

Penerapan Naive Bayes untuk Memprediksi Status Keberhasilan Transaksi pada Sistem Top Up AY Pulsa Menggunakan Aplikasi Orange

Aisyah Rahmadiyah Manoppo¹, Dhea Nurandani², Doni Adrian³, Muhammad Irfan Ayuda^{4,*}

¹Sains & Teknologi, Teknologi Informasi, Universitas Labuhanbatu, Rantauprapat, Indonesia

²Fakultas, Program Studi, Nama Institusi, Kota, Indonesia

Email: Aisyahrahmadiyah5@gmail.com, deanurandhani@gmail.com, ^{3,*}doniadrian520@gmail.com, ⁴Mhdifan842@gmail.com

Email Penulis Korespondensi: : Aisyahrahmadiyah5@gmail.com

Abstrak— Perkembangan layanan transaksi digital pada sistem top up pulsa menuntut keandalan sistem dalam memastikan status keberhasilan transaksi secara cepat dan akurat. Namun, pada praktiknya sering terjadi permasalahan seperti transaksi gagal atau pending yang menyebabkan ketidakpastian bagi pengguna. Penelitian ini bertujuan untuk menerapkan algoritma *Naive Bayes Classifier* dalam memprediksi status keberhasilan transaksi pada sistem Top Up AY Pulsa. Pendekatan klasifikasi probabilistik seperti Naive Bayes telah banyak digunakan pada sistem transaksi digital dan mobile payment karena efisiensi komputasi serta kemampuannya dalam mengenali pola transaksi (Botchey et al., 2020; Lokanan et al., 2023). Data yang digunakan berupa data historis transaksi yang meliputi atribut pengguna, provider, harga jual, dan status transaksi. Tahapan penelitian meliputi pengumpulan data, pra-pemrosesan data, penerapan algoritma Naive Bayes menggunakan aplikasi Orange, serta evaluasi kinerja model. Hasil pengujian menunjukkan bahwa model Naive Bayes mampu mencapai nilai akurasi sebesar 86,4%, nilai *Area Under Curve* (AUC) sebesar 0,714, *precision* sebesar 0,841, *recall* sebesar 0,864, dan *F1-score* sebesar 0,853. Hasil tersebut menunjukkan bahwa algoritma Naive Bayes memiliki kemampuan yang cukup baik dalam mengklasifikasikan status transaksi. Meskipun demikian, ketidakseimbangan distribusi data antar kelas masih memengaruhi kinerja model, yang ditunjukkan oleh rendahnya nilai *Matthews Correlation Coefficient*. Secara keseluruhan, penelitian ini membuktikan bahwa algoritma Naive Bayes dapat digunakan sebagai metode pendukung pengambilan keputusan untuk meningkatkan keandalan sistem Top Up AY Pulsa.

Kata Kunci: Naive Bayes, Klasifikasi Transaksi, Top Up Pulsa, Data Mining, Sistem

1. PENDAHULUAN

Perkembangan teknologi digital telah mendorong transformasi signifikan dalam sistem transaksi elektronik, khususnya pada layanan *top up* pulsa dan paket data yang terintegrasi dalam aplikasi berbasis mobile. Layanan ini menjadi bagian penting dari kebutuhan masyarakat modern karena mendukung komunikasi dan aktivitas digital sehari-hari, sehingga sistem transaksi dituntut untuk memiliki kecepatan proses, akurasi data, serta tingkat keberhasilan transaksi yang tinggi. Keandalan sistem transaksi digital berperan langsung dalam membangun kepuasan, loyalitas, dan kepercayaan pengguna terhadap penyedia layanan. Namun, dalam implementasinya, sistem *top up* pulsa masih menghadapi berbagai permasalahan operasional, seperti transaksi gagal, status transaksi tertunda (*pending*), gangguan jaringan, serta ketidaksesuaian antara saldo pengguna dan data sistem. Permasalahan tersebut tidak hanya berdampak pada pengalaman pengguna, tetapi juga meningkatkan beban operasional penyedia layanan akibat tingginya keluhan dan kebutuhan penanganan manual.

Salah satu kelemahan utama pada sistem transaksi digital saat ini adalah mekanisme penentuan status transaksi yang masih bersifat reaktif. Status keberhasilan atau kegagalan transaksi umumnya baru diketahui setelah seluruh proses transaksi selesai, sehingga ketika terjadi kegagalan, pengguna harus menunggu konfirmasi sistem atau melakukan pelaporan secara manual. Kondisi ini menunjukkan belum optimalnya pemanfaatan data transaksi historis sebagai sumber informasi strategis. Padahal, data transaksi yang tersimpan dalam sistem mengandung pola-pola tertentu yang dapat dianalisis untuk memprediksi potensi keberhasilan atau kegagalan transaksi secara lebih dini. Oleh karena itu, penerapan pendekatan berbasis *data mining* dan *machine learning* menjadi solusi yang relevan untuk meningkatkan kemampuan sistem dalam melakukan prediksi status transaksi secara lebih cepat, akurat, dan adaptif.

Salah satu algoritma klasifikasi yang banyak digunakan dalam bidang *data mining* adalah Naive Bayes. Algoritma ini didasarkan pada teori probabilitas Bayes dengan asumsi independensi antar atribut, sehingga memiliki struktur perhitungan yang sederhana dan efisien. Keunggulan utama Naive Bayes terletak pada kemampuannya dalam menangani data berukuran besar, bekerja dengan baik pada data numerik maupun kategorikal, serta menghasilkan performa klasifikasi yang stabil dengan kebutuhan komputasi yang relatif rendah. Penelitian yang dilakukan oleh (M. Botchey et al., 2020) menunjukkan bahwa algoritma Naive Bayes mampu mengklasifikasikan data transaksi digital secara efektif dengan tingkat akurasi yang kompetitif dibandingkan algoritma klasifikasi lain, serta memiliki waktu pemrosesan yang lebih efisien. Hasil penelitian tersebut membuktikan bahwa pola transaksi berhasil dan gagal dapat dipelajari dari data historis menggunakan pendekatan probabilistik.

Temuan tersebut mengindikasikan bahwa algoritma Naive Bayes memiliki potensi yang kuat untuk diterapkan pada sistem transaksi *top up* pulsa berbasis aplikasi. Dengan memanfaatkan atribut-atribut transaksi seperti pengguna, operator, nominal pulsa, waktu transaksi, dan status jaringan, model Naive Bayes dapat digunakan untuk memprediksi kemungkinan keberhasilan transaksi sebelum proses selesai. Penerapan model prediksi ini diharapkan mampu membantu sistem dalam memberikan informasi status transaksi secara lebih cepat, mengurangi ketidakpastian bagi pengguna, serta meminimalkan risiko kegagalan transaksi yang berulang.

Berdasarkan uraian tersebut, penelitian ini berfokus pada penerapan algoritma Naive Bayes untuk memprediksi status keberhasilan transaksi pada sistem Top Up AY Pulsa. Penelitian ini diharapkan tidak hanya memberikan kontribusi akademik dalam pengembangan penerapan *machine learning* pada sistem pembayaran digital, tetapi juga memberikan manfaat praktis bagi pengelola layanan *top up* pulsa dalam meningkatkan keandalan sistem, efisiensi operasional, serta kualitas layanan secara keseluruhan.

Pemanfaatan algoritma *machine learning* dalam sistem transaksi digital telah banyak diteliti, khususnya untuk klasifikasi status transaksi, deteksi kegagalan, dan analisis risiko pada sistem pembayaran elektronik. Salah satu algoritma yang sering digunakan adalah *Naive Bayes* karena kesederhanaan model dan efisiensi komputasi.

(R. M. R. Rahman, 2024) melakukan penelitian komparatif terhadap beberapa algoritma *machine learning* pada sistem transaksi mobile money dan menemukan bahwa *Naive Bayes* mampu memberikan performa klasifikasi yang stabil dengan waktu pemrosesan yang lebih cepat dibandingkan metode lain seperti Decision Tree dan K-Nearest Neighbor. Penelitian ini menegaskan bahwa pendekatan probabilistik efektif digunakan pada data transaksi digital yang bersifat dinamis dan berukuran besar.

Penelitian lain oleh (Lokanan et al., 2023) menerapkan *Naive Bayes* dan algoritma pembelajaran mesin lainnya untuk memprediksi anomali dan risiko kegagalan transaksi pada sistem mobile payment. Hasil penelitian menunjukkan bahwa *Naive Bayes* memiliki tingkat akurasi yang kompetitif, khususnya pada data dengan atribut heterogen seperti nominal transaksi, waktu, dan metode pembayaran. Temuan ini memperkuat relevansi penggunaan *Naive Bayes* dalam sistem top up berbasis aplikasi.

Dalam konteks implementasi menggunakan perangkat lunak analisis data, Saputra dan Handayani (2022) membuktikan bahwa algoritma *Naive Bayes* yang diimplementasikan melalui aplikasi Orange Data Mining mampu menghasilkan klasifikasi data transaksi yang akurat dan mudah diinterpretasikan. Penelitian ini menekankan keunggulan Orange sebagai alat bantu visual yang efektif untuk penelitian berbasis data mining, terutama bagi sistem transaksi skala kecil hingga menengah.

(Arsanto, 2024) meneliti optimalisasi algoritma *Naive Bayes* pada klasifikasi transaksi keuangan dengan permasalahan *class imbalance*. Hasil penelitian menunjukkan bahwa meskipun *Naive Bayes* mampu mencapai akurasi tinggi, distribusi kelas yang tidak seimbang dapat memengaruhi metrik evaluasi tertentu seperti Matthews Correlation Coefficient. Temuan ini relevan dengan penelitian ini, mengingat data transaksi top up pulsa juga cenderung didominasi oleh kelas transaksi berhasil.

Selain itu, penelitian oleh International Journal of Intelligent Systems and Applications in Engineering (2022) membahas penerapan analitik prediktif untuk mengidentifikasi potensi kegagalan transaksi pada sistem payment gateway. Studi tersebut menyimpulkan bahwa pemanfaatan data historis transaksi dengan metode klasifikasi probabilistik dapat membantu sistem dalam memprediksi status transaksi secara lebih dini dan mengurangi ketergantungan pada proses verifikasi manual.

Berdasarkan beberapa penelitian terdahulu tersebut, dapat disimpulkan bahwa algoritma *Naive Bayes* memiliki landasan empiris yang kuat dalam penerapan klasifikasi transaksi digital. Namun, sebagian besar penelitian sebelumnya masih berfokus pada fraud detection atau sistem pembayaran umum, sehingga penelitian ini memiliki kebaruan dengan menerapkan *Naive Bayes* secara spesifik pada prediksi status keberhasilan transaksi top up pulsa pada sistem AY Pulsa menggunakan aplikasi Orange, yang masih jarang dibahas dalam penelitian sejenis.

2. METODE PENELITIAN

2.1 Sumber Data

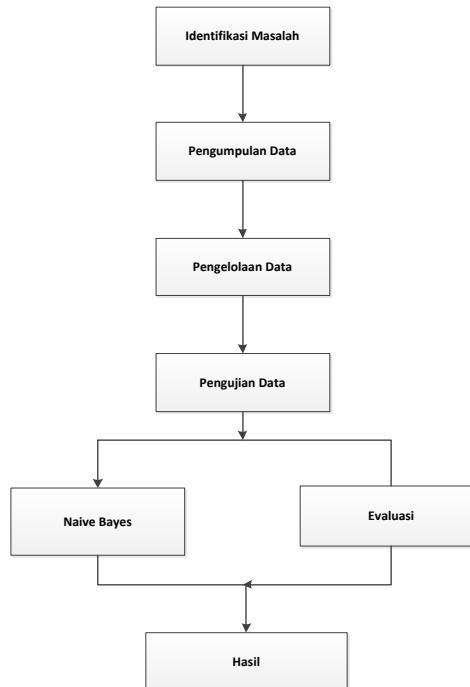
Data yang digunakan dalam penelitian ini merupakan data sekunder, yaitu data historis transaksi top up pulsa pada sistem AY Pulsa yang telah terdokumentasi sebelumnya. Data transaksi tersebut mencerminkan aktivitas nyata pengguna dalam melakukan pembelian pulsa melalui sistem, sehingga memiliki tingkat relevansi dan validitas yang tinggi terhadap tujuan penelitian.

Atribut yang digunakan dalam dataset meliputi waktu transaksi, nominal top up, provider, metode pembayaran, dan status transaksi yang diklasifikasikan ke dalam dua kelas, yaitu berhasil dan gagal (A. Rahman & Putra, 2023). Atribut-atribut ini dipilih karena secara operasional berpengaruh terhadap keberhasilan transaksi, baik dari sisi teknis sistem maupun perilaku pengguna.

Jenis data yang diolah terdiri dari data kategorikal dan numerik. Data numerik, seperti nominal transaksi dan waktu transaksi, merepresentasikan nilai kuantitatif, sedangkan data kategorikal, seperti provider dan metode pembayaran, merepresentasikan kategori tertentu. Seluruh data kemudian digunakan sebagai input dalam proses klasifikasi untuk memprediksi status transaksi secara otomatis.

2.2 Tahapan Penelitian

Penelitian ini dilakukan melalui beberapa tahapan sistematis untuk memastikan bahwa penerapan metode *Naive Bayes* dalam memprediksi keberhasilan transaksi pada sistem Top Up AY Pulsa dapat menghasilkan model yang akurat dan sesuai dengan tujuan penelitian. Tahapan penelitian disusun secara berurutan mulai dari identifikasi masalah, pengumpulan data, pengelolaan data, pengujian data, *Naive Bayes*, evaluasi, dan hasil..



Gambar 1. Alur Penelitian

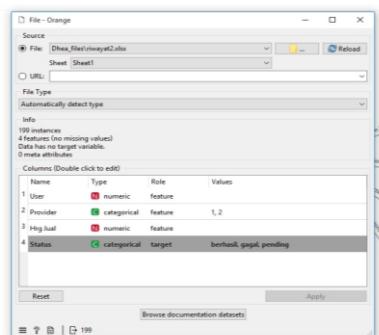
Keterangan:

Tahap pertama adalah identifikasi masalah dan studi literatur. Pada tahap ini, peneliti mengidentifikasi permasalahan yang terjadi pada sistem *top up* pulsa, khususnya terkait status transaksi yang sering mengalami kegagalan atau keterlambatan konfirmasi. Studi literatur dilakukan dengan menelaah jurnal, prosiding, dan artikel ilmiah yang membahas penerapan algoritma *Naive Bayes* pada klasifikasi transaksi dan sistem pembayaran digital (Arsanto, 2024). Tahap ini bertujuan untuk memperoleh dasar teoritis serta menemukan *research gap* yang menjadi urgensi penelitian.

Tahap kedua adalah pengumpulan data. Data yang digunakan dalam penelitian ini berupa data transaksi *top up* pulsa pada sistem AY Pulsa. Data transaksi mencakup atribut seperti usser, provider, harga jual, dan status transaksi (berhasil, pending, gagal). Data tersebut diperoleh dari riwayat transaksi sistem dan digunakan sebagai *dataset* penelitian.

Tahap ketiga adalah pengelolaan data. Pada tahap ini dilakukan pembersihan data (*data cleaning*) untuk menghilangkan data yang tidak lengkap, data ganda, atau data yang tidak konsisten. Selain itu, dilakukan proses transformasi data, seperti pengkodean atribut kategorikal agar dapat diolah oleh algoritma *Naive Bayes*. Tahap ini bertujuan untuk meningkatkan kualitas data sehingga model klasifikasi dapat bekerja secara optimal. Dataset di konversikan ke nilai numerik karena pada Aplikasi yang digunakan seperti Orange tidak bisa sepenuhnya membaca teks, karna pada penelitian ini kami mencari target pada status keberhasilan transaksi.

Tahap keempat adalah penerapan metode *Naive Bayes*. Data yang telah diproses kemudian di upload pada aplikasi Orange untuk diproses. Algoritma *Naive Bayes* diterapkan pada data latih untuk membangun model klasifikasi yang mampu memprediksi status transaksi. Proses ini dilakukan dengan menghitung probabilitas setiap kelas berdasarkan atribut yang ada menggunakan teorema Bayes.



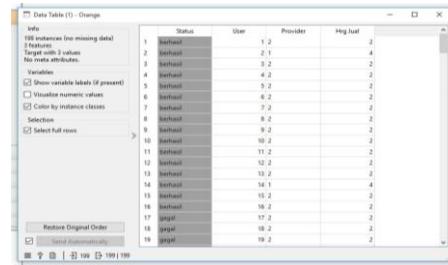
Gambar 2. Upload File

Prosiding Seminar Nasional Inovasi dan Riset Multidisiplin

Vol 1, No 1, Februari 2026, Hal 24 - 34

ISSN XXXX-XXXX (Media Online)

Website : <https://journal.hdgi.org/index.php/sinergi/>

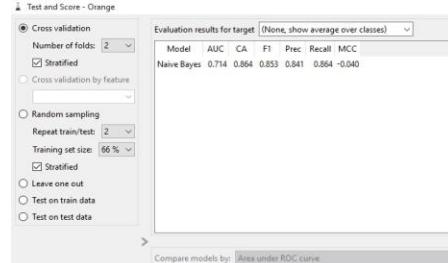


	Status	User	Provider	Reg. Inst.
1	berhasil	1.2		2
2	berhasil	2.1		4
3	berhasil	3.2		2
4	berhasil	4.2		2
5	berhasil	5.2		2
6	berhasil	6.2		2
7	berhasil	7.2		2
8	berhasil	8.2		2
9	berhasil	9.2		2
10	berhasil	10.2		2
11	berhasil	11.2		2
12	berhasil	12.2		2
13	berhasil	13.2		3
14	berhasil	14.1		4
15	berhasil	15.2		2
16	berhasil	16.2		2
17	gagal	17.2		2
18	gagal	18.2		2
19	gagal	19.2		2

Gambar 3. Data yang diproses

Tahap kelima adalah pengujian dan evaluasi model. Model yang telah dibangun diuji menggunakan data uji untuk mengetahui kinerja klasifikasi dalam memprediksi keberhasilan transaksi. Evaluasi dilakukan dengan menggunakan metrik performa seperti confusion matrix, Scatter Plot, Line plot, Distributions (diagram batang). Hasil evaluasi ini digunakan untuk menilai apakah model yang dibangun telah memenuhi harapan penelitian(Rizkiyanto, 2025).

Pada tahap pengujian dapat dilihat pada gambar sebagai berikut:

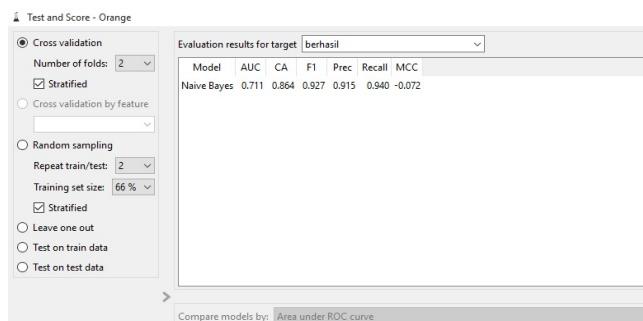


Gambar 4. Test & Score

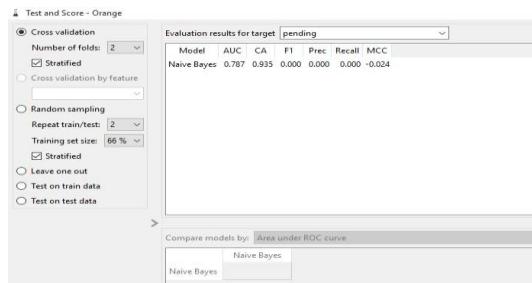
Penjelasan pada table Test & Score sebagai berikut:

Tabel 1. Keterangan pada Test & Score

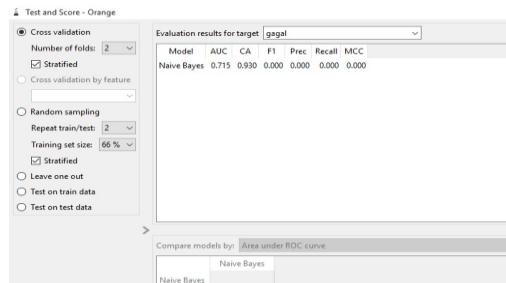
Metrik	Nilai	Penjelasan
AUC	0.714	Kemampuan model membedakan kelas positif dan negatif. Nilai 0,7 berarti cukup baik (di atas 0,5 = lebih baik dari tebakan acak).
CA (Classification Accuracy)	0.864	Akurasi model, artinya 86,4% data diklasifikasikan dengan benar.
F1-score	0.853	Rata-rata harmonis antara Precision dan Recall. Nilai tinggi menandakan keseimbangan yang baik.
Precision	0.841	Dari semua prediksi positif, 84,1% benar.
Recall	0.864	Dari semua data yang benar-benar positif, 86,4% berhasil dikenali model.
MCC (Matthews Correlation Coefficient)	-0.040	Mengukur korelasi prediksi dan label asli. Nilai mendekati 0 atau negatif menunjukkan hubungan prediksi masih lemah atau ada ketidakseimbangan kelas.



Gambar 5. Test & Score Pada Bagian Berhasil



Gambar 6. Test & Score Pada Bagian Pending



Gambar 7. Test & Score Pada Bagian Gagal

Tahap terakhir adalah analisis hasil dan penarikan kesimpulan. Pada tahap ini, hasil pengujian(Punkastyo, 2024) dianalisis untuk mengetahui tingkat keberhasilan metode *Naive Bayes* dalam memprediksi status transaksi. Analisis ini menjadi dasar dalam penarikan kesimpulan serta memberikan rekomendasi pengembangan sistem di masa mendatang.

2.2 Metode Klasifikasi Naïve Bayes

Metode penyelesaian masalah dalam penelitian ini menggunakan algoritma *Naive Bayes Classifier*, yaitu metode klasifikasi probabilistik yang didasarkan pada teorema Bayes dengan asumsi independensi antar atribut (Prasetya et al., 2024). Asumsi independensi ini menyatakan bahwa setiap atribut pada suatu data dianggap tidak saling memengaruhi terhadap atribut lainnya dalam menentukan kelas, sehingga perhitungan probabilitas menjadi lebih sederhana dan efisien. Meskipun asumsi tersebut bersifat “naïf”, algoritma ini terbukti mampu menghasilkan performa klasifikasi yang baik pada berbagai kasus nyata, termasuk pada data transaksi digital.

Secara umum, *Naive Bayes* bertujuan untuk menentukan probabilitas suatu data termasuk ke dalam kelas tertentu berdasarkan informasi atribut yang dimilikinya. Dalam penelitian ini, kelas yang digunakan adalah status transaksi, yaitu transaksi sukses dan transaksi gagal. Proses klasifikasi dilakukan dengan memilih kelas yang memiliki nilai probabilitas posterior terbesar.

Dasar matematis algoritma *Naive Bayes* mengacu pada teorema Bayes, yang dirumuskan sebagai berikut:

$$P(C|X) = \frac{P(X|C)P(C)}{P(X)}$$

Keterangan:

$P(C|X)$ adalah probabilitas posterior, yaitu peluang suatu data X termasuk ke dalam kelas C
 $P(X|C)$ adalah probabilitas bersyarat (*likelihood*), yaitu peluang munculnya data X jika diketahui kelas C ;
 $P(C)$ adalah probabilitas awal (*prior probability*) dari kelas C ;
 $P(X)$ adalah probabilitas kemunculan data X .

Pada proses klasifikasi, nilai $P(X)$ bersifat konstan untuk seluruh kelas sehingga dapat diabaikan. Dengan demikian, keputusan klasifikasi ditentukan berdasarkan nilai terbesar dari hasil perkalian $P(X|C)$ dan $P(C)$.

Karena data transaksi terdiri dari beberapa atribut, maka nilai X dinyatakan sebagai sekumpulan atribut ($x_1, x_2, x_3, \dots, x_n$). Dengan asumsi independensi antar atribut, maka probabilitas bersyarat dapat dihitung menggunakan persamaan berikut:

$$P(X|C) = \prod_{i=1}^n P(X_i|C)$$

Sehingga, rumus *Naive Bayes* secara manual dapat dituliskan sebagai:

$$P(C|X) \propto P(C) \prod_{i=1}^n P(X_i|C)$$

Dalam penelitian ini, atribut x_i meliputi operator seluler, nominal pulsa, waktu transaksi, dan atribut pendukung lainnya. Probabilitas awal $P(C)$ dihitung berdasarkan proporsi masing-masing kelas pada data latih, sedangkan probabilitas bersyarat $P(x_i|C)$ dihitung berdasarkan frekuensi kemunculan atribut terhadap kelas tertentu.

Setelah seluruh nilai probabilitas diperoleh, proses klasifikasi dilakukan dengan membandingkan nilai probabilitas posterior dari setiap kelas. Kelas dengan nilai probabilitas terbesar dipilih sebagai hasil prediksi status transaksi.

Pendekatan ini memungkinkan sistem untuk melakukan prediksi secara objektif berdasarkan pola statistik yang terbentuk dari data historis transaksi.

Pengujian metode *Naive Bayes* dilakukan dengan membandingkan hasil prediksi model terhadap data aktual pada data uji. Evaluasi hasil klasifikasi disajikan menggunakan *confusion matrix* untuk mengetahui jumlah prediksi benar dan salah pada masing-masing kelas. Selain itu, visualisasi hasil klasifikasi ditampilkan melalui *scatter plot*, *line plot*, dan *distribution* (diagram batang) untuk memberikan gambaran pola distribusi data. Hasil evaluasi kuantitatif juga disajikan dalam bentuk tabel performa guna menilai tingkat akurasi dan keandalan model yang diusulkan.

Dengan memasukkan pengertian dan perhitungan manual ini, diharapkan algoritma *Naive Bayes* dapat dipahami tidak hanya dari sisi implementasi, tetapi juga dari aspek teoritis dan matematis. Model yang dihasilkan diharapkan mampu berfungsi sebagai pendukung pengambilan keputusan pada sistem Top Up AY Pulsa dalam meningkatkan keandalan penentuan status transaksi(Irmayani, 2021).

Dataset di konversikan ke nilai numerik karena pada Aplikasi yang digunakan seperti Orange tidak bisa sepenuhnya membaca teks, karna pada penelitian ini kami mencari target pda status keberhasilan transaksi

Tabel 2. Data Sebelum Di Konversikan

NO	User	Provider	Hrg Jual	Status
1	ihsanbyong	DANA NON ADMIN VIA DIRECT DANA	1085	Berhasil
2	ihsanbyong	XL Data Bebas Puas 5K/H	150200	Berhasil
3	adminaypulsa	DANA NON ADMIN VIA DIRECT DANA	8085	Berhasil
4	ihsanbyong	DANA NON ADMIN VIA DIRECT DANA	4085	Berhasil
5	adminaypulsa	DANA NON ADMIN VIA DIRECT DANA	8085	Berhasil
6	ihsanbyong	DANA NON ADMIN VIA DIRECT DANA	1085	Berhasil
7	adminaypulsa	DANA NON ADMIN VIA DIRECT DANA	8085	Berhasil
8	ihsanbyong	DANA NON ADMIN VIA DIRECT DANA	2085	Berhasil
9	ihsanbyong	DANA NON ADMIN VIA DIRECT DANA	2085	Berhasil
10	adminaypulsa	DANA NON ADMIN VIA DIRECT DANA	5085	Berhasil
11	adminaypulsa	DANA NON ADMIN VIA DIRECT DANA	5085	Berhasil
200	ihsanbyong	DANA NON ADMIN VIA DIRECT DANA	1085	Berhasil

Tabel 3. Data Sesudah Di Konversikan

User	Provider	Hrg Jual	Status
1	2	2	berhasil
2	1	4	berhasil
3	2	2	berhasil
4	2	2	berhasil
5	2	2	berhasil
6	2	2	berhasil
7	2	2	berhasil
8	2	2	berhasil
9	2	2	berhasil
10	2	2	berhasil
11	2	2	berhasil
200	2	2	berhasil

Keterangan konversi setiap tabel:

Tabel 4. Provider

No	Provider	Nilai
1	DANA NON ADMIN VIA DIRECT DANA	2
2	XL Data Bebas Puas 5K/H	1

Tabel 5. *harga jual*

No	Harga Jual	Nilai
1	≤ 50.000	2
2	≥ 50.000	4

3. HASIL DAN PEMBAHASAN

3.1 Hasil Penerapan Algoritma Naive Bayes

Pada penelitian ini, algoritma *Naive Bayes Classifier* diterapkan untuk memprediksi status keberhasilan transaksi pada sistem Top Up AY Pulsa. Dataset yang digunakan merupakan data transaksi yang telah melalui tahap pra-pemrosesan, meliputi pembersihan data, transformasi atribut kategorikal ke dalam bentuk numerik, serta penentuan atribut target berupa status transaksi.

Proses penerapan dilakukan menggunakan aplikasi Orange dengan memanfaatkan data latih untuk membangun model klasifikasi. Model Naive Bayes dibentuk berdasarkan perhitungan probabilitas awal (*prior probability*) masing-masing kelas serta probabilitas bersyarat (*likelihood*) dari setiap atribut terhadap kelas target. Kelas yang digunakan dalam penelitian ini meliputi transaksi berhasil, pending, dan gagal(M. Botchey et al., 2020).

Model yang dihasilkan selanjutnya digunakan untuk melakukan prediksi terhadap data uji. Hasil prediksi inilah yang kemudian dianalisis dan dievaluasi untuk mengetahui tingkat keberhasilan algoritma Naive Bayes dalam mengklasifikasikan status transaksi(Saputra & Handayani, 2022).

3.2 Evaluasi dan Kinerja Model

Evaluasi kinerja model bertujuan untuk mengukur kemampuan algoritma Naive Bayes dalam memprediksi status keberhasilan transaksi pada sistem Top Up AY Pulsa. Pengujian dilakukan menggunakan data uji yang berbeda dari data latih guna memperoleh gambaran objektif terhadap performa model klasifikasi. Proses evaluasi ini penting untuk memastikan bahwa model yang dibangun tidak hanya mampu mempelajari data latih, tetapi juga memiliki kemampuan generalisasi yang baik pada data baru.

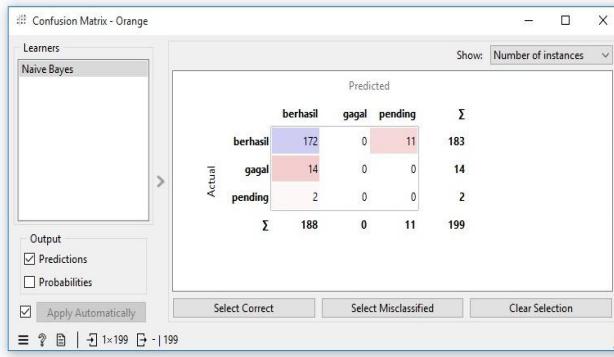
Pengukuran kinerja model dilakukan dengan menggunakan beberapa metrik evaluasi, yaitu akurasi, precision, recall, F1-score, dan Area Under Curve (AUC). Akurasi digunakan untuk menunjukkan proporsi prediksi yang benar terhadap keseluruhan data, sedangkan precision dan recall digunakan untuk mengukur ketepatan dan kelengkapan prediksi pada masing-masing kelas transaksi. F1-score digunakan sebagai ukuran keseimbangan antara precision dan recall, sementara AUC digunakan untuk menilai kemampuan model dalam membedakan kelas transaksi secara keseluruhan. Penggunaan metrik evaluasi tersebut sejalan dengan pendekatan evaluasi model klasifikasi Naive Bayes pada transaksi digital yang dilakukan oleh(F. E. Botchey et al., 2020).

Selain itu, evaluasi juga dilakukan menggunakan confusion matrix untuk melihat distribusi prediksi benar dan salah pada setiap kelas transaksi, yaitu berhasil, pending, dan gagal. Pendekatan evaluasi berbasis confusion matrix ini banyak digunakan dalam penelitian prediksi kegagalan transaksi karena mampu memberikan gambaran yang lebih rinci mengenai kesalahan klasifikasi pada masing-masing kelas ((“Predictive Analytics for Transaction Failures in Payment Gateways,” 2022).

Hasil evaluasi yang diperoleh kemudian dianalisis untuk menilai tingkat keandalan model Naive Bayes dalam memprediksi status transaksi. Nilai-nilai metrik evaluasi tersebut menjadi dasar dalam menentukan apakah model yang dibangun telah memenuhi tujuan penelitian serta layak digunakan sebagai pendukung pengambilan keputusan pada sistem Top Up AY Pulsa.

3.2.1 Confusion Matrix

Confusion matrix digunakan untuk menggambarkan perbandingan antara hasil prediksi model dan data aktual. Matriks ini menunjukkan jumlah data yang diklasifikasikan secara benar maupun salah pada masing-masing kelas transaksi.



Gambar.8. Tabel. Confusion Matrix

Berdasarkan confusion matrix yang diperoleh, dapat diketahui bahwa sebagian besar data transaksi berhasil diklasifikasikan dengan benar oleh model Naive Bayes. Hal ini menunjukkan bahwa algoritma Naive Bayes memiliki kemampuan yang cukup baik dalam mempelajari pola probabilistik dari data transaksi digital, khususnya pada kelas transaksi berhasil yang memiliki jumlah data dominan. Keberhasilan klasifikasi ini mengindikasikan bahwa atribut transaksi yang digunakan mampu merepresentasikan karakteristik status transaksi secara memadai.

Namun demikian, masih ditemukan kesalahan klasifikasi pada beberapa data, terutama pada kelas pending dan gagal. Kesalahan ini disebabkan oleh adanya kemiripan pola atribut antar kelas transaksi, sehingga model mengalami kesulitan dalam membedakan batas kelas secara tegas. Selain itu, ketidakseimbangan distribusi data antar kelas juga berpengaruh terhadap meningkatnya tingkat kesalahan prediksi pada kelas minoritas. Kondisi ini sejalan dengan temuan (Lokanan et al., 2023) yang menyatakan bahwa algoritma Naive Bayes cenderung mengalami penurunan performa pada kelas transaksi yang memiliki jumlah data lebih sedikit akibat overlapping feature dan class imbalance.

3.2.2 Nilai Test & Score

Pengukuran kinerja model dilakukan menggunakan metrik AUC, Classification Accuracy (CA), Precision, Recall, F1-score, serta Matthews Correlation Coefficient (MCC).

Tabel 5. Hasil Test & Score Model Naive Bayes

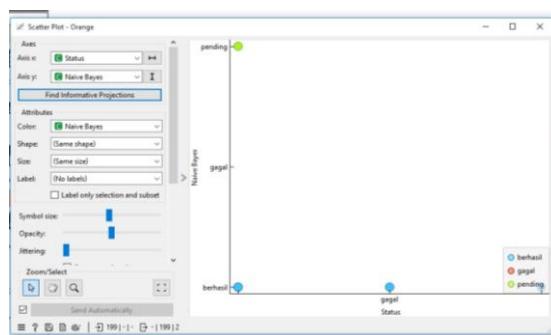
Metrik	Nilai
AUC	0.714
Accuracy	0.864
Precision	0.841
Recall	0.864
F1-score	0.853
MCC	-0.040

Nilai akurasi sebesar 86,4% menunjukkan bahwa model Naive Bayes mampu mengklasifikasikan sebagian besar data transaksi dengan benar, sehingga dapat dikatakan bahwa model memiliki performa yang cukup baik dalam mempelajari pola data transaksi top up pulsa. Nilai Area Under Curve (AUC) sebesar 0,714 mengindikasikan bahwa model memiliki kemampuan yang memadai dalam membedakan kelas transaksi, terutama antara transaksi berhasil dan tidak berhasil. Selain itu, nilai precision, recall, dan F1-score yang relatif tinggi menunjukkan adanya keseimbangan antara ketepatan prediksi dan kemampuan model dalam mengenali seluruh data yang relevan, sehingga model tidak hanya akurat tetapi juga cukup konsisten dalam proses klasifikasi.

Namun demikian, nilai Matthews Correlation Coefficient (MCC) yang mendekati nol menunjukkan bahwa korelasi antara hasil prediksi model dan label aktual masih tergolong lemah. Kondisi ini mengindikasikan bahwa meskipun tingkat akurasi model tinggi, performa klasifikasi belum sepenuhnya stabil pada seluruh kelas transaksi. Salah satu faktor utama yang memengaruhi rendahnya nilai MCC adalah ketidakseimbangan jumlah data pada masing-masing kelas transaksi, di mana kelas transaksi berhasil memiliki proporsi data yang jauh lebih besar dibandingkan kelas pending dan gagal. Temuan ini sejalan dengan penelitian (Arsanto, 2024) yang menyatakan bahwa algoritma Naive Bayes cenderung menghasilkan nilai MCC yang rendah pada dataset dengan distribusi kelas tidak seimbang, meskipun nilai akurasi dan F1-score relatif tinggi.

3.2.3 Scatter Plot

Scatter plot digunakan untuk memvisualisasikan pola distribusi hasil klasifikasi berdasarkan kelas transaksi. Grafik ini memberikan gambaran mengenai pemisahan data antar kelas yang dihasilkan oleh model.



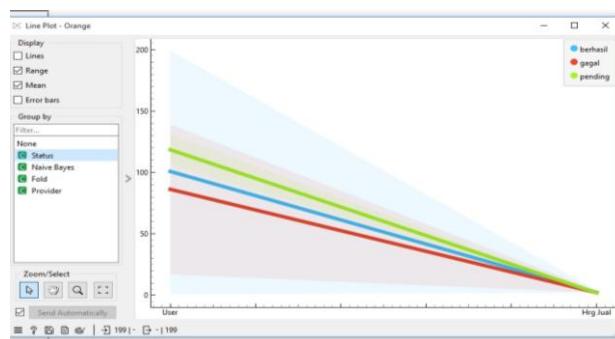
Gambar 9. Scatter Plot

Berdasarkan scatter plot yang diperoleh, terlihat bahwa sebagian besar data transaksi terdistribusi pada kelompok kelas yang sesuai dengan hasil prediksi model. Hal ini menunjukkan bahwa algoritma Naive Bayes mampu memetakan sebagian besar pola data transaksi secara cukup jelas, terutama pada kelas transaksi berhasil yang memiliki karakteristik atribut yang lebih dominan. Visualisasi ini memperlihatkan bahwa model dapat membedakan kelas transaksi dengan tingkat pemisahan yang relatif baik.

Namun demikian, masih terdapat sejumlah data yang berada pada area tumpang tindih antar kelas, khususnya antara kelas pending dan gagal. Kondisi ini mengindikasikan adanya kemiripan karakteristik atribut transaksi pada kedua kelas tersebut, sehingga menyebabkan batas antar kelas menjadi kurang tegas. Fenomena tumpang tindih data antar kelas ini merupakan salah satu tantangan umum dalam penerapan algoritma klasifikasi probabilistik pada data transaksi digital, terutama ketika beberapa faktor operasional memiliki pengaruh yang saling berkaitan. Temuan ini sejalan dengan penelitian (Yussiff et al., 2024) yang menyatakan bahwa overlapping feature antar kelas dapat menurunkan kejelasan pemisahan kelas pada model Naive Bayes dan berdampak pada performa klasifikasi pada kelas minoritas(Orange Data Mining, 2023)

3.2.4 Line Plot

Line plot digunakan untuk menunjukkan perbandingan jumlah prediksi benar dan prediksi salah pada masing-masing kelas transaksi. Grafik ini memperlihatkan kinerja model secara visual terhadap setiap kategori kelas.

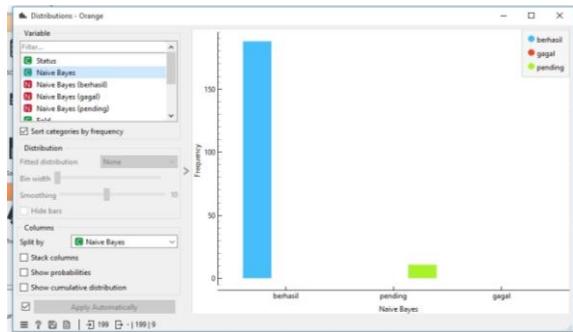


Gambar. 11 Line Plot

Hasil line plot menunjukkan bahwa jumlah prediksi benar lebih dominan dibandingkan prediksi salah, terutama pada kelas transaksi berhasil. Temuan ini menguatkan hasil evaluasi bahwa algoritma Naive Bayes cukup efektif dalam memprediksi status keberhasilan transaksi(Arsanto, 2024).

3.3 Analisis Distribusi Data

Analisis distribusi data dilakukan untuk mengetahui proporsi jumlah data pada setiap kelas transaksi. Distribusi data ditampilkan dalam bentuk diagram batang.



Gambar. 12 Diagram Batang

Berdasarkan diagram distribusi, terlihat bahwa kelas transaksi berhasil memiliki jumlah data yang lebih besar dibandingkan kelas pending dan gagal. Ketidakseimbangan distribusi data ini berpotensi memengaruhi performa model, terutama dalam mengklasifikasikan kelas dengan jumlah data yang lebih sedikit(Adeyemi, 2022).

Ketidakseimbangan data tersebut menjadi salah satu faktor penyebab terjadinya kesalahan klasifikasi dan rendahnya nilai MCC pada hasil evaluasi model.

3.4 Pembahasan

Hasil penelitian menunjukkan bahwa algoritma Naive Bayes mampu memberikan performa yang cukup baik dalam memprediksi status transaksi pada sistem Top Up AY Pulsa. Hal ini ditunjukkan oleh nilai akurasi, precision, recall, dan F1-score yang relatif tinggi. Keunggulan Naive Bayes dalam kesederhanaan perhitungan dan efisiensi komputasi menjadikan algoritma ini sesuai untuk diterapkan pada data transaksi(Yussiff et al., 2024).

Namun demikian, hasil evaluasi juga memperlihatkan beberapa keterbatasan, terutama terkait ketidakseimbangan distribusi data antar kelas. Kondisi ini menyebabkan rendahnya nilai MCC serta kesalahan klasifikasi pada kelas pending dan gagal. Oleh karena itu, diperlukan upaya pengembangan lebih lanjut, seperti penerapan teknik penyeimbangan data atau perbandingan dengan algoritma klasifikasi lain, untuk meningkatkan kinerja model. Secara keseluruhan, penelitian ini membuktikan bahwa algoritma Naive Bayes dapat digunakan sebagai metode pendukung pengambilan keputusan dalam memprediksi keberhasilan transaksi pada sistem Top Up AY Pulsa.

4. KESIMPULAN

Penelitian ini bertujuan untuk menerapkan algoritma *Naive Bayes Classifier* dalam memprediksi status keberhasilan transaksi pada sistem Top Up AY Pulsa sebagai solusi terhadap permasalahan ketidakpastian status transaksi yang sering dialami oleh pengguna. Berdasarkan seluruh tahapan penelitian yang telah dilakukan, mulai dari identifikasi masalah, pengumpulan data transaksi, pra-pemrosesan data, penerapan algoritma Naive Bayes, hingga proses evaluasi model, dapat disimpulkan bahwa algoritma Naive Bayes mampu memberikan kinerja yang cukup baik dalam mengklasifikasikan status transaksi. Hasil pengujian menunjukkan bahwa model berhasil mencapai nilai akurasi sebesar 86,4% serta didukung oleh nilai precision, recall, dan F1-score yang relatif tinggi, yang mengindikasikan bahwa model memiliki kemampuan yang baik dalam mengenali pola transaksi berhasil maupun transaksi gagal. Selain itu, nilai AUC sebesar 0,714 menunjukkan bahwa model memiliki kapasitas yang cukup dalam membedakan kelas transaksi. Meskipun demikian, hasil evaluasi juga mengungkapkan adanya keterbatasan pada model, khususnya terkait ketidakseimbangan distribusi data antara kelas transaksi berhasil, pending, dan gagal, yang berdampak pada rendahnya nilai Matthews Correlation Coefficient serta terjadinya kesalahan klasifikasi pada kelas tertentu. Kendati demikian, secara keseluruhan penerapan algoritma Naive Bayes terbukti dapat menjadi solusi awal dalam membantu prediksi status transaksi dan mendukung pengambilan keputusan pada sistem Top Up AY Pulsa, sehingga diharapkan dapat meningkatkan keandalan sistem dan mengurangi risiko kegagalan transaksi di masa mendatang.

UCAPAN TERIMAKASIH

Penulis mengucapkan terima kasih kepada seluruh pihak yang telah memberikan kontribusi dan dukungan dalam pelaksanaan penelitian ini. Ucapan terima kasih disampaikan kepada pengelola sistem Top Up AY Pulsa yang telah memberikan izin serta data transaksi yang digunakan sebagai bahan dalam penelitian. Penulis juga mengucapkan terima kasih kepada dosen pembimbing dan rekan-rekan yang telah memberikan arahan, masukan, serta saran yang konstruktif

Prosiding Seminar Nasional Inovasi dan Riset Multidisiplin

Vol 1, No 1, Februari 2026, Hal 24 - 34

ISSN XXXX-XXXX (Media Online)

Website : <https://journal.hdgi.org/index.php/sinergi/>

selama proses penyusunan dan penyelesaian penelitian ini. Selain itu, penulis menyampaikan apresiasi kepada institusi dan pihak terkait yang telah menyediakan fasilitas dan sarana pendukung sehingga penelitian ini dapat terlaksana dengan baik. Semoga hasil penelitian ini dapat memberikan manfaat bagi pengembangan ilmu pengetahuan serta menjadi referensi bagi penelitian selanjutnya.

REFERENCES

- Adeyemi, A. (2022). Predicting Mobile Money Transaction Fraud using Machine Learning Algorithms. *ResearchGate Preprint*. https://www.researchgate.net/publication/370085325_Predicting_Mobile_Money_Transaction_Fraud_using_Machine_Learning_Algorithms
- Arsanto, A. T. (2024). Optimization of the Naïve Bayes Algorithm with Handling Class Imbalance for Card Fraud Classification. *Sistemasi: Jurnal Sistem Informasi*, 13(1), 45–55. <https://sistemasif.tftk.unisi.ac.id/index.php/stmsi/article/view/4719>
- Botchey, F. E., Qin, Z., & Hughes-Lartey, K. (2020). Mobile Money Fraud Prediction: A Cross-Case Analysis on the Efficiency of Support Vector Machines, Gradient Boosted Decision Trees, and Naïve Bayes Algorithms. *Information*, 11(8), 383. <https://doi.org/10.3390/info11080383>
- Botchey, M., Qin, Z., & Hughes-Lartey, K. (2020). A Comparative Analysis of Machine Learning Techniques for Mobile Money Fraud Detection. *IEEE Access*, 8, 193540–193557. <https://doi.org/10.1109/ACCESS.2020.3033416>
- Irmayani, W. (2021). Visualisasi Data pada Data Mining Menggunakan Orange. *Jurnal Khatulistiwa Informatika*. <https://ejournal.bsi.ac.id/ejurnal/index.php/khatulistiwa/article/download/9593/4876>
- Lokanan, M. E., Hasan, R., & Alshamsi, A. (2023). Predicting Mobile Money Transaction Fraud using Machine Learning. *Applied Artificial Intelligence Letters*, 4(2), e85. <https://doi.org/10.1002/ail2.85>
- Orange Data Mining. (2023). *Naïve Bayes — Widget Catalog*. <https://orangedatamining.com/widget-catalog/model/naivebayes/>
- Prasetya, I. K., Putra, I. G. A. P., & Nugraha, I. G. N. A. (2024). Comparing the Performance of Multivariate Hotelling's T^2 Control Chart and Naïve Bayes Classifier for Credit Card Fraud Detection. *IPTEK The Journal for Technology and Science*, 35(2), 67–75. <https://iptek.its.ac.id/index.php/inferensi/article/view/18755>
- Predictive Analytics for Transaction Failures in Payment Gateways. (2022). *International Journal of Intelligent Systems and Applications in Engineering*, 10(4), 356–364. <https://ijisae.org/index.php/IJISAE/article/view/7679>
- Punkastyo, D. A. (2024). Implementasi Data Mining Menggunakan Algoritma Naïve Bayes. *Journal of Software and Computer Engineering (JSCE)*. <https://jurnal.unpacti.ac.id/index.php/JSCE/article/view/1073>
- Rahman, A., & Putra, D. (2023). Application of Support Vector Machine and Naïve Bayes for Transaction Data Classification. *Journal of Information and Data Technology*, 5(2), 101–109. <https://jidt.org/jidt/article/download/462/267>
- Rahman, R. M. R. (2024). Online Payment Fraud Prediction with Machine Learning Using Naïve Bayes. *Journal of Scientific Research and Engineering*. <https://mail.shmpublisher.com/index.php/josre/article/view/343>
- Rizkiyanto, R. (2025). Predicting Consumer Payment Preferences Using Naïve Bayes. *International Conference on Payment Systems*. <https://ejournal.darunnajah.ac.id/index.php/icop/article/view/621>
- Saputra, R., & Handayani, S. (2022). Penerapan Algoritma Naïve Bayes dalam Klasifikasi Data Menggunakan Aplikasi Orange Mining. *INTECOM Journal*, 2(3), 211–219. <https://journal.ipm2kpe.or.id/index.php/INTECOM/article/view/16910>
- Yussiff, A. S., Abdulai, J. D., & Issahaku, A. R. (2024). The Best Machine Learning Model for Fraud Detection on E-Platforms: A Systematic Literature Review. *Computer Science and Information Technologies*, 5(1), 1–15. <https://iaesprime.com/index.php/csit/article/view/408>