



Penerapan XGBoost dan SMOTE untuk Klasifikasi Metode Pembayaran Pelanggan pada Data Transaksi Tidak Seimbang

Fadilah Nuria Handayani*, Vihi Atina, Aprilisa Arumsari

Fakultas Ilmu Komputer, Program Studi Sistem Informasi, Univesitas Duta Bangsa, Surakarta, Indonesia

Email: ^{1,*}dhyllafadilla26@gmail.com, ²vihi_atina@udb.ac.id, ³aprilisa_arumsari@udb.ac.id³

Email Penulis Korespondensi: dhyllafadilla26@gmail.com

Abstrak—Meningkatnya penggunaan metode pembayaran digital dalam transaksi penjualan menunjukkan pentingnya analisis untuk memahami perilaku pembayaran pelanggan. Penelitian ini bertujuan untuk mengklasifikasikan metode pembayaran pelanggan menggunakan algoritma XGBoost serta mengevaluasi pengaruh penerapan Synthetic Minority Over-sampling Technique (SMOTE) dalam menangani ketidakseimbangan data. Dataset yang digunakan terdiri dari 287.422 data transaksi yang diproses menggunakan kerangka kerja Cross Industry Standard Process for Data Mining (CRISP-DM), yang meliputi tahap pemahaman data, persiapan data, pemodelan, dan evaluasi. Hasil eksperimen menunjukkan bahwa model XGBoost tanpa SMOTE memperoleh nilai accuracy sebesar 92,83% dan ROC-AUC sebesar 0,7759, namun memiliki kinerja yang rendah dalam mendeteksi kelas minoritas (card) dengan nilai recall sebesar 0,14, yang menunjukkan adanya bias terhadap kelas mayoritas. Setelah penerapan SMOTE, kemampuan model dalam mendeteksi kelas minoritas meningkat dengan nilai recall menjadi 0,53 dan F1-score sebesar 0,28, meskipun diikuti oleh penurunan accuracy menjadi 78,50% dan ROC-AUC menjadi 0,7529. Penelitian ini berkontribusi melalui penerapan XGBoost dan SMOTE untuk menangani ketidakseimbangan data pada klasifikasi metode pembayaran pelanggan serta mengevaluasi performa model menggunakan berbagai metrik klasifikasi. Hasil ini menunjukkan adanya trade-off antara peningkatan sensitivitas terhadap kelas minoritas dan penurunan kinerja keseluruhan model. Penelitian ini juga menegaskan bahwa evaluasi model pada data tidak seimbang tidak dapat hanya mengandalkan accuracy, tetapi perlu mempertimbangkan metrik lain seperti precision, recall, F1-score, dan ROC-AUC agar penilaian performa lebih komprehensif.

Kata Kunci: XGBoost; SMOTE; Klasifikasi; Metode Pembayaran; Data Tidak Seimbang

Abstract—The increasing use of digital payment methods in retail transactions highlights the importance of analyzing customer payment behavior. This study aims to classify customer payment methods using the XGBoost algorithm and to evaluate the effect of Synthetic Minority Over-sampling Technique (SMOTE) in handling class imbalance. The dataset consists of 287,422 transaction records processed using the Cross Industry Standard Process for Data Mining (CRISP-DM) framework, which includes data understanding, data preparation, modeling, and evaluation stages. Experimental results show that the XGBoost model without SMOTE achieved an accuracy of 92.83% and a ROC-AUC of 0.7759, but performed poorly in identifying the minority class (Card), with a recall of 0.14, indicating a strong bias toward the majority class. After applying SMOTE, the model's ability to detect the minority class improved, with recall increasing to 0.53 and F1-score reaching 0.28, although accuracy decreased to 78.50% and ROC-AUC to 0.7529. This study contributes by implementing XGBoost combined with the SMOTE method for customer payment method classification on imbalanced data and evaluating model performance using multiple classification metrics. This trade-off indicates that SMOTE improves sensitivity toward minority classes while affecting overall predictive accuracy. The findings highlight that evaluation of imbalanced classification models should not rely solely on accuracy but must also consider precision, recall, F1-score, and ROC-AUC to obtain a more comprehensive assessment. Overall, while SMOTE enhances minority class detection, further improvements are still required to achieve more stable and reliable classification performance.

Keywords: XGBoost; SMOTE; Classification; Payment Methods; Imbalanced Data

1. PENDAHULUAN

Seiring berkembangnya sistem digital saat ini telah memengaruhi berbagai aktivitas masyarakat, termasuk dalam proses transaksi penjualan dan sistem pembayaran pelanggan. Jika sebelumnya transaksi lebih sering dilakukan secara tunai, kini banyak masyarakat mulai menggunakan metode pembayaran non-tunai, seperti penggunaan kartu maupun aplikasi pembayaran digital karena dianggap lebih praktis, cepat, dan memudahkan proses pembayaran [1][2]. Meskipun demikian, metode pembayaran tunai (*cash*) masih banyak digunakan, terutama pada sektor usaha kecil dan menengah (UMKM) yang belum sepenuhnya terintegrasi dengan layanan keuangan digital. Kondisi ini menunjukkan bahwa preferensi pelanggan terhadap metode pembayaran masih beragam, sehingga diperlukan analisis yang lebih mendalam untuk memahami pola tersebut.

Permasalahan utama dalam penelitian ini terletak pada sulitnya mengidentifikasi pola preferensi metode pembayaran pelanggan secara akurat, terutama ketika data transaksi memiliki ketidakseimbangan kelas (*imbalanced dataset*). Data transaksi umumnya didominasi oleh satu jenis metode pembayaran, sehingga model lebih sering mengenali pola pada kelas dengan jumlah data yang lebih banyak dibandingkan kelas dengan jumlah data yang lebih sedikit [3][4]. Dampaknya, model dapat menghasilkan nilai akurasi yang tinggi, tetapi tidak benar-benar mencerminkan kemampuan model dalam mengklasifikasikan seluruh kelas secara seimbang. Namun, penilaian performa model tidak cukup hanya melihat nilai akurasi saja, melainkan juga perlu memperhatikan metrik evaluasi lain seperti *precision*, *recall*, dan *F1-score* sehingga hasil kinerja model dapat dianalisis dengan lebih menyeluruh. [5].

Dalam beberapa tahun terakhir, berbagai penelitian telah dilakukan untuk mengklasifikasikan perilaku pelanggan maupun permasalahan prediktif lainnya menggunakan algoritma machine learning. Indrayana dkk. [6] menerapkan algoritma Decision Tree J48 untuk mengklasifikasikan metode pembayaran pelanggan di supermarket dan memperoleh tingkat akurasi sebesar 54%. Hasil tersebut menunjukkan bahwa model masih memiliki keterbatasan dalam mengenali



pola data secara optimal. Penelitian lain yang dilakukan oleh Pahlevi dkk. [7] menggunakan algoritma Random Forest untuk klasifikasi kelayakan kredit dan menghasilkan akurasi sebesar 78,60%, yang menunjukkan bahwa pendekatan ensemble learning mampu memberikan performa yang lebih baik dibandingkan metode klasifikasi konvensional.

Perkembangan metode ensemble learning juga mendorong penggunaan algoritma boosting, salah satunya XGBoost. Fatima dkk. [8] menunjukkan bahwa XGBoost mampu menghasilkan performa klasifikasi yang tinggi dengan nilai F1-score mencapai 0,92 pada prediksi perilaku konsumen. Hasil serupa juga ditemukan oleh Lin [9] yang menyatakan bahwa algoritma boosting seperti XGBoost memberikan kemampuan prediksi yang baik dalam analisis perilaku konsumen pada lingkungan e-commerce. Selain itu, Halim dan Azmi [10] menunjukkan bahwa penerapan XGBoost yang dipadukan dengan teknik penanganan data tidak seimbang mampu meningkatkan kemampuan klasifikasi pada kasus credit card default. Selain XGBoost, algoritma boosting lain yang banyak digunakan dalam tugas klasifikasi adalah LightGBM dan CatBoost. Berbagai penelitian menunjukkan bahwa ketiga algoritma tersebut mampu memberikan performa yang kompetitif pada data tabular. XGBoost yang dipadukan dengan SMOTE berhasil memperoleh akurasi sebesar 94,5% pada klasifikasi obesitas [11]. Sementara itu, CatBoost mencapai akurasi sebesar 98,47% pada klasifikasi risiko stunting [12]. Sedangkan LightGBM menunjukkan performa terbaik pada klasifikasi Human Development Index dibandingkan Random Forest dan XGBoost [13]. Temuan tersebut menunjukkan bahwa algoritma boosting memiliki kemampuan yang baik dalam menyelesaikan berbagai permasalahan klasifikasi. Dalam penelitian ini, XGBoost dipilih karena memiliki kemampuan yang baik dalam menangani hubungan kompleks antar fitur serta menunjukkan peningkatan performa ketika dikombinasikan dengan teknik penyeimbangan data seperti SMOTE.


Meskipun berbagai penelitian terdahulu telah menunjukkan bahwa algoritma boosting, khususnya XGBoost, mampu menghasilkan performa klasifikasi yang baik, masih terdapat beberapa kesenjangan penelitian yang perlu dikaji lebih lanjut. Penelitian Fatima dkk. [8] dan Lin [9] berfokus pada prediksi perilaku konsumen, Halim dan Azmi [10] menerapkan XGBoost dan SMOTE pada kasus *credit card default*, sedangkan Sukmawati dkk. [11], Pahlevi dkk. [12], dan Indah dkk. [13] mengimplementasikan algoritma boosting pada bidang kesehatan dan Human Development Index. Berdasarkan penelitian-penelitian tersebut, penelitian yang secara khusus menerapkan kombinasi XGBoost dan SMOTE untuk mengklasifikasikan metode pembayaran pelanggan pada data transaksi ritel masih sangat terbatas. Selain itu, belum banyak penelitian yang mengevaluasi pengaruh SMOTE terhadap kemampuan XGBoost dalam meningkatkan deteksi kelas minoritas menggunakan berbagai metrik evaluasi seperti accuracy, precision, recall, F1-score, ROC-AUC, dan Cohen's Kappa. Oleh karena itu, diperlukan penelitian lanjutan untuk mengisi kesenjangan tersebut.

Berdasarkan permasalahan dan research gap tersebut, penelitian ini bertujuan untuk membangun model klasifikasi metode pembayaran pelanggan menggunakan algoritma XGBoost serta mengevaluasi pengaruh penerapan SMOTE terhadap kinerja model pada data transaksi yang memiliki distribusi kelas tidak seimbang. Evaluasi dilakukan menggunakan metrik accuracy, precision, recall, F1-score, ROC-AUC, dan Cohen's Kappa sehingga evaluasi performa model dapat dilakukan secara lebih komprehensif. Kontribusi penelitian ini terletak pada penerapan kombinasi algoritma XGBoost dan metode SMOTE untuk klasifikasi metode pembayaran pelanggan pada data transaksi yang tidak seimbang, serta penyajian analisis perbandingan performa model sebelum dan sesudah penerapan SMOTE menggunakan berbagai metrik evaluasi. Hasil penelitian diharapkan dapat menjadi referensi bagi pengembangan model klasifikasi pada data transaksi penjualan serta mendukung pengambilan keputusan berbasis data.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini menggunakan metodologi *Cross Industry Standard Process for Data Mining (CRISP-DM)* sebagai kerangka kerja dalam proses pengolahan dan analisis data. *CRISP-DM* dipilih karena menyediakan tahapan yang sistematis dan terstruktur dalam pengembangan model data mining, mulai dari identifikasi permasalahan hingga evaluasi hasil model. Metodologi ini banyak digunakan dalam penelitian machine learning karena mampu membantu proses pembangunan model secara lebih terarah dan mudah direplikasi [14][15]. Tahapan penelitian yang diterapkan terdiri atas lima tahap utama, yaitu *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modeling*, dan *Evaluation*, sebagaimana ditunjukkan pada Gambar 1.



Gambar 1. Tahap Penelitian



Gambar 1 menunjukkan alur penelitian yang terdiri atas lima tahap utama, yaitu Business Understanding, Data Understanding, Data Preparation, Modeling, dan Evaluation.

- Tahap pertama adalah *business understanding*, Tahap ini dilakukan untuk memahami permasalahan dan tujuan penelitian. Permasalahan yang ditemukan adalah adanya ketidakseimbangan jumlah data pada metode pembayaran pelanggan, sehingga dapat memengaruhi kemampuan model dalam melakukan klasifikasi secara optimal..
- Tahap kedua adalah *data understanding*, yaitu tahap ini bertujuan untuk memahami karakteristik dataset transaksi dari CV Ekasa Technology. Analisis dilakukan terhadap struktur data, tipe data, jumlah data, distribusi kelas, serta identifikasi missing value dan data duplikat yang dapat memengaruhi proses pemodelan.
- Tahapan berikutnya adalah data preparation, Pada tahap ini dilakukan pembersihan data, transformasi data, serta pembentukan fitur yang digunakan dalam proses klasifikasi. Selain itu, diterapkan metode *Synthetic Minority Over-sampling Technique (SMOTE)* untuk menyeimbangkan jumlah data pada kelas minoritas sehingga distribusi data menjadi lebih merata dan model dapat mengenali pola data dengan lebih baik [16] .
- Tahap modeling yaitu membangun model klasifikasi menggunakan algoritma Extreme Gradient Boosting (XGBoost). Algoritma ini dipilih karena mampu mengolah data tabular dengan baik dan menghasilkan performa klasifikasi yang kompetitif [4][8]. Model dibangun menggunakan data training dan diuji menggunakan data testing untuk mengetahui kemampuan klasifikasinya.
- Tahap terakhir merupakan *evaluation*, yaitu mengukur kinerja model menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, *ROC-AUC*, dan *Cohen's Kappa* [17][18][19]. Evaluasi dilakukan menggunakan pembagian data 80% untuk training dan 20% untuk testing guna mengetahui performa model pada data yang belum pernah dipelajari sebelumnya.

2.2 Metode Penyelesaian Masalah

Penelitian ini menggunakan algoritma XGBoost yang termasuk dalam metode *ensemble learning* berbasis *boosting*, di mana model algoritma ini dipilih karena memiliki kemampuan yang baik dalam mengolah data tabular, menangani hubungan yang kompleks antar fitur, serta mampu menghasilkan performa klasifikasi yang tinggi pada berbagai penelitian sebelumnya [18]. Klasifikasi dilakukan terhadap metode pembayaran pelanggan yang terdiri dari dua kelas, yaitu *cash* dan *card*. Fitur yang digunakan merupakan hasil seleksi dan pengolahan data, seperti *total payment*, waktu transaksi, serta beberapa fitur turunan yang dianggap berpengaruh terhadap pemilihan metode pembayaran. Untuk menangani permasalahan ketidakseimbangan data, penelitian ini menerapkan metode *Synthetic Minority Over-sampling Technique (SMOTE)* yang digunakan untuk menambah jumlah data pada kelas minoritas sehingga distribusi data menjadi lebih seimbang [19][20][5]. Penerapan SMOTE diharapkan mampu meningkatkan kemampuan model dalam mengenali kelas minoritas tanpa mengubah karakteristik utama data asli. Setelah proses penyeimbangan data, dataset dibagi menjadi data *training* dan *testing* dengan rasio 80:20. Data *training* digunakan untuk membangun model, sedangkan data *testing* digunakan untuk mengevaluasi performa model. Pada penelitian ini, model XGBoost dibangun menggunakan parameter bawaan (*default parameter*) dari pustaka XGBoost. Fokus penelitian diarahkan pada analisis pengaruh penerapan SMOTE terhadap kemampuan klasifikasi metode pembayaran pelanggan, sehingga proses optimasi *hyperparameter* tidak dilakukan. Evaluasi model dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, *ROC-AUC*, dan *Cohen's Kappa* sehingga performa model dapat dianalisis secara menyeluruh, khususnya pada kondisi data yang tidak seimbang. Selain itu, *confusion matrix* digunakan untuk membandingkan hasil prediksi dengan data aktual, sedangkan *feature importance* digunakan untuk mengidentifikasi fitur yang paling berpengaruh dalam proses klasifikasi. Ringkasan tahapan penelitian dapat dilihat pada Tabel 1 berikut.

Tabel 1. Tahapan Metode Penelitian

No	Tahapan	Deskripsi
1	Business Understanding	Identifikasi masalah dan tujuan penelitian
2	Data Understanding	Eksplorasi dan analisis dataset
3	Data Preparation	Pembersihan data dan penerapan SMOTE
4	Modeling	Penerapan algoritma XGBoost
5	Evaluation	Evaluasi model menggunakan berbagai metrik klasifikasi

Tabel 1 menjelaskan tahapan penelitian yang digunakan mulai dari identifikasi masalah hingga evaluasi model.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Penelitian

3.1.1 Business Understanding

Tahap ini berfokus pada identifikasi permasalahan bisnis yang mendasari penelitian. Data transaksi penjualan menunjukkan distribusi metode pembayaran yang sangat tidak seimbang antara *cash* dan *card* dengan rasio sekitar 11,6:1. Ketimpangan ini berpotensi membuat model hanya mengenali pola kelas mayoritas, sehingga diperlukan pendekatan khusus agar model mampu mendeteksi kedua kelas secara proporsional. Dari sisi bisnis, kemampuan mengidentifikasi

pelanggan pengguna card berguna untuk merancang strategi promosi berbasis metode pembayaran dan meningkatkan infrastruktur pembayaran digital [21].

3.1.2 Data Understanding

Penelitian ini menggunakan data transaksi penjualan sebanyak 287.512 baris dengan 16 atribut yang dianalisis. Setelah proses pembersihan, tidak ditemukan nilai kosong maupun data tidak valid sehingga data siap digunakan untuk analisis lebih lanjut. Hasil eksplorasi menunjukkan adanya ketidakseimbangan distribusi metode pembayaran dengan rasio sekitar 11,6:1, di mana transaksi cash jauh lebih dominan dibandingkan card. Kondisi ini menjadi tantangan dalam proses klasifikasi karena model cenderung lebih mudah mempelajari pola dari kelas yang jumlah datanya lebih besar dibandingkan kelas minoritas [22]. Seperti yang ditampilkan pada Gambar 2. Kondisi ini menjadi tantangan utama karena model klasifikasi konvensional cenderung bias terhadap kelas yang jumlah datanya lebih banyak.

```
Jumlah data : 287,512 baris
Jumlah fitur: 16 kolom

   jual_date   jual_no sal_no let_no   person_no \
0  2025-09-17 11:09:03 PJ25091700054 S001 T000 ID-211007-104810-0001
1  2025-09-17 11:09:03 PJ25091700038 S001 T002 ID-211007-104810-0001
2  2025-09-17 11:09:03 PJ25091700029 S001 T001 ID-211007-104810-0001
3  2025-09-17 11:07:36 PJ25091700037 S001 T002 ID-211007-104810-0001
4  2025-09-17 11:07:36 PJ25091700053 S001 T000 ID-211007-104810-0001

   cust_name   jual_sub_total   jual_disc0_rp   jual_disc1_rp   jual_ppn_rp \
0      NaN      47950.0           0.0           0.0           0.0
1      NaN      30350.0           0.0           0.0           0.0
2      NaN      17600.0           0.0           0.0           0.0
3      NaN      77500.0           0.0           0.0           0.0
4      NaN      77500.0           0.0           0.0           0.0

   jual_total   jual_nama   pay_cash   pay_card   pay_credit   is_delete
0      47950.0      CASH      100000.0      0      0.0      0
1      30350.0      NaN      30350.0      0      0.0      0
2      17600.0      NaN      17600.0      0      0.0      0
3      77500.0      NaN      77500.0      0      0.0      0
4      77500.0      CASH      100000.0      0      0.0      0

Daftar Fitur:
['jual_date', 'jual_no', 'sal_no', 'let_no', 'person_no', 'cust_name', 'jual_sub_total', 'jual_disc0_rp', 'jual_disc1_rp',
'jual_ppn_rp', 'jual_total', 'jual_nama', 'pay_cash', 'pay_card', 'pay_credit', 'is_delete']
```

Gambar 2. Info Dataset

Berdasarkan Gambar 2, dataset memiliki 287.512 transaksi yang dinilai cukup untuk merepresentasikan pola transaksi pelanggan. Dari 16 atribut yang tersedia, tidak semuanya digunakan dalam pemodelan karena beberapa di antaranya seperti *cust_name*, *jual_no*, *sal_no*, *let_no*, dan *person_no* hanya berfungsi sebagai identitas transaksi dan tidak berpengaruh langsung terhadap klasifikasi metode pembayaran. Sebaliknya, atribut yang berkaitan dengan nilai transaksi, diskon, pajak, serta waktu transaksi digunakan sebagai dasar pembentukan fitur pada tahap selanjutnya. Hasil analisis awal juga menunjukkan bahwa transaksi didominasi oleh metode pembayaran cash dibandingkan card, yang mengindikasikan adanya ketidakseimbangan kelas yang perlu ditangani pada tahap persiapan data.

3.1.3 Data Preparation

Tahap persiapan data merupakan proses kritis yang menentukan kualitas model yang akan dibangun. Pada tahap ini dilakukan serangkaian langkah sistematis mulai dari pembersihan data, rekayasa fitur (feature engineering), seleksi fitur, pembagian data, hingga penanganan ketidakseimbangan kelas. Rangkuman seluruh proses persiapan data disajikan pada Tabel 2.


Tabel 2. Proses Data Preparation

No	Tahapan	Proses yang Dilakukan	Hasil
1	Data Cleaning	Menghapus kolom yang tidak relevan (<i>cust_name</i>) dan menghapus data dengan <i>is_delete</i> = 1 serta menangani nilai NaN dan infinite	Data menjadi bersih dan siap digunakan
2	Pembentukan Target	Membuat variabel <i>payment_method</i> berdasarkan nilai <i>pay_cash</i>	Kelas: cash dan card
3	Feature Engineering	Membuat fitur baru seperti <i>day_of_week</i> , <i>hour</i> , <i>month</i> , <i>is_weekend</i> , <i>transaction_size</i> , <i>disc_ratio</i> , <i>tax_ratio</i> , <i>hour_group</i> , dan <i>is_large_transaction</i>	Total fitur menjadi 10 variabel
4	Seleksi Fitur	Memilih fitur yang relevan dan menghindari data leakage	Dataset siap untuk modeling
5	Split Data	Membagi data menjadi train (80%) dan test (20%)	230.009 data train dan 57.503 data test
6	Penanganan Imbalance	Metode SMOTE diterapkan pada data training agar jumlah data pada setiap kelas menjadi lebih merata	Jumlah data pada kelas cash dan card menjadi lebih seimbang (cash = card)

Proses awal dilakukan dengan pembersihan data, yaitu menghapus kolom *cust_name* karena hanya berisi identitas pribadi yang tidak berpengaruh terhadap analisis, serta menghapus data dengan status *is_delete* = 1 karena merupakan transaksi yang dibatalkan dan tidak relevan. Setelah tahap ini, dataset dipastikan bebas dari nilai kosong maupun data tidak valid.

Selanjutnya dilakukan rekayasa fitur untuk memperkaya informasi dari data mentah. Dari atribut waktu transaksi dibentuk fitur seperti `day_of_week`, `hour`, `month`, `is_weekend`, dan `hour_group` untuk menganalisis pola perilaku pelanggan berdasarkan waktu. Selain itu, dibuat fitur berbasis nilai transaksi seperti `disc_ratio`, `tax_ratio`, `transaction_size`, dan `is_large_transaction` yang menggambarkan karakteristik finansial transaksi. Kombinasi fitur ini diharapkan dapat memberikan representasi yang lebih lengkap terhadap pola pembayaran pelanggan.

Dataset kemudian dibagi menjadi data latih dan data uji dengan rasio 80:20, menghasilkan 230.009 data latih dan 57.503 data uji. Pembagian dilakukan sebelum penerapan SMOTE agar data uji tetap murni dan evaluasi model lebih objektif. Untuk mengatasi ketidakseimbangan kelas, digunakan SMOTE pada data latih dengan membangkitkan data sintetis melalui interpolasi data minoritas. Setelah penerapan SMOTE, distribusi kelas pada data latih menjadi seimbang antara `cash` dan `card`, seperti ditunjukkan pada Gambar 3.



Gambar 3. Perbandingan Distribusi Kelas Data Sebelum dan Setelah Menggunakan SMOTE

Berdasarkan Gambar 3, terlihat bahwa sebelum SMOTE diterapkan, jumlah data kelas `cash` jauh mendominasi dibandingkan kelas `card`. Setelah SMOTE, keduanya mencapai proporsi yang setara, sehingga model mendapatkan kesempatan belajar yang lebih adil dari masing-masing kelas. Perlu ditekankan bahwa keseimbangan ini hanya berlaku pada data latih, sedangkan data uji tetap mempertahankan distribusi aslinya untuk menjaga validitas evaluasi.

3.1.4 Modeling


Proses pemodelan dilakukan menggunakan algoritma XGBoost (Extreme Gradient Boosting), yaitu metode ensemble berbasis pohon keputusan yang memiliki performa tinggi dalam tugas klasifikasi. XGBoost bekerja dengan membangun pohon keputusan secara bertahap, di mana setiap pohon baru bertujuan memperbaiki kesalahan dari model sebelumnya melalui mekanisme gradient boosting.

Dalam penelitian ini digunakan dua skenario pemodelan untuk tujuan perbandingan, yaitu model XGBoost tanpa penanganan ketidakseimbangan data dan model XGBoost yang dilatih menggunakan data hasil SMOTE. Kedua model menggunakan data uji yang sama agar hasil evaluasi dapat dibandingkan secara objektif dan adil.

A. Implementasi Sistem

Selain pengujian menggunakan Jupyter Notebook, model yang dihasilkan juga diimplementasikan ke dalam antarmuka web sederhana menggunakan Streamlit. Implementasi ini bertujuan untuk memudahkan pengguna non-teknis dalam mengeksplorasi hasil analisis secara interaktif. Dashboard yang dibangun terdiri dari empat panel utama, yaitu distribusi data, evaluasi performa model, confusion matrix, dan feature importance. Tampilan masing-masing panel disajikan pada Gambar 4 hingga Gambar 8 [23].

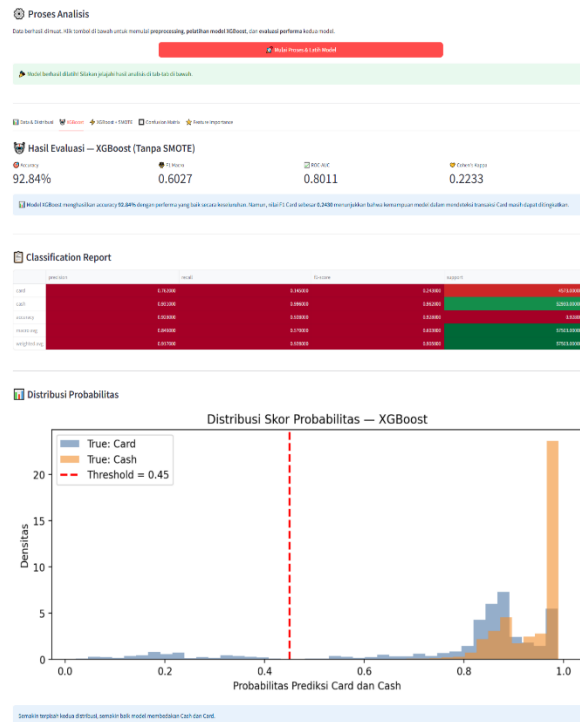
Gambar 4 menampilkan dashboard distribusi data yang memberikan gambaran awal mengenai karakteristik dan sebaran variabel pada dataset transaksi.



Gambar 4. Dashboard Data & Distribusi

Berdasarkan Gambar 4, terlihat bahwa distribusi data menunjukkan ketidakseimbangan antara kelas transaksi cash dan card, yang menjadi dasar dilakukannya teknik penanganan imbalance pada tahap selanjutnya.

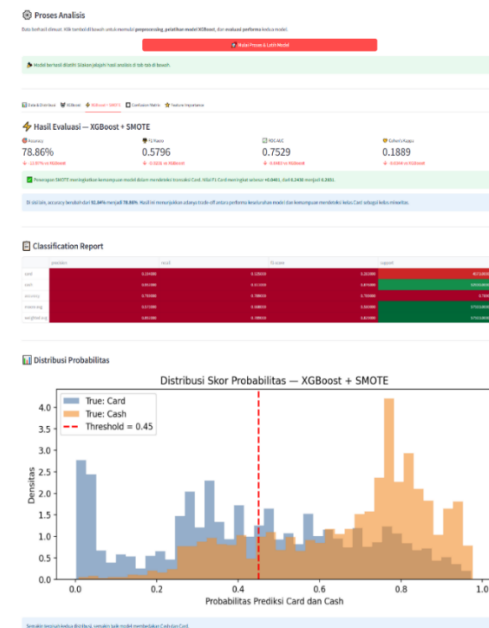
Gambar 5 menunjukkan hasil evaluasi performa model XGBoost tanpa penerapan teknik penyeimbangan data (SMOTE) dalam bentuk dashboard interaktif.



Gambar 5. Dashboard Hasil Evaluasi Model XGBoost Murni

Hasil pada Gambar 5 memperlihatkan bahwa model memiliki akurasi yang tinggi, namun masih menunjukkan ketimpangan performa antara kelas mayoritas dan minoritas.


Gambar 6 menyajikan hasil evaluasi model XGBoost setelah penerapan SMOTE yang digunakan untuk mengatasi ketidakseimbangan kelas pada data pelatihan.



Gambar 6. Dashboard Hasil Evaluasi Model Menggunakan Smote

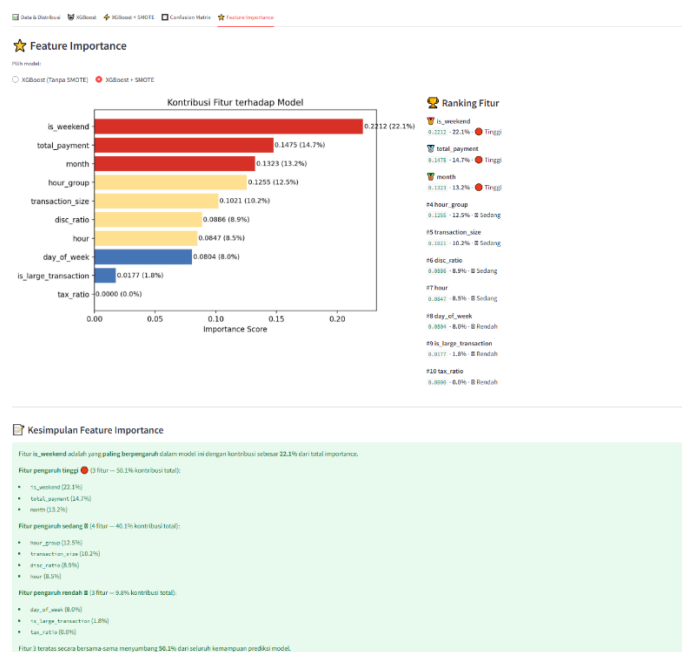
Berdasarkan Gambar 6, terlihat adanya peningkatan kemampuan model dalam mendeteksi kelas minoritas, meskipun disertai penurunan pada beberapa metrik keseluruhan. Gambar 7 menampilkan confusion matrix hasil evaluasi

model XGBoost setelah penerapan SMOTE, yang digunakan untuk melihat kinerja klasifikasi berdasarkan perbandingan antara nilai prediksi dan kondisi aktual.



Gambar 7. Dashboard Confusion Matrix

Berdasarkan Gambar 7, dapat dilihat bahwa meskipun terjadi peningkatan kemampuan model dalam mengenali kelas minoritas, masih terdapat kesalahan klasifikasi, terutama pada kelas card yang masih cukup sering diprediksi sebagai kelas cash. Gambar 8 menunjukkan hasil analisis feature importance dari model XGBoost setelah penerapan SMOTE, yang menggambarkan kontribusi masing-masing fitur terhadap proses pengambilan keputusan model.



Gambar 8. Dashboard Feature Importance

Hasil pada Gambar 8 menunjukkan bahwa beberapa fitur seperti nilai transaksi dan indikator waktu memiliki pengaruh yang lebih dominan dalam menentukan hasil prediksi metode pembayaran dibandingkan fitur lainnya. Dashboard pada Gambar 4 hingga Gambar 8 dirancang dengan antarmuka yang sederhana namun informatif. Setiap panel menyajikan visualisasi yang berbeda namun saling melengkapi, sehingga pengguna dapat memperoleh gambaran menyeluruh mengenai karakteristik data, performa model, serta faktor-faktor yang paling berpengaruh terhadap prediksi metode pembayaran.

3.1.5 Evaluation

Evaluasi model dilakukan menggunakan beberapa metrik, yaitu accuracy, precision, recall, F1-score, ROC-AUC, dan Cohen's Kappa. Penggunaan berbagai metrik ini penting pada data tidak seimbang karena accuracy saja dapat memberikan gambaran yang menyesatkan, terutama ketika model cenderung hanya memprediksi kelas mayoritas.

Tabel 3. Hasil Evaluasi Model

No	Metrik Evaluasi	Tanpa SMOTE	Dengan SMOTE
1	Accuracy	0.9283	0.7850
2	ROC-AUC	0.7759	0.7529
3	F1-Score (Macro)	0.6021	0.5778
4	Precision (Card)	0.76	0.19
5	Recall (Card)	0.14	0.53
6	F1-Score (Card)	0.2419	0.2820
7	Precision (Cash)	0.93	0.95
8	Recall (Cash)	1.00	0.81
9	F1-Score (Cash)	0.9624	0.8735
10	Cohen's Kappa	0.2222	0.1871


Berdasarkan Tabel 3, model tanpa SMOTE memang menghasilkan accuracy yang tinggi sebesar 92,83%, tetapi kemampuan mendeteksi kelas card sangat rendah dengan recall hanya 0,14. Hal ini menunjukkan bahwa sebagian besar transaksi card tidak teridentifikasi dan justru diklasifikasikan sebagai cash, sehingga tingginya accuracy lebih disebabkan oleh dominasi kelas mayoritas.

Setelah penerapan SMOTE, terjadi perubahan performa yang lebih seimbang. Recall kelas card meningkat menjadi 0,53, yang berarti model lebih mampu mengenali kelas minoritas. Namun, hal ini diikuti penurunan accuracy menjadi 78,50% karena model menjadi lebih sensitif terhadap kelas card. Meski demikian nilai ROC-AUC sebesar 0,7529 menunjukkan bahwa model masih memiliki kemampuan yang cukup baik dalam membedakan kedua kelas.

Meskipun demikian, nilai precision pada kelas *card* hanya mencapai 0,19. Hasil ini menunjukkan bahwa masih terdapat banyak transaksi *cash* yang diprediksi sebagai *card* (*false positive*). Dengan kata lain, peningkatan kemampuan model dalam mendeteksi kelas minoritas harus dibayar dengan meningkatnya jumlah kesalahan prediksi pada kelas tersebut. Kondisi ini menunjukkan adanya *trade-off* antara kemampuan mendeteksi kelas minoritas (*recall*) dan ketepatan prediksi (*precision*) setelah penerapan SMOTE. Oleh karena itu, performa model tidak dapat dinilai hanya berdasarkan *accuracy* atau *ROC-AUC*, tetapi perlu mempertimbangkan seluruh metrik evaluasi secara bersama-sama agar interpretasi hasil menjadi lebih objektif.

a. Confusion Matrix


Analisis confusion matrix memberikan gambaran lebih rinci mengenai jenis kesalahan prediksi model. Berdasarkan Gambar 9, model dengan SMOTE menunjukkan kemampuan yang cukup baik dalam mengenali transaksi cash, yang terlihat dari dominasi nilai True Positive pada kelas tersebut [21].

**Gambar 9.** Confusion Matrix

Namun, di sisi lain masih ditemukan cukup banyak false positive, yaitu transaksi cash yang diprediksi sebagai card. Kondisi ini tercermin dari nilai precision kelas card yang hanya sebesar 0,19, yang berarti hanya sekitar 19% prediksi card merupakan transaksi card yang sebenarnya. Sebaliknya, nilai recall kelas card meningkat menjadi 0,53, yang menunjukkan bahwa model menjadi lebih mampu mengenali kelas minoritas setelah penerapan SMOTE. Peningkatan recall tersebut diperoleh dengan konsekuensi meningkatnya jumlah false positive, sehingga terjadi penurunan precision. Secara keseluruhan, hasil ini menunjukkan adanya *trade-off* antara precision dan recall. Dalam konteks bisnis, kondisi ini masih dapat dipertimbangkan apabila biaya kehilangan pelanggan yang menggunakan metode pembayaran card lebih besar dibandingkan biaya akibat prediksi yang salah terhadap transaksi cash. Oleh karena itu, evaluasi performa model tidak cukup hanya didasarkan pada accuracy atau ROC-AUC, tetapi juga perlu mempertimbangkan precision, recall, dan F1-score agar kualitas model dapat dinilai secara lebih komprehensif.

b. ROC Curve

Kurva ROC menunjukkan bahwa model memiliki nilai AUC sebesar 0,7529. Hal ini mengindikasikan bahwa model cukup mampu membedakan kedua kelas dalam proses klasifikasi. Pada gambar 10 posisi kurva yang berada di atas garis diagonal ($AUC = 0,5$) menandakan bahwa performa model lebih baik dibandingkan tebakan acak.




Gambar 10. Roc Kurva

Berdasarkan Gambar 10, kurva ROC menunjukkan nilai ROC-AUC sebesar 0,7529, yang mengindikasikan bahwa model memiliki kemampuan yang cukup baik dalam membedakan transaksi cash dan card. Nilai tersebut menunjukkan bahwa model bekerja lebih baik dibandingkan prediksi secara acak karena kurva ROC berada di atas garis diagonal. Meskipun demikian, nilai ROC-AUC yang cukup baik tidak secara otomatis menunjukkan bahwa model telah optimal pada data tidak seimbang. Hal ini terlihat dari nilai precision kelas card yang masih rendah, sehingga interpretasi ROC-AUC perlu dipadukan dengan metrik lain seperti precision, recall, dan F1-score agar evaluasi model menjadi lebih komprehensif.

c. Feature Importance

Analisis feature importance pada Gambar 11 mengungkap informasi penting tentang faktor-faktor yang paling berkontribusi dalam menentukan metode pembayaran pelanggan.



Gambar 11. Feature Importance

Berdasarkan Gambar 11, fitur `is_large_transaction` menjadi variabel yang memiliki kontribusi paling besar terhadap model. Hasil ini menunjukkan bahwa nilai transaksi merupakan faktor utama yang memengaruhi pemilihan metode pembayaran pelanggan. Transaksi dengan nominal yang lebih besar cenderung menggunakan metode pembayaran card, yang diduga dipengaruhi oleh faktor keamanan, kemudahan, dan kenyamanan dalam bertransaksi. Temuan ini menunjukkan bahwa karakteristik nilai transaksi dapat dimanfaatkan sebagai indikator penting dalam memprediksi preferensi metode pembayaran pelanggan.

Selanjutnya, fitur `is_weekend` berada pada urutan kedua yang menunjukkan adanya perbedaan pola pembayaran antara hari kerja dan akhir pekan, di mana penggunaan card cenderung meningkat pada akhir pekan. Hal ini dapat menjadi dasar dalam pengaturan operasional, seperti penjadwalan staf dan kesiapan sistem pada periode transaksi tinggi. Sementara itu, `total_payment` juga berpengaruh cukup signifikan, menegaskan bahwa besarnya pengeluaran berkaitan dengan metode pembayaran yang digunakan.


Dari sisi bisnis, hasil penelitian ini dapat dimanfaatkan oleh perusahaan untuk meningkatkan ketersediaan fasilitas pembayaran digital, seperti mesin EDC atau layanan pembayaran elektronik, terutama pada transaksi bernilai tinggi dan pada periode akhir pekan. Selain itu, perusahaan dapat menyusun strategi promosi, seperti pemberian cashback atau potongan harga untuk pembayaran non-tunai, sehingga berpotensi meningkatkan penggunaan metode pembayaran card.

Di sisi lain, fitur seperti `tax_ratio` dan `transaction_size` memiliki kontribusi yang relatif kecil terhadap proses klasifikasi. Hal ini menunjukkan bahwa kedua fitur tersebut belum memberikan pengaruh yang signifikan terhadap

keputusan model. Oleh karena itu, pada penelitian selanjutnya kedua fitur tersebut dapat dievaluasi kembali melalui proses seleksi fitur sehingga model yang dihasilkan menjadi lebih sederhana tanpa mengurangi performa klasifikasi secara signifikan.

d. Distribusi Probabilitas Prediksi

Distribusi probabilitas prediksi pada Gambar 12 memberikan wawasan tambahan mengenai tingkat keyakinan model dalam membuat keputusan klasifikasi.



Gambar 12. Distribusi Probabilitas Prediksi

Berdasarkan Gambar 12, data cash cenderung terkonsentrasi pada probabilitas tinggi (mendekati 1,0), yang menunjukkan tingkat keyakinan model yang cukup kuat dalam mengklasifikasikannya. Sebaliknya, data card tersebar pada rentang probabilitas yang lebih rendah, mencerminkan ketidakpastian model terhadap kelas minoritas.

Penetapan threshold sebesar 0,45 digunakan untuk meningkatkan sensitivitas terhadap kelas card dibandingkan threshold default 0,50. Pendekatan ini berhasil meningkatkan nilai recall kelas card menjadi 0,53, namun diikuti oleh penurunan precision menjadi 0,19 akibat meningkatnya jumlah false positive. Hasil tersebut menunjukkan bahwa batas keputusan (*decision threshold*) yang digunakan masih menghasilkan trade-off antara kemampuan mendeteksi kelas minoritas dan ketepatan prediksi. Secara keseluruhan, model lebih sesuai digunakan sebagai alat skrining awal (*screening tool*) untuk mengidentifikasi transaksi yang berpotensi menggunakan metode pembayaran card, dibandingkan sebagai sistem pengambilan keputusan otomatis. Oleh karena itu, penelitian selanjutnya dapat mengoptimalkan threshold, melakukan hyperparameter tuning, maupun menambahkan fitur yang lebih representatif agar pemisahan antar kelas menjadi lebih jelas dan performa klasifikasi dapat ditingkatkan.

3.2 Pembahasan

Penerapan metode SMOTE pada penelitian ini berhasil meningkatkan kemampuan model dalam mendeteksi kelas card, yang ditunjukkan oleh peningkatan recall dari 0,14 menjadi 0,53. Namun, peningkatan tersebut diikuti oleh penurunan accuracy menjadi 78,50% dan precision kelas card yang masih rendah (0,19). Hasil ini menunjukkan adanya *trade-off* antara kemampuan mendeteksi kelas minoritas dan ketepatan prediksi, sehingga evaluasi model pada data tidak seimbang perlu mempertimbangkan precision, recall, dan F1-score, tidak hanya accuracy.

Hasil penelitian ini sejalan dengan penelitian Halim dan Azmi [10] serta Sukmawati dkk. [11] yang menunjukkan bahwa penerapan teknik penyeimbangan data mampu meningkatkan kemampuan model dalam mengenali kelas minoritas. Namun, berbeda dengan penelitian Fatima dkk. [8] dan Lin [9] yang memperoleh performa klasifikasi lebih tinggi, penelitian ini menggunakan dataset transaksi dengan rasio ketidakseimbangan yang lebih besar (11,6:1), sehingga proses klasifikasi menjadi lebih menantang.

Kontribusi penelitian ini terletak pada penerapan kombinasi XGBoost dan SMOTE untuk klasifikasi metode pembayaran pelanggan serta evaluasi model menggunakan berbagai metrik, yaitu accuracy, precision, recall, F1-score, ROC-AUC, dan Cohen's Kappa. Hasil penelitian ini menunjukkan bahwa penggunaan beberapa metrik evaluasi memberikan gambaran performa model yang lebih komprehensif dibandingkan hanya menggunakan nilai akurasi, sehingga dapat menjadi referensi bagi penelitian selanjutnya dalam menangani data yang tidak seimbang.

4. KESIMPULAN

Penelitian ini berhasil membangun model klasifikasi metode pembayaran pelanggan menggunakan algoritma XGBoost dengan menerapkan metode SMOTE untuk mengatasi ketidakseimbangan data. Hasil pengujian menunjukkan bahwa penerapan SMOTE meningkatkan kemampuan model dalam mengenali kelas minoritas, yang ditunjukkan oleh peningkatan nilai recall kelas *card* dari 0,14 menjadi 0,53, meskipun diikuti penurunan nilai accuracy dari 92,83% menjadi 78,50%. Temuan ini menunjukkan bahwa pada kasus data tidak seimbang, evaluasi model tidak cukup hanya berdasarkan accuracy, tetapi perlu mempertimbangkan precision, recall, F1-score, ROC-AUC, dan Cohen's Kappa agar performa model dapat dinilai secara lebih menyeluruh. Kontribusi penelitian ini adalah menerapkan kombinasi algoritma XGBoost dan metode SMOTE pada klasifikasi metode pembayaran pelanggan serta menyajikan analisis perbandingan performa model sebelum dan sesudah penerapan SMOTE menggunakan berbagai metrik evaluasi. Hasil penelitian diharapkan dapat menjadi referensi dalam pengembangan model klasifikasi pada data transaksi yang tidak seimbang serta



mendukung pengambilan keputusan berbasis data. Penelitian selanjutnya dapat mengembangkan model melalui optimasi hyperparameter, penerapan teknik penyeimbangan data lain seperti ADASYN, atau penambahan fitur yang lebih representatif untuk meningkatkan performa klasifikasi.

REFERENCES

- [1] Erna Kristia dan Mirzam Arqy Ahmadi, "Implementasi QRIS sebagai Alternatif Pembayaran Non Tunai pada Kalangan Usaha Mikro, Kecil, dan Menengah (UMKM): Peluang dan Tantangan," *PENG J. Ekon. Dan Manaj.*, vol. 2, no. 1, hal. 1014–1024, 2024, doi: 10.62710/21sq943.
- [2] Diva Amanda Lintang Sutomo dan Yusuf S Barusman, "Pengaruh Pengguna Fitur Paylater Terhadap Perilaku Implusive Buying Pada Mahasiswa Pengguna E-Commerce Di Kota Bandar Lampung," *Hirarki J. Ilm. Manaj. dan Bisnis*, vol. 7, no. 2, hal. 13–32, 2025, doi: 10.30606/4wsm2g10.
- [3] Mailiana Anita, Imelda Grecea Dwi Yulianti, dan Swarno Varestama Pasaribu, "Klasifikasi Faktor Risiko Penyakit Jantung Menggunakan Machine Learning," *HOAQ (High Educ. Organ. Arch. Qual. J. Teknol. Inf.)*, vol. 16, no. 1, hal. 68–78, 2025, doi: 10.52972/hoaq.vol16no1.p68-78.
- [4] Jan Melvin Ayu Soraya Dachi dan Pardomuan Sitompul, "Analisis Perbandingan Algoritma XGBoost dan Algoritma Random Forest Ensemble Learning pada Klasifikasi Keputusan Kredit," *J. Ris. Rumpun Mat. Dan Ilmu Pengetah. Alam*, vol. 2, no. 2, hal. 65–71, 2023, doi: 10.55606/jurrimipa.v2i2.1336.
- [5] K. A. and M. Abdelaziz, *Machine Learning for Imbalanced Data*. Birmingham: Packt Publishing, 2023.
- [6] Yahya Khaliman Indrayana, Radhistya Krisna Ramadhan, Indra Budi Kurniawan, dan Siti Rihastuti, "Implementasi Decision Tree untuk Mengklasifikasikan Metode Pembayaran di Supermarket," *Semin. Nas. Amikom Surakarta 2023*, no. November, hal. 43, 2023, [Daring]. Tersedia pada: <https://ojs.amikomsolo.ac.id/index.php/semnasa/article/view/86>
- [7] Omar Pahlevi, Amrin, dan Yopi Handrianto, "Implementasi Algoritma Klasifikasi Random Forest Untuk Penilaian Kelayakan Kredit," *J. Infortech*, vol. 5, no. 1, hal. 71–76, 2023, doi: 10.31294/infortech.v5i1.15829.
- [8] Sana Fatima, Ayan Hussain, Sohaib Bin Amir, Syed Haseeb Ahmed, dan Syed Muhammad Huzaifa Aslam, "XGBoost and Random Forest Algorithms: An in Depth Analysis," *Pakistan J. Sci. Res.*, vol. 3, no. 1, hal. 26–31, 2023, doi: 10.57041/pjosr.v3i1.946.
- [9] Jin Lin, "Application of machine learning in predicting consumer behavior and precision marketing," *PLoS One*, vol. 20, no. 5 May, hal. 1–12, 2025, doi: 10.1371/journal.pone.0321854.
- [10] St Fatika Nabila Halim dan Ulil Azmi, "Analisis Perbandingan Klasifikasi dan Penerapan Teknik SMOTE Dalam Imbalanced Data Pada Credit Card Default," *J. Sains dan Seni ITS*, vol. 12, no. 2, 2023, doi: 10.12962/j23373520.v12i2.111833.
- [11] Cici Emilia Sukmawati, Adi Rizky Pratama, Hanny Hikmayanti, dan Ayu Ratna Juwita, "Optimasi AdaBoost dan XGBoost untuk Klasifikasi Obesitas Menggunakan SMOTE," *J. Inform. J. Pengemb. IT*, vol. 10, no. 3, hal. 771–780, 2025, doi: 10.30591/jpit.v10i3.8536.
- [12] Omar Pahlevi, Dewi Ayu Nur Wulandari, Luci Kanti Rahayu, Henny Leidiyana, dan Yopi Handrianto, "Model Klasifikasi Risiko Stunting Pada Balita Menggunakan Algoritma CatBoost Classifier," *Bull. Comput. Sci. Res.*, vol. 6, no. 4, hal. 414–421, 2024, doi: 10.47065/bulletincsr.v4i6.373.
- [13] Yunna Mentari Indah, Rafika Aristawidya, Anwar Fitrianto, Erfiani, dan L.M. Risman Dwi Jumansyah, "Comparison of Random Forest, XGBoost and LightGBM Methods on the Human Development Index Classification," *JAMBURA J. Math.*, vol. 7, no. 1, hal. 14–18, 2025, doi: 10.37905/jjom.v7i1.28290.
- [14] Afika Rianti, Nuur Wachid Abdul Majid, dan Ahmad Fauzi, "CRISP-DM: Metodologi Proyek Data Science," *Pros. Semin. Nas. Teknol. Inf. dan Bisnis*, no. July 2023, hal. 107–114, 2023, [Daring]. Tersedia pada: <https://ojs.udb.ac.id/index.php/Senatib/article/view/3015>
- [15] Dwi Bagus Saputra, Vihi Atina, dan Faulinda Ely Nastiti, "Penerapan Model CRISP-DM pada Prediksi Nasabah Kredit Menggunakan Algoritma Random Forest," *Idealis Indones. J. Inf. Syst.*, vol. 7, no. 2021, hal. 240–247, 2024, doi: 10.36080/idealis.v7i2.3244.
- [16] Ridwan, Eni Heni Hermaliani, dan Muji Ernawati, "Penerapan Metode SMOTE Untuk Mengatasi Imbalanced Data Pada Klasifikasi Ujaran Kebencian," *Comput. Sci.*, vol. 4, no. 1, 2024, doi: 10.31294/coscience.v4i1.2990.
- [17] Randi Estian Pambudi, Hendri Purnomo, dan Adimas Aglasia, "Analisis Klasifikasi Sentimen Pengguna MyPertamina Menggunakan Metode Evaluasi Precision, Recall, dan F1-Score," *Aisyah J. Informatics Electr. Eng.*, vol. 07, no. 02, hal. 17–22, 2025, [Daring]. Tersedia pada: <https://jti.aisyahuniversity.ac.id/index.php/AJIEE>
- [18] Muhamad Amhar Rayadin, Mustarum Musaruddin, Rizal Adi Saputra, dan Isnawaty, "Implementasi Ensemble Learning Metode XGBoost dan Random Forest untuk Prediksi Waktu Penggantian Baterai Aki," *BIOS J. Teknol. Inf. dan Rekayasa Komput.*, vol. 5, no. 2, hal. 111–119, 2024, doi: 10.37148/bios.v5i2.128.
- [19] Fazal Malik, Muhammad Suliman, Muhammad Qasim Khan, Noor Rahman, Khairullah Khan, dan Muhammad Khan, "Optimizing Malicious Website Detection with the XGBoost Machine Learning Approach," *J. Comput. Biomed. Informatics*, vol. 7, no. 02 SE-Articles, 2024, doi: 10.56979/702/2024.
- [20] Raihan Zahran Firdaus, Satrio Hadi Wijoyo, dan Welly Purnomo, "Analisis Sentimen Berbasis Aspek Ulasan Pengguna Aplikasi Alfagift Menggunakan Metode Random Forest dan Pemodelan Topik Latent Dirichlet Allocation," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 9, no. 2, 2025, [Daring]. Tersedia pada: <http://j-ptiik.ub.ac.id>
- [21] Agum Cahyana, Erliyan Redy Susanto, dan Parjito, "Penerapan Algoritma XGBoost untuk Prediksi Diabetes: Analisis Confusion Matrix dan ROC Curve," *Fountain Informatics J.*, vol. 10, no. 1, hal. 40–50, 2025, doi: 10.21111/fij.v10i1.14311.
- [22] Yuda Irawan, Refni Wahyuni, Rian Ordila, dan Herianto, "Comparative Analysis of Machine Learning Algorithms with SMOTE and Boosting Techniques in Accuracy Improvement," *Indones. J. Comput. Sci.*, vol. 13, no. 5, hal. 7262–7278, 2024, doi: 10.33022/ijcs.v13i5.4368.
- [23] Ega Muhammad Atsir, Nurmalitasari, dan Aprilisa Arum Sari, "Traffic Accident Severity Classification System Using Random Forest Algorithm," *J-INTECH (Journal Inf. Technol.)*, vol. 13, no. 2, 2025, doi: 10.32664/j-intech.v13i02.2089.