Jurnal Ilmiah Teknik Informatika dan Komunikasi
Volume. 6, Nomor. 3, November 2026
E-ISSN : 2827-7945 ; P-ISSN : 2827-8127; Hal. 383-398
DOI: https://doi.org/10.55606/juitik.v6i3.2775
Tersedia: https://journal.sinov.id/index.php/juitik

Analisis Perbandingan Naïve Bayes dan Random Forest dalam Klasifikasi Validitas Data Inventory PT Suplai Indo Tehnik

Mahdiah Amelia[1*], Sriyadi[2], Firstianti Wahyuhening[3]
[1-3] Prodi Sistem Informatika, Bina Sarana Informatika, Indonesia
**Penulis Korespondensi: mahdiahamelia33@gmail.com*

Abstract*. Accuracy of inventory data is vital for distribution operational efficiency, yet data quality issues such as duplication and manual validation errors remain persistent at PT Suplai Indo Tehnik. This study aims to implement and compare the performance of Naïve Bayes and Random Forest algorithms in classifying inventory data validity into Valid and Invalid classes. The dataset comprises 3,236 cleaned operational records spanning 2022 to 2026 across eight selected attributes. Modeling was conducted using Orange Data Mining evaluated via 10-Fold Cross Validation. Results reveal that Random Forest significantly outperforms Naïve Bayes across all metrics, achieving 93.3% Accuracy, 93.3% Precision, 93.3% Recall, 93.3% F1-Score, an Area Under Curve (AUC) of 0.980, and a Matthews Correlation Coefficient (MCC) of 0.863, whereas Naïve Bayes yielded an Accuracy of 58.9% and an AUC of 0.635. The lower performance of Naïve Bayes stems from the violation of its conditional independence assumption due to inter-attribute correlations, whereas Random Forest's ensemble mechanism effectively captures complex feature interactions. Practically, these findings recommend Random Forest for automating real-time inventory data validation to enhance data accuracy and operational consistency.*

Keywords: *10-Fold Cross Validation; Data Mining; Inventory Validity; Naïve Bayes; Random Forest.*

Abstrak. Akurasi data persediaan sangat krusial bagi efisiensi operasional distribusi, namun permasalahan kualitas data seperti duplikasi dan validasi manual masih terjadi di PT Suplai Indo Tehnik. Penelitian ini bertujuan mengimplementasikan serta membandingkan performa algoritma Naïve Bayes dan Random Forest dalam mengklasifikasikan validitas data persediaan ke dalam kelas Valid dan Tidak Valid. Dataset terdiri dari 3.236 data operasional bersih periode 2022–2026 dengan delapan atribut terpilih. Pemodelan dilakukan menggunakan Orange Data Mining dengan pengujian 10-Fold Cross Validation. Hasil penelitian menunjukkan bahwa Random Forest unggul secara signifikan dibandingkan Naïve Bayes pada seluruh metrik, memperoleh Accuracy 93,3%, Precision 93,3%, Recall 93,3%, F1-Score 93,3%, Area Under Curve (AUC) 0,980, dan Matthews Correlation Coefficient (MCC) 0,863, sementara Naïve Bayes hanya mencapai Accuracy 58,9% dan AUC 0,635. Rendahnya performa Naïve Bayes disebabkan oleh pelanggaran asumsi independensi bersyarat akibat keterkaitan antar-atribut, sedangkan mekanisme ensemble Random Forest mampu menangani hubungan fitur yang kompleks. Secara terapan, hasil ini merekomendasikan penggunaan Random Forest untuk mengotomatisasi validasi data persediaan secara real-time guna meningkatkan akurasi data dan konsistensi operasional.

Kata Kunci: *10-Fold Cross Validation*; *Data Mining*; Data Persediaan; Naïve Bayes; Random Forest.

1. LATAR BELAKANG

Akurasi data persediaan (*inventory*) merupakan faktor krusial dalam mendukung kelancaran operasional pada perusahaan distribusi. Data yang presisi berfungsi sebagai landasan utama dalam manajemen stok dan proses pengadaan, sehingga memungkinkan pihak manajemen untuk merumuskan kebijakan yang selaras dengan realitas di lapangan. Sebaliknya, ketidakakuratan data berpotensi memicu distorsi informasi persediaan yang pada akhirnya akan merintangi jalannya proses bisnis perusahaan (Dong et al., 2024; Yulia & Seputro, 2025). Walaupun perannya sangat vital, manajemen data persediaan kerap kali dihadapkan pada beragam isu terkait kualitas data. Problematika seperti duplikasi data, kekeliruan dalam proses entri, informasi yang usang, serta inkonsistensi pencatatan masih menjadi kendala umum dalam basis data. Situasi semacam ini dapat mendistorsi informasi yang tersimpan, sehingga

Naskah Masuk: 13 September 2026; Revisi: 29 September 2026; Diterima: 22 Oktober 2026; Terbit: 01 November 2026

berdampak negatif terhadap validitas hasil analisis maupun proses pengambilan keputusan strategis (Mohammed et al., 2024).

Kendala serupa turut dialami oleh PT Suplai Indo Tehnik, sebuah entitas bisnis yang berfokus pada distribusi perlengkapan teknik dan industri. Perusahaan ini mengelola lebih dari 25.000 entri data persediaan guna menunjang siklus pengadaan dan penyaluran barang. Observasi awal memperlihatkan adanya temuan data yang tercatat ganda, galat saat proses penginputan data, hingga data yang tidak mengalami pembaruan. Permasalahan ini diperburuk oleh mekanisme validasi data yang masih dijalankan secara konvensional, sehingga menyita waktu yang signifikan seiring dengan pembengkakan volume data. Signifikansi validitas data persediaan di PT Suplai Indo Tehnik semakin ditekankan oleh fakta bahwa mayoritas proses pengadaan barang dieksekusi berbasis *Purchase Order* (PO) dari pelanggan. Apabila data stok tidak sinkron dengan ketersediaan fisik, perusahaan dihadapkan pada risiko kekeliruan estimasi kebutuhan maupun kapasitas barang. Implikasinya, pemenuhan pesanan konsumen dapat tersendat dan berimbas pada penurunan standar pelayanan yang diberikan oleh perusahaan (Yulia & Seputro, 2025).

Di samping isu duplikasi dan kekeliruan entri, ditemukan pula anomali terkait pencatatan harga di mana harga jual direkam lebih rendah atau sejajar dengan harga pokok. Meskipun fenomena ini tidak selalu mengindikasikan data yang cacat secara absolut, hal tersebut dapat menjadi sinyalemen adanya galat pencatatan atau keterlambatan pembaruan data, sehingga menuntut validasi lebih lanjut. Mengingat laju pertumbuhan data, prosedur validasi manual dinilai tidak lagi efisien. Implementasi teknik penambangan data melalui algoritma klasifikasi menawarkan solusi strategis untuk memfasilitasi pengelompokan data berdasarkan karakteristik spesifiknya, sehingga proses identifikasi data yang valid maupun tidak valid dapat dieksekusi dengan lebih cepat dan konsisten (Purwandaru et al., 2024; William & Handhayani, 2025).

Penelitian ini mengadopsi algoritma Naïve Bayes dan Random Forest karena tingginya frekuensi penggunaan keduanya dalam berbagai studi klasifikasi serta karakteristik unik yang dimiliki masing-masing. Naïve Bayes dikenal sebagai komputasi yang efisien, sementara Random Forest diunggulkan dalam mengelola kompleksitas data. Fluktuasi kapabilitas kedua algoritma ini tecermin dari ragam penelitian terdahulu. Fidayanthie et al. (2025) mencatatkan tingkat akurasi 87% untuk Naïve Bayes dan 93% untuk Random Forest dalam studi klasifikasi penyakit paru-paru. Senada dengan hal tersebut, klasifikasi penyakit AIDS memaparkan superioritas Random Forest dengan akurasi 88,16% berbanding 81,46% milik Naïve Bayes (Saprudin et al., 2026). Di sisi lain, temuan yang kontras diungkapkan dalam riset prediksi

tingkat stres, di mana Naïve Bayes justru mendominasi dengan akurasi 92%, mengungguli Random Forest yang mencapai 88% (Saifudin, 2026). Disparitas ini mengonfirmasi bahwa supremasi sebuah algoritma bergantung pada konstelasi atribut serta distribusi suatu *dataset* (Kurniasari et al., 2024; Momole & Mailoa, 2022; Saprudin et al., 2026; William & Handhayani, 2025).

Walaupun Naïve Bayes dan Random Forest kerap diimplementasikan, dominasi riset sebelumnya masih terpaku pada domain medis, prediksi anomali, maupun evaluasi mutu barang. Studi yang secara definitif mengomparasikan kedua algoritma ini untuk mengklasifikasi validitas data persediaan berbasis data operasional nyata korporasi masih tergolong langka. Validitas data *inventory* mengusung karakteristik spesifik karena melibatkan korelasi antar-atribut kompleks seperti satuan ukur, harga jual, harga pokok, margin, hingga waktu pencatatan. Kesenjangan fokus riset (*gap analysis*) inilah yang membangun urgensi penelitian ini dilakukan. Oleh karena itu, penelitian ini bertujuan untuk menerapkan algoritma Naïve Bayes dan Random Forest dalam klasifikasi validitas data *inventory* barang pada PT Suplai Indo Tehnik. Pemodelan sistem dilakukan menggunakan *Orange Data Mining* dengan metode *10-Fold Cross Validation*. Lebih lanjut, penelitian ini juga bertujuan untuk menganalisis sekaligus membandingkan performa kedua algoritma berdasarkan instrumen evaluasi *Accuracy, Precision, Recall, F1-Score, Area Under Curve* (AUC), dan *Matthews Correlation Coefficient* (MCC) guna menentukan algoritma mana yang paling sesuai dan berkinerja terbaik dalam mengklasifikasikan data berstatus Valid dan Tidak Valid.

2. KAJIAN TEORITIS

Data mining atau penambangan data merupakan serangkaian proses analisis untuk mengekstraksi pola, korelasi, serta informasi yang sebelumnya belum teridentifikasi dari sekumpulan data berukuran besar dan kompleks dengan memanfaatkan komputasi statistik, matematika, serta kecerdasan buatan (Saputri, 2025; Rahayu et al., 2024). Landasan utama dari *data mining* tidak sebatas pemrosesan ekstraksi semata, melainkan mencakup pemahaman, pembersihan, dan transformasi data guna menghasilkan tingkat validitas informasi yang dapat diandalkan dalam skema pengambilan keputusan organisasi (Saputri, 2025; Hapsari et al., 2024; Maulani et al., 2024). Salah satu fungsionalitas inti *data mining* adalah teknik klasifikasi (*classification*), yakni pendekatan *supervised learning* yang bertujuan memetakan serta mengelompokkan entitas data ke dalam label atau kelas tertentu yang spesifik berbasis pola dan atribut yang dipelajari (Saputri, 2025; SLN, 2023; Alnuaimi & Albaldawi, 2024).

Dalam ranah pembelajaran mesin (*machine learning*), algoritma Naïve Bayes dan Random Forest menjadi dua kontstruk klasifikasi yang sering diimplementasikan dengan mekanisme operasional yang kontras (SLN, 2023). Naïve Bayes merupakan algoritma klasifikasi probabilistik (*generative classifier*) yang didasarkan pada penerapan Teorema Bayes (Berrar, 2024). Algoritma ini beroperasi di bawah asumsi *naive*, yaitu independensi kondisional antar-atribut, di mana setiap variabel masukan dianggap saling bebas dan tidak memengaruhi satu sama lain (Berrar, 2024; Nurhidayati et al., 2023). Berdasarkan kalkulasi probabilitas *prior* dan *likelihood*, Naïve Bayes mengestimasi probabilitas *posterior* dari setiap kriteria kelas untuk menetapkan prediksi pada kelas dengan nilai peluang probabilitas tertinggi (Berrar, 2024; Pajila et al., 2023). Efisiensi komputasi dan kemudahannya menjadikan Naïve Bayes tangguh dalam memproses pengelompokan data berorientasi nilai probabilitas (Nurhidayati et al., 2023; Pajila et al., 2023).

Di sisi lain, Random Forest yang diintroduksikan oleh Leo Breiman merupakan teknik klasifikasi berbasis *ensemble learning* yang menggabungkan hasil keputusan dari sekumpulan pohon keputusan (*decision trees*) (Salman et al., 2024; Scornet et al., 2025). Pembentukan model Random Forest memanfaatkan metode *bootstrap aggregating* (*bagging*) berupa pengambilan sampel secara acak dengan pengembalian (*sampling with replacement*), disertai dengan *random feature selection* pada setiap percabangan *node* (Salman et al., 2024). Keberagaman *decision tree* yang terbentuk berfungsi mereduksi tingkat korelasi antar-pohon dan menekan risiko *overfitting* (Salman et al., 2024). Keputusan klasifikasi akhir ditentukan melalui mekanisme *majority voting* dari seluruh akumulasi prediksi pohon, sehingga mampu memicu kestabilan serta performa generalisasi model yang lebih unggul dibanding penggunaan tunggal *decision tree* (Resti et al., 2023; Salman et al., 2024).

Validasi keandalan dan pengujian objektif dari model klasifikasi membutuhkan instrumen evaluasi matematis yang terstruktur. Pengukuran performa umum diawali dengan penyusunan *Confusion Matrix*, sebuah matriks evaluasi yang memetakan matriks prediksi terhadap luaran faktual melalui empat representasi utama: *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) (Rainio et al., 2024). Dari matriks ini, metrik *Accuracy* diturunkan untuk menghitung rasio ketepatan prediksi total (Sathyanarayanan & Tantri, 2024; Kurniawan et al., 2024), *Precision* untuk mengukur kepastian presisi prediksi kelas positif (Kozak et al., 2022), serta *Recall* untuk mengukur sensitivitas model dalam mengidentifikasi keseluruhan sampel bernilai positif (Opitz, 2024). Keseimbangan proporsional antara *precision* dan *recall* diukur melalui nilai *F1-Score* menggunakan rata-rata harmonik (Hicks et al., 2022; Permana & Herdiana, 2025).

Guna melengkapi evaluasi pada ketersediaan data dengan pembagian kelas yang kompleks atau ketidakseimbangan kelas (*imbalanced data*), metrik *Matthews Correlation Coefficient* (MCC) dan *Area Under Curve* (AUC) diintegrasikan. MCC memperhitungkan seluruh elemen *Confusion Matrix* secara simultan dengan rentang rentang skor -1 hingga +1, mengeliminasi bias pada penetapan performa biner (Chicco & Jurman, 2023). Sementara itu, nilai AUC mengukur luas area di bawah kurva *Receiver Operating Characteristic* (ROC) yang merepresentasikan dinamika *True Positive Rate* (TPR) terhadap *False Positive Rate* (FPR) pada rentang ambang batas *threshold*, sehingga memberikan pembuktian mengenai kapabilitas spesifik model dalam membedakan kelas target secara komprehensif (Hicks et al., 2022; Li, 2024; Handayani et al., 2025).

3. METODE PENELITIAN

Penelitian ini dirancang menggunakan pendekatan kuantitatif eksperimental berbasis *data mining* untuk membandingkan kinerja algoritma Naïve Bayes dan Random Forest dalam mengklasifikasikan validitas data *inventory* barang. Populasi data dalam penelitian ini mencakup seluruh catatan operasional *inventory* pada PT Suplai Indo Tehnik yang berjumlah lebih dari 25.000 entri data persediaan. Pengumpulan data dilakukan melalui observasi dan ekstraksi langsung terhadap dokumen serta basis data operasional perusahaan yang mengintegrasikan atribut-atribut seperti kode barang, nama barang, satuan, harga beli, harga pokok, harga jual, margin, kategori harga, dan tanggal entri (Daruhadi & Sopiati, 2024).

Tahap pra-pemrosesan data (*data preprocessing*) dieksekusi sebelum pemodelan untuk meningkatkan efektivitas klasifikasi (Vargas et al., 2023). Pembersihan data dilakukan dengan mengeliminasi entri duplikat dan menghapus catatan abnormal seperti nilai harga yang bernilai nol atau tidak valid. Selanjutnya, seleksi atribut (*feature selection*) diterapkan untuk memilih variabel yang relevan terhadap klasifikasi validitas data, yang memisahkan dataset ke dalam dua target kelas utama, yaitu Valid dan Tidak Valid (Vargas et al., 2023; Alnuaimi & Albaldawi, 2024; Pardede & Dwianto, 2025).

Pemodelan dan eksperimen komputasi dijalankan memanfaatkan perangkat lunak *Orange Data Mining* berbasis *visual programming* (Dobesova, 2024; Saifudin & Sunanto, 2026). Alur *workflow* pemodelan dibangun dengan menghubungkan pustaka *widget* utama seperti *File, Preprocessing, Naive Bayes, Random Forest, Test & Score, Confusion Matrix*, dan *ROC Analysis* (Saifudin, 2026). Untuk menguji keandalan model serta mencegah timbulnya *overfitting*, penelitian ini menerapkan metode *10-Fold Cross Validation* (Allgaier & Pryss, 2024). Melalui skema ini, dataset dibagi secara proporsional menjadi sepuluh *fold*, di

mana pada setiap iterasi sembilan *fold* dijadikan data latih (*training set*) dan satu *fold* difungsikan sebagai data uji (*testing set*) secara bergantian (Wijiyanto et al., 2024; Humairah & Fauzan, 2024).

Pengujian performa model dievaluasi secara menyeluruh menggunakan metrik penilaian standar klasifikasi biner berbasis matriks kontingensi (*Confusion Matrix*) (Rainio et al., 2024). Metrik evaluasi yang dihitung meliputi *Accuracy* untuk mengukur rasio ketepatan keseluruhan (Sathyanarayanan & Tantri, 2024), *Precision* untuk mengukur ketepatan prediksi positif (Kozak et al., 2022), *Recall* untuk menilai sensitivitas deteksi kelas positif (Opitz, 2024), serta *F1-Score* untuk mengukur keseimbangan proporsional antara *precision* dan *recall* (Hicks et al., 2022; Permana & Herdiana, 2025). Guna menjamin pengujian yang beralasan terhadap distribusi data, kinerja model turut diverifikasi menggunakan *Matthews Correlation Coefficient* (MCC) (Chicco & Jurman, 2023) serta *Area Under Curve* (AUC) berbasis *Receiver Operating Characteristic* (ROC) (Hicks et al., 2022; Li, 2024; Handayani et al., 2025).

4. HASIL DAN PEMBAHASAN

Proses pengumpulan data operasional *inventory* pada PT Suplai Indo Tehnik dilaksanakan untuk merekam catatan persediaan periode 2022–2026. Data mentah awal yang berhasil diekstraksi dari basis data internal perusahaan mencakup 25.153 entri dengan 22 atribut mencakup identitas barang, rincian harga, kelompok barang, data pemasok, serta tanggal administratif (Khong et al., 2023). Ringkasan dataset awal disajikan pada Tabel 1.

Tabel 1. Dataset Awal.

Keterangan	Jumlah
Sumber Data	PT Suplai Indo Tehnik
Jumlah Data	25.153
Periode Data	2022-2026
Jumlah Atribut	22

Sebagian data *inventory* yang diperoleh dari hasil pengumpulan data awal sebelum dilakukan tahapan *preprocessing* ditampilkan pada Tabel 2.

Tabel 2. Dataset Hasil Pengumpulan Data.

Kode	Nama Item	Satuan	Harga Jual	Harga Pokok	Harga Beli	Supplier	Kelompok Barang
75.0071	"D-LINK" DGS-1008A; Switch Hub 8 Port Gigabit	pc	400.000	55.000	55.000	S057	PERLENGKAPAN KOMPUTER
17.0508	"FLASHLIGHT" Working Lamp 9 LED DC 12–60V; IP68	pcs	2.870.000	2.125.000	2.500.000	O001	LAMPU
75.0156	"FUJITECH" Thin Client V-8	pc	1.625.000	1.250.000	1.250.000	F019	PERLENGKAPAN KOMPUTER

Kode	Nama Item	Satuan	Harga Jual	Harga Pokok	Harga Beli	Supplier	Kelompok Barang
07.1411	"HIWIN" R25-10T3-FSi-0,05; Nut	pc	1.835.000	1.275.000	1.275.000	U007	BAUT (MUR, RING PLAT, RING PER, PAKU, PAKU RIVET)
75.0272	"LOGITECH" BCC950; Conference Cam	set	4.121.000	2.750.000	2.750.000	S124	PERLENGKAPAN KOMPUTER

Berdasarkan Tabel 2, dataset hasil pengumpulan data memuat informasi mengenai identitas barang, harga, pemasok, serta kelompok barang. Seluruh atribut yang terdapat pada dataset awal tersebut dijelaskan secara rinci pada Tabel 3.

Tabel 3. Atribut Dataset Awal.

No	Nama Atribut	Deskripsi
1	Kode	Kode identitas setiap barang.
2	Nama Item	Nama barang yang tercatat pada sistem *inventory* perusahaan.
3	No. ISBN	Nomor identifikasi barang yang digunakan perusahaan.
4	Fisik	Jumlah stok fisik barang yang tersedia.
5	Satuan	Satuan pengukuran barang.
6	Min Stock	Batas minimum persediaan barang.
7	Harga Jual	Harga jual barang kepada pelanggan.
8	Harga Pokok	Harga pokok barang.
9	Harga Beli	Harga pembelian barang dari pemasok.
10	Margin	Nilai margin barang yang tercatat pada sistem *inventory* perusahaan.
11	Kategori Harga	Kategori harga yang telah ditetapkan oleh perusahaan.
12	Level1	Klasifikasi barang tingkat pertama.
13	Level2	Klasifikasi barang tingkat kedua.
14	Level3	Klasifikasi barang tingkat ketiga.
15	Level4	Klasifikasi barang tingkat keempat.
16	Level5	Klasifikasi barang tingkat kelima.
17	Supplier	Pemasok barang.
18	Tanggal Expire	Tanggal kedaluwarsa barang.
19	Kelompok Barang	Kelompok atau kategori barang.
20	Tanggal Input	Tanggal data pertama kali dicatat dalam sistem.
21	Status Data	Status validitas data yang digunakan sebagai kelas (*target*) dalam penelitian.
22	Tanggal Update	Tanggal terakhir data diperbarui.

Guna menjamin keandalan pemodelan, dataset diawali dengan tahapan pra-pemrosesan (*preprocessing*) yang meliputi *data cleaning* dan seleksi atribut. Tahap *data cleaning* membuang entri duplikat serta rekaman abnormal yang memiliki nilai 0 pada variabel harga jual, harga pokok, maupun harga beli untuk mengeliminasi bias transaksi. Tahap ini berhasil menyaring dataset dari 25.153 rekaman menjadi 3.236 data bersih siap pakai (mengeliminasi 21.917 data cacat/duplikat). Ringkasan hasil pembersihan data disajikan pada Tabel 4.

Tabel 4. Hasil Data Cleaning.

Keterangan	Jumlah Data
Dataset awal	25.153
Data setelah cleaning	3.236
Data yang dihapus	21.917

Selanjutnya, dari 22 atribut awal, dilakukan seleksi atribut (*attribute selection*) untuk menyaring variabel yang relevan dengan kebutuhan pemodelan. Hasil seleksi menetapkan 8 atribut utama yang digunakan sebagai variabel penelitian, sedangkan 14 atribut lainnya tidak digunakan karena hanya berfungsi sebagai informasi pendukung. Hasil seleksi atribut disajikan pada Tabel 5.

Tabel 5. Hasil Seleksi Atribut.

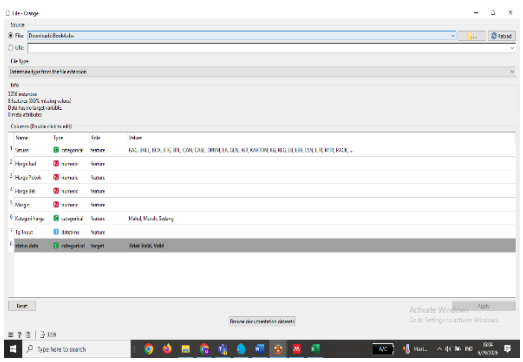
Kelompok Atribut	Nama Atribut	Keterangan
Digunakan	Satuan, Harga Jual, Harga Pokok, Harga Beli, Margin, Kategori Harga, Tanggal Input, Status Data	Digunakan sebagai variabel pada proses klasifikasi.
Tidak Digunakan	Kode, Nama Item, No. ISBN, Fisik, Min Stock, Level1, Level2, Level3, Level4, Level5, Supplier, Tanggal Expire, Kelompok Barang, Tanggal Update	Tidak disertakan dalam proses pemodelan karena tidak termasuk dalam variabel penelitian.

Dataset hasil seleksi atribut yang siap digunakan untuk tahapan penentuan *feature* dan *target* disajikan pada Tabel 6.

Tabel 6. Dataset Seleksi Atribut.

Satuan	Harga Jual	Harga Pokok	Harga Beli	Margin	Kategori harga	Tgl Input	status data
PCS	2,900,000	2,150,000	2,150,000	750,000	Sedang	05/01/22	Valid
BOX	260,000	144,000	144,000	116,000	Murah	06/01/22	Valid
PCS	300,000	165,000	165,000	135,000	Murah	06/01/22	Valid
PCS	355,000	273,000	390,000	82,000	Murah	07/01/22	Tidak Valid
PSG	359,000	312,000	480,000	47,000	Murah	07/01/22	Tidak Valid
PSG	359,000	312,000	480,000	47,000	Murah	07/01/22	Tidak Valid
PSG	359,000	312,000	480,000	47,000	Murah	07/01/22	Tidak Valid

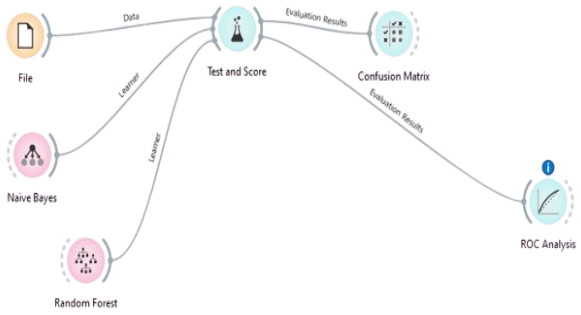
Penetapan *feature* dan *target* dilakukan pada perangkat lunak *Orange Data Mining* menggunakan *widget* File yang divisualisasikan pada Gambar 1. Atribut Satuan, Harga Jual, Harga Pokok, Harga Beli, Margin, Kategori Harga, dan Tanggal Input dikonfigurasi sebagai *feature* (masukan), sedangkan atribut Status Data dialokasikan sebagai *target* klasifikasi (Valid dan Tidak Valid).



Gambar 1. Penentuan Feature dan Target Menggunakan Widget File pada Orange Data Mining.

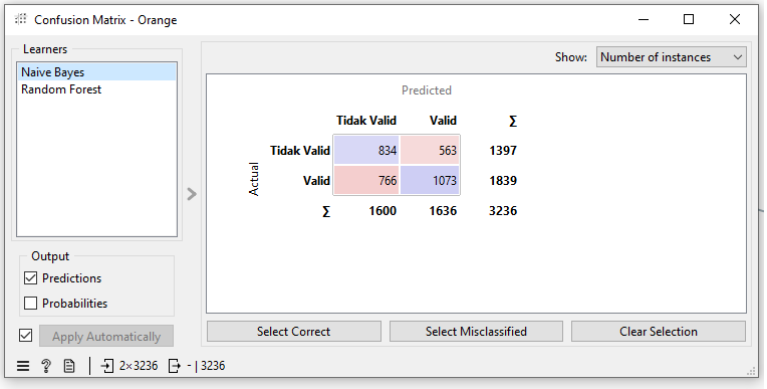
Implementasi dan Evaluasi Pemodelan

Implementasi eksperimen dijalankan menggunakan alur *workflow* terintegrasi pada *Orange Data Mining* berbasis *10-Fold Cross Validation* seperti yang ditunjukkan pada Gambar 2.



Gambar 2. Workflow Implementasi Model Klasifikasi Orange.

Pengujian matriks kontingensi (*Confusion Matrix*) menunjukkan perbandingan signifikan antar-algoritma. Hasil *Confusion Matrix* untuk algoritma Naïve Bayes disajikan pada Gambar 3 dan rincian tabelnya pada Tabel 7. Algoritma Naïve Bayes berhasil mengklasifikasikan 834 data Tidak Valid dan 1.073 data Valid secara benar, namun mengalami kesalahan klasifikasi pada 563 data Tidak Valid yang diprediksi Valid serta 766 data Valid yang diprediksi Tidak Valid.

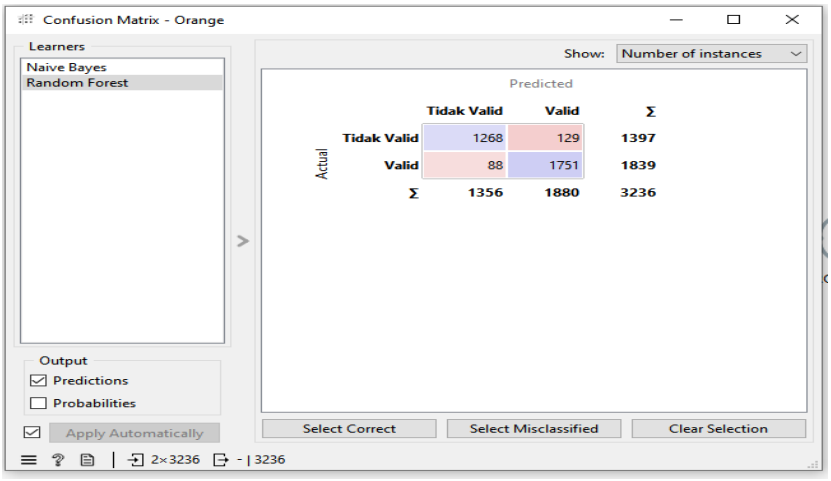


Gambar 3. Hasil Confusion Matrix Algoritma Naïve Bayes.

Tabel 7. *Confusion Matrix* Algoritma *Naïve Bayes.*

Aktual	Prediksi Tidak Valid	Prediksi Valid	Total
Tidak Valid	834	563	1.397
Valid	766	1.073	1.839
Total	1.600	1.636	3.236

Sebaliknya, algoritma Random Forest mencatatkan tingkat presisi klasifikasi yang jauh lebih tinggi seperti ditunjukkan pada Gambar 4 dan Tabel 8. Random Forest berhasil mengklasifikasikan 1.268 data Tidak Valid dan 1.751 data Valid secara akurat, serta hanya menghasilkan misklasifikasi sebanyak 129 data Tidak Valid dan 88 data Valid.



Gambar 4. Hasil Confusion Matrix Algoritma Random Forest.

Tabel 8. *Confusion Matrix* Algoritma *Random Forest.*

Aktual	Prediksi Tidak Valid	Prediksi Valid	Total
Tidak Valid	1.268	129	1.397
Valid	88	1.751	1.839
Total	1.356	1.880	3.236

Hasil perhitungan manual terhadap *Confusion Matrix* untuk kelas Valid pada algoritma Naïve Bayes dan Random Forest masing-masing dibandingkan dengan keluaran sistem *Orange Data Mining* pada Tabel 9 dan Tabel 10. Perbandingan ini mengonfirmasi bahwa perhitungan manual metrik evaluasi telah sesuai dan konsisten dengan hasil pengolahan komputasi.

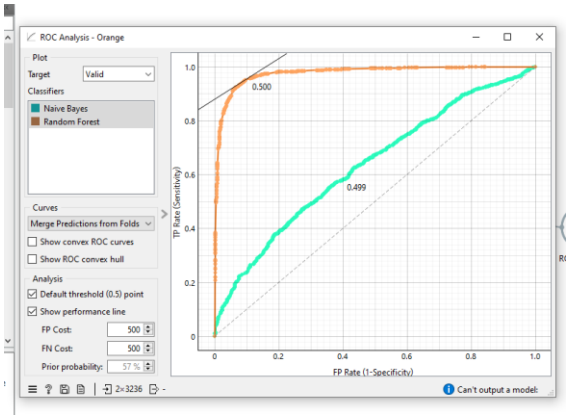
Tabel 9. Perbandingan manual dengan Orange target Valid.

Metrik	Perhitungan Manual	Orange, Target Valid
Accuracy	0,589	0,589
Precision	0,656	0,656
Recall	0,583	0,583
F1-Score	0,618	0,618
MCC	0,179	0,179

Tabel 10. Perbandingan Manual dengan Orange target Valid.

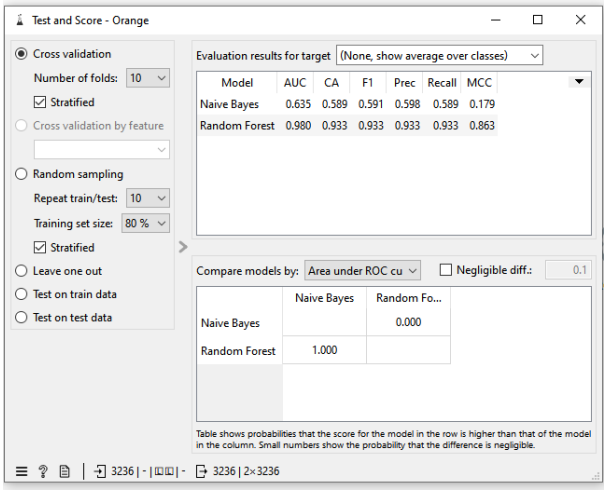
Metrik	Perhitungan Manual	Orange (Target = Valid)
Accuracy	0,933	0,933
Precision	0,931	0,931
Recall	0,952	0,952
F1-Score	0,942	0,942
MCC	0,863	0,863

Visualisasi kemampuan diskriminasi model ditampilkan melalui kurva *Receiver Operating Characteristic* (ROC) pada Gambar 5.



Gambar 5. Hasil ROC Analysis Algoritma Naive Bayes dan Random Forest.

Hasil evaluasi komprehensif menggunakan *widget Test & Score* pada Gambar 6 menyajikan perbandingan metrik performa utama antara kedua algoritma.



Gambar 6. Hasil Evaluasi Model Menggunakan Widget Test & Score.

Berdasarkan hasil evaluasi tersebut, algoritma Naïve Bayes memperoleh nilai *Area Under Curve* (AUC) sebesar 0,635, *Classification Accuracy* (CA) sebesar 0,589 (58,9%), *F1-Score* sebesar 0,591, *Precision* sebesar 0,598, *Recall* sebesar 0,589, dan *Matthews Correlation Coefficient* (MCC) sebesar 0,179. Sementara itu, algoritma Random Forest memperoleh nilai AUC sebesar 0,980, CA sebesar 0,933 (93,3%), *F1-Score* sebesar 0,933, *Precision* sebesar 0,933, *Recall* sebesar 0,933, dan MCC sebesar 0,863.

Terdapat selisih akurasi yang amat signifikan sebesar 34,4% memenangkan Random Forest. Performa Naïve Bayes yang relatif rendah dipengaruhi oleh asumsi independensi bersyarat (*conditional independence*) yang menjadi landasan teoritisnya. Pada data operasional persediaan PT Suplai Indo Tehnik, terdapat keterkaitan erat antar-atribut finansial (seperti Harga Jual, Harga Pokok, Harga Beli, Margin, dan Kategori Harga). Keterikatan antarfaktor

ini melanggar asumsi dasar Naïve Bayes sehingga membatasi kemampuannya dalam mengenali pola data, yang juga ditunjukkan oleh nilai MCC sebesar 0,179. Sebaliknya, Random Forest sangat unggul dengan nilai AUC mencapai 0,980 dan MCC sebesar 0,863 karena mekanisme *ensemble learning* berbasis *bootstrap sampling* dan *random feature selection* mampu menangkap hubungan non-linier serta keterkaitan antar-atribut yang kompleks.

Perbandingan dengan Penelitian Terdahulu

Untuk menguji validitas dan keselarasan temuan, hasil eksperimen dibandingkan dengan beberapa studi terdahulu sebagaimana dirangkum pada Tabel 11.

Table 11. Perbandingan Hasil Penelitian.

Penelitian	*Naive Bayes*	*Random Forest*	Analisis Singkat
Penelitian ini	58,9%	93,3%	*Random Forest* memberikan performa terbaik pada klasifikasi validitas data *inventory*.
(Fidayanthie et al., 2025)	87%	93%	*Random Forest* lebih unggul pada klasifikasi penyakit paru-paru.
(Saprudin et al., 2026)	81,46%	88,16%	*Random Forest* lebih unggul pada klasifikasi penyakit AIDS.
(Saifudin, 2026)	92%	88%	*Naive Bayes* lebih unggul pada prediksi tingkat stres.

Berdasarkan Tabel 11, temuan penelitian ini sejalan dengan hasil riset Fidayanthie et al. (2025) pada klasifikasi penyakit paru-paru yang mencatatkan keunggulan Random Forest (93%) atas Naïve Bayes (87%), serta penelitian Saprudin et al. (2026) pada klasifikasi penyakit AIDS yang memenangkan Random Forest (88,16%) dibanding Naïve Bayes (81,46%). Hal ini menegaskan bahwa untuk karakteristik dataset berdimensi kompleks dengan keterkaitan atribut yang kuat, Random Forest secara konsisten menghasilkan stabilitas prediksi yang lebih tinggi.

Meski demikian, temuan ini berbeda dengan riset Saifudin (2026) mengenai prediksi tingkat stres, di mana Naïve Bayes (92%) mengungguli Random Forest (88%). Disparitas hasil tersebut membuktikan bahwa supremasi suatu algoritma tidak bersifat mutlak, melainkan sangat bergantung pada distribusi, tipe data, serta kompleksitas korelasi atribut dalam dataset. Secara terapan, implikasi hasil penelitian ini memberikan rekomendasi konkret bagi PT Suplai Indo Tehnik untuk menerapkan pemodelan berbasis Random Forest guna mengotomatisasi validasi data persediaan secara cepat, akurat, dan efisien.

5. KESIMPULAN DAN SARAN

Implementasi algoritma Naïve Bayes dan Random Forest telah berhasil dieksekusi untuk mengklasifikasikan validitas data *inventory* barang pada PT Suplai Indo Tehnik ke dalam kategori Valid dan Tidak Valid. Hasil evaluasi komparatif secara sistematis membuktikan bahwa algoritma Random Forest menghasilkan keunggulan performa yang sangat dominan

dibanding Naïve Bayes di seluruh metrik pengujian. Random Forest mencatatkan *Accuracy* sebesar 93,3%, *Precision* 93,3%, *Recall* 93,3%, *F1-Score* 93,3%, *Area Under Curve* (AUC) 0,980, dan *Matthews Correlation Coefficient* (MCC) 0,863. Sebaliknya, Naïve Bayes hanya memperoleh *Accuracy* sebesar 58,9%, *Precision* 59,8%, *Recall* 58,9%, *F1-Score* 59,1%, AUC 0,635, dan MCC 0,179. Kesenjangan akurasi sebesar 34,4% ini menegaskan bahwa Random Forest merupakan model yang paling tepat dan andal untuk mengotomatisasi pemilahan data persediaan secara presisi dan konsisten pada karakteristik *dataset* perusahaan yang memiliki keterkaitan antar-atribut cukup kompleks.

Berdasarkan temuan tersebut, PT Suplai Indo Tehnik disarankan untuk mengintegrasikan model klasifikasi berbasis Random Forest ke dalam sistem informasi persediaan internal perusahaan guna mengotomatisasi validasi data secara *real-time*, sehingga dapat memangkas durasi pemeriksaan manual serta menekan risiko kesalahan entri data operasional. Kendati demikian, penelitian ini memiliki keterbatasan pada cakupan algoritma yang dibandingkan serta belum diterapkannya teknik optimasi parameter tingkat lanjut. Oleh karena itu, penelitian di masa mendatang direkomendasikan untuk memperluas komparasi dengan algoritma lain seperti *XGBoost*, *Support Vector Machine* (SVM), atau *Artificial Neural Network* (ANN), serta menerapkan *hyperparameter tuning* dan metode penanganan *imbalanced data* guna meningkatkan skalabilitas dan efektivitas klasifikasi data persediaan secara lebih optimal.

UCAPAN TERIMA KASIH

Artikel ilmiah ini merupakan bagian dari hasil penelitian skripsi pada Program Studi Sistem Informasi, Fakultas Teknik dan Informatika, Universitas Bina Sarana Informatika. Penulis menyampaikan ucapan terima kasih dan apresiasi setinggi-tingginya kepada segenap civitas akademika Universitas Bina Sarana Informatika atas dukungan fasilitas dan bimbingan yang diberikan selama penyusunan penelitian ini. Penulis juga mengucapkan terima kasih kepada manajemen dan jajaran staf PT Suplai Indo Tehnik yang telah memberikan izin penelitian, menyediakan akses data operasional inventory, serta memberikan bantuan teknis yang sangat berharga dalam mendukung penyelesaian penelitian ini.

DAFTAR REFERENSI

Allgaier, J., & Pryss, R. (2024). Cross-Validation Visualized: A Narrative Guide to Advanced Methods. *Machine Learning and Knowledge Extraction*, 6(2), 1378–1388. https://doi.org/10.3390/make6020065

Alnuaimi, A. F. A. H., & Albaldawi, T. H. K. (2024). An overview of machine learning classification techniques. *BIO Web of Conferences*, 97, 00133. https://doi.org/10.1051/bioconf/20249700133

Ardan, T. S., Mujiatno, A. S., & Akbar, B. A. (2025). Implementasi Data Analytics Menggunakan Metodologi CRISP-DM (Studi Kasus Data Bike Sales in Europe Pada Platform Kaggle). *JSiI (Jurnal Sistem Informasi)*, 12(2), 10–15.

Arvind, V. R., Shrinidhi, R. M., Deepa, T., & Maheedhar, M. (2025). Intelligent Warehousing: A Machine Learning and IoT Framework for Precision Inventory Optimization. *IEEE Access*, 13, 169381–169414. https://doi.org/10.1109/ACCESS.2025.3614679

Berrar, D. (2024). Bayes' Theorem and Naive Bayes Classifier. *Encyclopedia of Data Science*, 1, 118–125. https://doi.org/10.1016/B978-0-323-95502-7.00118-4

Cahyono, A. R., Iskandar, A., & Rifqi, A. (2025). Analisis Data Inventaris Pada PT. Global Samudera Kreasi untuk Optimalisasi Pengelolaan dan Prediksi Kualitas Barang Menggunakan Algoritma Support Vector Machine dan Naïve Bayes. *Jurnal Mahasiswa Teknik Informatika (JATI)*, 9(3), 13437–13444. https://doi.org/10.36040/jati.v9i3.13437

Chicco, D., & Jurman, G. (2023). The Matthews correlation coefficient (MCC) should replace the ROC AUC as the standard metric for assessing binary classification. *BioData Mining*, 16(1), 1–23. https://doi.org/10.1186/s13040-023-00322-4

Daruhadi, G., & Sopiati, P. (2024). Metode Pengumpulan Data Penelitian. *Jurnal Cendekia Ilmiah*, 3(5), 5423–5443. https://doi.org/10.56799/jceki.v3i5.5181

Diantika, S., Nalatissifa, H., Maulidah, N., Supriyadi, R., & Fauzi, A. (2024). Penerapan Teknik Random Oversampling Untuk Memprediksi Ketepatan Waktu Lulus Menggunakan Algoritma Random Forest. *Computer Science (CO-SCIENCE)*, 4(1), 11–18. https://doi.org/10.31294/coscience.v4i1.1996

Dobesova, Z. (2024). Evaluation of Orange data mining software and examples for lecturing machine learning tasks in geoinformatics. *Computer Applications in Engineering Education*, 32(4), e22735. https://doi.org/10.1002/cae.22735

Dong, S., Sahri, S., & Palpanas, T. (2024). Data Quality Awareness: A Journey from Traditional Data Management to Data Science Systems. *Proceedings of ACM Conference*, 1, 1–12.

Fidayanthie, E. W., Sayfulloh, A., Alzena, M. R., & Sari, N. K. (2025). Analisis Perbandingan Algoritma Random Forest dan Algoritma Naive Bayes untuk Memprediksi Penyakit Paru-Paru di Indonesia. *Saturnus: Jurnal Teknologi Dan Sistem Informasi*, 3(3), 123–135. https://doi.org/10.61132/saturnus.v3i3.956

Handayani, K., Erni, Ardiyansyah, & Sasongko, A. (2025). Analisis Kinerja Logistic Regression dan Random Forest pada Deteksi Fraud E-Commerce Menggunakan SMOTE dan PCA. *Jurnal Infortech*, 6(2), 186–193.

Handrianto, Y., & AlWafi, M. Z. (2025). Penerapan Algoritma Naive Bayes Pada Penerimaan Santri Baru Pendidikan Pondok Pesantren. *Jurnal Infortech*, 7(1), 1–5. https://doi.org/10.31294/infortech.v7i1.25458

Hicks, S. A., Strümke, I., Thambawita, V., Hammou, M., Riegler, M. A., Halvorsen, P., & Parasa, S. (2022). On evaluation metrics for medical applications of artificial intelligence. *Scientific Reports*, 12(1), 1–9. https://doi.org/10.1038/s41598-022-09954-8

Humairah, N. L., & Fauzan, A. (2024). Spatial Insights Into Earthquake Strength: a Sulawesi Case Study Using Ordinary and Robust Kriging Methods. *Barekeng: Jurnal Ilmu Matematika dan Terapan*, 18(2), 1283–1296. https://doi.org/10.30598/barekengvol18iss2pp1283-1296

Kozak, J., Probierz, B., Kania, K., & Juszczuk, P. (2022). Preference-Driven Classification Measure. *Entropy*, 24(4), 1–24. https://doi.org/10.3390/e24040531

Kurniasari, D., Hidayah, R. N., Notiragayu, N., Warsono, W., & Nisa, R. K. (2024). Classification Models for Academic Performance: A Comparative Study of Naïve Bayes and Random Forest Algorithms in Analyzing University of Lampung Student Grades. *Jurnal Teknik Informatika (JUTIF)*, 5(5), 1267–1276. https://doi.org/10.52436/1.jutif.2024.5.5.2066

Kurniawan, D., Purnomo, H. D., & Iriani, A. (2024). Analisis Sentimen Komentar Konsumen Industri Jamu di Media Sosial menggunakan Artificial Neural Network dan K-Nearest Neighbor. *Jurnal Sistem Informasi Bisnis*, 14(3), 210–223. https://doi.org/10.21456/vol14iss3pp210-223

Li, J. (2024). Area under the ROC Curve has the most consistent evaluation for binary classification. *PLoS ONE*, 19(12), e0316019. https://doi.org/10.1371/journal.pone.0316019

Mahfouz, M. A., Mosaad, S. M., & Belal, M. A. (2023). Inventory Data Mining System Using Federated Machine Learning Strategy. *Journal of Southwest Jiaotong University*, 58(3), 51–62. https://doi.org/10.35741/issn.0258-2724.58.3.51

Nurhidayati, Samsu, L., & Amina, W. (2023). Implementasi Algoritma Naive Bayes Untuk Klasifikasi Penerima Beasiswa. *Infotek: Jurnal Informatika Dan Teknologi*, 6(1), 45–54. https://doi.org/10.29408/jit.v6i1.7529

Opitz, J. (2024). A Closer Look at Classification Evaluation Metrics and a Critical Reflection of Common Evaluation Practice. *Transactions of the Association for Computational Linguistics*, 12, 820–836. https://doi.org/10.1162/tacl_a_00675

Pardede, J., & Dwianto, R. (2025). The Effect of Feature Selection on Machine Learning Classification. *International Journal on Informatics Visualization*, 9(4), 1419–1429. https://doi.org/10.62527/joiv.9.4.2926

Permana, R., & Herdiana, F. A. (2025). Analisis Klasifikasi Dan Prediksi Pola Publikasi Berita Pemprov DKI Jakarta Menggunakan Machine Learning. *Jurnal Infortech*, 7(1), 50–55. https://doi.org/10.31294/infortech.v7i1.25926

Pudjihartono, N., Fadason, T., Kempa-Liehr, A. W., & O'Sullivan, J. M. (2022). A Review of Feature Selection Methods for Machine Learning-Based Disease Risk Prediction. *Frontiers in Bioinformatics*, 2, 927312. https://doi.org/10.3389/fbinf.2022.927312

Purwandaru, D., Ruldeviyani, Y., Nugraheni, S., & Prisillia, G. (2024). Comparative Analysis of Multicriteria Inventory Classification and Forecasting: A Case Study in PT XYZ. *Jurnal Informatika Ekonomi Bisnis*, 6(4), 732–739. https://doi.org/10.37034/infeb.v6i4.1014

Rainio, O., Teuho, J., & Klén, R. (2024). Evaluation metrics and statistical tests for machine learning. *Scientific Reports*, 14(1), 6086. https://doi.org/10.1038/s41598-024-56706-x

Resti, Y., Irsan, C., Latif, J. F., Yani, I., & Dewi, N. R. (2023). A Bootstrap-Aggregating in Random Forest Model for Classification of Corn Plant Diseases and Pests. *Science and Technology Indonesia*, 8(2), 288–297. https://doi.org/10.26554/sti.2023.8.2.288-297

Saifudin, S. I. F., & Sunanto. (2026). Komparasi Naïve Bayes dan Random Forest untuk Prediksi Tingkat Stres Berdasarkan Pola Penggunaan Medsos. *Informatics and Computer Engineering Journal*, 6(1), 12–20.

Salman, H. A., Kalakech, A., & Steiti, A. (2024). Random Forest Algorithm Overview. *Babylonian Journal of Machine Learning*, 2024, 69–79. https://doi.org/10.58496/BJML/2024/007

Saprudin, M. T., Sudrajat, B., & Asymar, H. H. (2026). Analisis Perbandingan Algoritma Random Forest dan Naive Bayes Dalam Klasifikasi Penyakit AIDS. *Jurnal Elektro dan Informatika Selatan (JEIS)*, 6(1), 100–108. https://doi.org/10.56486/jeis.vol6no1.1002

Saputri, E. (2025). Teknik dan aplikasi data mining di Indonesia: tinjauan literatur satu dekade (2015-2024). *IT-Explore: Jurnal Penerapan Teknologi Informasi Dan Komunikasi*, 4(2), 138–149. https://doi.org/10.24246/itexplore.v4i2.2025.pp138-149

Vargas, V. W. de, Aranda, J. A. S., Silva Pereira, P. R. da, & Barbosa, J. L. V. (2023). Imbalanced data preprocessing techniques for machine learning: a systematic mapping study. *Knowledge and Information Systems*, 65(1), 31–57. https://doi.org/10.1007/s10115-022-01772-8

Yulia, R., & Seputro, D. N. D. (2025). Digital Transformation of Inventory Management: Evaluating the Impact of First In First Out-Based Accurate Point of Sale System Implementation on Warehouse Operations. *International Journal Administration, Business & Organization*, 6(3), 378–393. https://doi.org/10.61242/ijabo.25.663