilu 2024,” *J. Elektronika dan Komput.*, vol. 17, no. 2, pp. 495–502, 2024.
- T. D. A. N. Penerapannya, *Metode Penelitian Kualitatif: Teori dan Penerapannya*. 2024.