



Klasifikasi Risiko Kredit Nasabah Menggunakan Algoritma Machine Learning dan Teknik Explainable AI

Ismi Hayati Nabila^{1*}, Sri Lestari¹

¹ Fakultas Ilmu Komputer, Institut Informatika dan Bisnis Darmajaya, Kota Bandar Lampung, Indonesia

*Corresponding author email: ismihayati.2221210075@mail.darmajaya.ac.id

Article Info

Article history:

Received April 15, 2026

Approved May 20, 2026

Keywords:

Classification, Credit Risk, Machine Learning, SMOTE, SHAP, German Credit Dataset

ABSTRACT

The banking sector faces a major challenge in the form of credit risk due to customers' inability to repay loans, which can threaten financial stability. Traditional methods are less effective at handling complex data and class imbalances, so a machine learning approach is needed to improve classification accuracy. This study compares the performance of the Naïve Bayes, AdaBoost, Random Forest, and XGBoost algorithms on the German Credit dataset (1000 entries, 70% low risk and 30% high risk) with SMOTE techniques to overcome class imbalances as well as SHAP as Explainable AI for model interpretability. Data processing is carried out using Python (Pandas, Scikit-learn, XGBoost, SHAP) in Google Colab, including preprocessing (handling missing values, encoding, scaling), 10-fold cross-validation evaluation, and SHAP analysis. The results showed that Random Forest achieved the best performance with an average accuracy of 87% (Std: 0.036), precision 0.88, recall 0.87, F1-score 0.87, and ROC-AUC 0.93, followed by XGBoost (85%, Std: 0.041). Naïve Bayes and AdaBoost only reached 81%. SHAP analysis revealed Credit Amount and Duration as the most influential features on high risk prediction (positive correlation ~0.62). The ensemble model excels in accuracy and stability, while the integration of SMOTE and SHAP improves minority class recall as well as transparency for banking decision-making. This study outperformed previous studies (71.33% in ANN and 83% in Random Forest) thanks to the combination of these techniques, supporting more accurate, ethical, and regulated credit risk management in financial institutions.

ABSTRAK

Sektor perbankan menghadapi tantangan utama berupa risiko kredit akibat ketidakmampuan nasabah membayar pinjaman, yang dapat mengancam stabilitas keuangan. Metode tradisional kurang efektif menangani data kompleks dan ketidakseimbangan kelas, alhasil diperlukan pendekatan machine learning untuk memaksimalkan akurasi klasifikasi. Riset ini membandingkan performa algoritma Naïve Bayes, AdaBoost, Random Forest, dan XGBoost pada dataset German Credit (1000 entri, 70% risiko rendah dan 30% risiko tinggi) dengan teknik SMOTE untuk menangani ketidakseimbangan kelas serta SHAP sebagai Explainable AI untuk interpretabilitas model. Pemrosesan data dilakukan menggunakan Python (Pandas, Scikit-learn, XGBoost, SHAP) di Google Colab, mencakup preprocessing (penanganan missing values, encoding, scaling), evaluasi 10-fold cross-validation, dan analisis SHAP. Hasil memperlihatkan Random Forest mencapai performa terbaik dengan akurasi rata-rata 87% (Std: 0,036), precision 0,88, recall 0,87, F1-score 0,87, dan ROC-AUC 0,93, diikuti XGBoost (85%, Std: 0,041). Naïve Bayes dan AdaBoost hanya mencapai 81%. Analisis SHAP mengungkap Credit Amount dan Duration sebagai fitur paling berpengaruh terhadap prediksi risiko tinggi (korelasi positif ~0,62). Model ensemble

unggul dalam akurasi dan stabilitas, sementara integrasi SMOTE dan SHAP memaksimalkan recall kelas minoritas serta transparansi untuk pengambilan keputusan perbankan. Riset ini mengungguli studi sebelumnya (71,33% pada ANN dan 83% pada Random Forest) berkat kombinasi teknik tersebut, mendukung pengelolaan risiko kredit yang lebih akurat, etis, dan sesuai regulasi di lembaga keuangan.

Copyright © 2026, The Author(s).

This is an open access article under the CC-BY-SA license



How to cite: Nabila, I. H., & Lestari, S. (2026). Klasifikasi Risiko Kredit Nasabah Menggunakan Algoritma Machine Learning dan Teknik Explainable AI. *Jurnal Ilmiah Global Education*, 7(2), 1922–1938. <https://doi.org/10.55681/jige.v7i2.5941>

PENDAHULUAN

Sektor perbankan memainkan peran krusial dalam mendorong pertumbuhan ekonomi melalui penerimaan simpanan masyarakat dan penyaluran kembali dana tersebut dalam bentuk kredit (Ardana et al., 2021). Selain itu, bank menyediakan berbagai layanan keuangan yang mendukung kesejahteraan masyarakat dan perkembangan bisnis. Namun, di tengah era globalisasi dan digitalisasi, industri perbankan menghadapi tantangan yang makin kompleks, terutama dalam pengelolaan risiko kredit nasabah (Chang et al., 2024). Risiko kredit, sebagai salah satu risiko utama yang dialami lembaga keuangan, terjadi akibat ketidakmampuan nasabah untuk memenuhi kewajiban pembayaran pinjaman, yang dapat mengancam stabilitas keuangan bank. Oleh karena itu, pengelolaan risiko kredit yang efektif menjadi kunci untuk menjaga kesehatan finansial institusi perbankan dan meminimalkan potensi kerugian.

Klasifikasi risiko kredit nasabah merupakan proses penting yang memungkinkan bank untuk mengidentifikasi tingkat risiko pemberian pinjaman dan mengambil tindakan preventif untuk mengurangi risiko gagal bayar. Metode tradisional yang mengandalkan analisis statistik sederhana sering kali tidak mampu menangkap kompleksitas data nasabah yang makin beragam dan dinamis. Perkembangan teknologi pembelajaran mesin (machine learning) telah menciptakan peluang baru untuk memaksimalkan akurasi klasifikasi risiko kredit melalui algoritma seperti Naïve Bayes, Adaboost, Random Forest, serta pendekatan boosting modern seperti XGBoost (Bintoro et al., n.d.; Raharjo, 2021). Naïve Bayes, yang berbasis pada Teorema Bayes dengan asumsi independensi fitur, dikenal karena kesederhanaan dan efisiensi komputasinya. Sementara itu, Adaboost dan Random Forest, sebagai metode ensemble, menggabungkan beberapa model untuk memaksimalkan kinerja klasifikasi (Perwira, 2019). Adaboost bekerja secara sekuensial dengan memberikan bobot lebih pada sampel yang sulit diklasifikasikan, sedangkan Random Forest membangun banyak pohon keputusan untuk mengurangi overfitting dan memaksimalkan akurasi (Aryani & Wijayanto, 2021). Selain itu, XGBoost sebagai algoritma boosting modern menawarkan efisiensi dan akurasi yang lebih tinggi melalui optimisasi gradien dan pengelolaan data yang lebih canggih (Permata & Nababan, 2023).

Namun, tantangan lain dalam klasifikasi risiko kredit adalah ketidakseimbangan kelas (class imbalance), di mana jumlah nasabah yang gagal bayar biasanya jauh lebih kecil dibandingkan nasabah yang mampu membayar. Untuk menangani masalah ini, teknik seperti SMOTE (Synthetic Minority Oversampling Technique) dapat diterapkan untuk menghasilkan data sintesis dari kelas minoritas, alhasil memaksimalkan performa model dalam mendeteksi kasus gagal bayar (Ismail et al., 2023).

Penelitian sebelumnya dengan mempergunakan dataset yang sama, seperti yang dilakukan oleh Yani (2019), memperlihatkan metode Artificial Neural Network (ANN) dengan Backpropagation menghasilkan akurasi sejumlah 71,33% dan AUC 72%, yang mengindikasikan perlunya optimalisasi lebih lanjut. Sementara itu, Prasojo dan Haryatmi (2021) mempergunakan Random Forest dengan tahapan preprocessing seperti transformasi tipe data dan normalisasi Min-Max, serta pembagian data 80% latih dan 20% uji, menyentuh akurasi sejumlah 83%, yang termasuk dalam kategori very good model. Hasil ini memperlihatkan Random Forest efektif untuk memprediksi kelayakan kredit dan mendukung pengambilan keputusan otomatis di perbankan.

Selain akurasi, interpretabilitas hasil prediksi menjadi aspek penting dalam konteks perbankan, di mana keputusan pemberian kredit harus dapat dijelaskan kepada pemangku kepentingan. Untuk itu, teknik Explainable AI seperti SHAP (Shapley Additive Explanations) dapat digunakan untuk memberikan penjelasan yang transparan tentang kontribusi setiap fitur dalam prediksi model (Ghildiyal et al., 2025). Pendekatan ini tidak hanya memaksimalkan kepercayaan terhadap model, tetapi juga memenuhi kebutuhan regulasi dan etika dalam pengambilan keputusan keuangan.

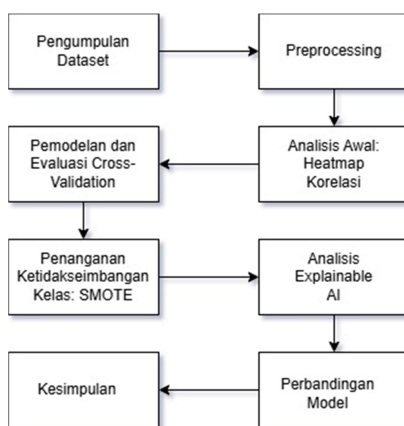
Penelitian lain oleh Momole (2022) membandingkan Naïve Bayes dan Random Forest dalam konteks identifikasi bahasa daerah Indonesia. Hasilnya memperlihatkan Naïve Bayes menyentuh akurasi di atas 90%, sedangkan Random Forest berada di bawah 70%. Hal ini mengindikasikan bahwa efektivitas algoritma dapat bervariasi tergantung pada karakteristik data yang dipergunakan. Mahirani et al. (2025) mempergunakan dataset sebanyak 13.805 teks dari media sosial Twitter untuk klasifikasi gangguan kepribadian Klaster B pada Generasi Z. Metode yang dipergunakan adalah Naïve Bayes yang diperkuat dengan teknik ensemble Adaboost serta penyeimbangan data mempergunakan SMOTE. Hasil penelitian memperlihatkan kombinasi Naïve Bayes dan Adaboost memaksimalkan akurasi dari 85% menjadi 91%, alhasil teknik ensemble terbukti efektif dalam memaksimalkan performa klasifikasi pada data tidak seimbang. Qurahman et al. (2019) mengkaji klasifikasi status kolektibilitas kredit nasabah bank mempergunakan Naïve Bayes Classifier (NBC) dan Probabilistic Neural Network (PNN). Hasil penelitian memperlihatkan PNN memberikan akurasi lebih tinggi sejumlah 93,58% dibandingkan NBC sejumlah 89,90%, alhasil PNN dinilai lebih efektif dalam mengidentifikasi risiko kredit bermasalah. ryani dan Wijayanto (2021) membandingkan SVM, Naïve Bayes, dan Random Forest pada dataset ionosfer dari UCI Machine Learning Repository. Hasil evaluasi memperlihatkan Random Forest memberikan performa terbaik dengan akurasi 90,57% dan presisi 94,12%. Fauzihan et al. (2024) mempergunakan algoritma XGBoost untuk klasifikasi indeks pencemaran udara (ISPU) dengan menerapkan teknik SMOTE dan balancing data. Model menyentuh akurasi sangat tinggi antara 99,40% hingga 99,63%, memperlihatkan efektivitas XGBoost dalam menangani data tidak seimbang. Sari et al. (2020) membandingkan algoritma Stochastic Gradient Descent (SGD), Random Forest, dan Naïve Bayes dalam prediksi kualitas kopi Arabika. Hasil penelitian memperlihatkan SGD menyentuh akurasi tertinggi sejumlah 98% hingga 99% setelah pengujian lanjutan, serta memperlihatkan performa terbaik dalam AUC dan stabilitas model.

Berdasarkan tinjauan tersebut, riset ini tujuannya untuk mengembangkan model klasifikasi risiko kredit nasabah mempergunakan algoritma Naïve Bayes, Adaboost, Random Forest, dan XGBoost, dengan memanfaatkan teknik SMOTE untuk menangani ketidakseimbangan kelas. Selain itu, riset ini akan mengintegrasikan teknik Explainable AI berbasis SHAP untuk

memaksimalkan interpretabilitas hasil prediksi. Riset ini diharapkan dapat menjawab pertanyaan mengenai perbandingan performa algoritma machine learning dalam klasifikasi risiko kredit nasabah, serta memberikan analisis interpretatif yang mendukung pengambilan keputusan yang lebih transparan dan efektif di lembaga keuangan.

METODE

Penelitian klasifikasi risiko kredit dimulai dari tahap pengumpulan dataset mempergunakan German Credit Data dari Kaggle/UCI (1000 entri, 10 atribut: Age, Sex, Job, Housing, Saving accounts, Checking account, Credit amount, Duration, Purpose, Risk). Dataset memiliki imbalance kelas (70% Good Risk, 30% bad risk). sebuah dataset publik dari Kaggle yang terdiri dari 1000 entri nasabah dengan atribut demografis, kondisi keuangan, dan riwayat pinjaman seperti usia, jenis kelamin, pekerjaan, kepemilikan rumah, rekening tabungan, rekening giro, jumlah kredit, durasi, dan tujuan pinjaman, serta variabel target risiko kredit yang dikategorikan menjadi risiko rendah dan tinggi untuk analisis serta prediksi tingkat risiko nasabah. Dataset dalam format CSV menjadi dasar analisis, diikuti oleh Preprocessing Data yang melibatkan pembersihan, transformasi, dan persiapan data untuk menghilangkan noise atau missing values. Kemudian, analisis awal fokus pada pembuatan heatmap korelasi untuk mengidentifikasi hubungan antar variabel, membantu memahami dependensi fitur. Setelah itu, penanganan ketidakseimbangan kelas dengan SMOTE diterapkan untuk menyeimbangkan distribusi kelas target melalui teknik oversampling sintesis, mencegah bias pada model. Tahap Pemodelan dan Evaluasi dengan Cross-Validation melibatkan pembangunan model klasifikasi (seperti Naïve Bayes, Adaboost, Random Forest, atau XGBoost) dan pengujiannya mempergunakan cross-validation untuk mengukur performa secara robust. Selanjutnya, Explainable AI: Analisis SHAP digunakan untuk menjelaskan kontribusi setiap fitur terhadap prediksi, memaksimalkan transparansi. Akhirnya, Perbandingan dan Kesimpulan menyajikan analisis komparatif antar model berdasarkan metrik evaluasi, diikuti dengan kesimpulan mengenai model terbaik dan implikasinya dalam klasifikasi risiko kredit, dengan alur linier ini dirancang untuk membangun setiap langkah secara bertahap guna memaksimalkan akurasi dan interpretabilitas prediksi. Gambar 1 mengilustrasikan alur penelitian secara linier mulai dari pengumpulan data hingga analisis SHAP, alhasil memudahkan pembaca memahami tahapan secara keseluruhan.



Gambar 1. Proses Pengembangan dan Evaluasi Model Machine Learning

Tabel 1. Atribut

No	Atribut	Keterangan
1	Usia	Muda, Tua
2	Jenis_Kelamin	Pria,Wanita
3	Pekerjaan	Ya, Tidak
4	Kepemilikan Rumah	Milik Sendiri, Sewa
5	Rekening Tabungan	Tidak ada, sedikit, sedang, cukup banyak, banyak)
6	Rekening Giro	Tidak ada, Sedikit, Sedang, Banyak
7	Jumlah Kredit	Besar pinjaman/kredit yang diajukan nasabah
8	Durasi_Pinjaman	Jangka Waktu Pinjaman
9	Tujuan Pinjaman	Keperluan penggunaan kredit (misalnya mobil, radio/TV, furnitur, bisnis, dll.)
10	Risiko	Risiko Rendah, Risiko Tinggi

Prosedur penelitian terbagi menjadi beberapa tahapan utama, yaitu pengumpulan dataset dan preprocessing data, analisis awal dengan heatmap korelasi, penanganan ketidakseimbangan kelas menggunakan SMOTE, pemodelan dan evaluasi dengan cross-validation, analisis explainable AI menggunakan SHAP, serta perbandingan dan kesimpulan model (Santoso, 2023).

Pra-pemrosesan Data

Pada tahap ini untuk menyiapkan data agar siap digunakan oleh algoritma *machine learning* (Scheule, 2020). Langkah-langkah yang dilaksanakan mencakup:

- a. Pemuatan Datasets dimuat menggunakan pustaka Pandas. Penting untuk memastikan pemisah (delimiter) yang benar ('sep=',';') digunakan agar data terbaca dengan struktur kolom yang tepat.
- b. Penanganan Missing Values yang dilakukan pemeriksaan terhadap keberadaan nilai yang hilang (NaN) atau 'NA' dalam dataset menggunakan metode `df.isnull().sum()`. Untuk kolom numerik, seperti Age, Job, Credit amount, Duration), missing values diisi dengan nilai median dari kolom tersebut. Untuk kolom kategorikal, seperti (Sex, Housing, Saving accounts, Checking account, Purpose) missing values di isi dengan nilai modus (nilai yang paling sering muncul), yang mempertahankan distribusi data asli tanpa memperkenalkan bias. Penanganan missing values disajikan pada gambar 2 memperlihatkan hasil pengecekan dan imputasi missing values menggunakan median untuk data numerik serta modus untuk data kategorikal.

```

--- Mengatasi Missing Values ---
↔
Cek Missing Values Setelah Pengisian:
Age                0
Sex                0
Job                0
Housing            0
Saving accounts    0
Checking account   0
Credit amount      0
Duration           0
Purpose            0
Risk               0
dtype: int64
    
```

Gambar 2. Penanganan Missing Values

- c. Enkoding data kategorikal fitur-fitur yang bersifat kategorikal (Sex, housing, saving accounts, Checking account, purpose) diubah menjadi representasi numerik menggunakan LabelEncoder dari Pustaka Scikit-Learn. Kolom target Risk juga di-encode menjadi nilai numerik (0 dan 1). Di mana 0 merepresentasikan Low Risk dan 1 merepresentasikan High Risk. Gambar ditunjukkan pada gambar 3

```

↔
--- Enkoding Data Kategorikal ---
Kolom kategorikal sebelum encoding: ['Sex', 'Housing',
Kolom 'Sex' berhasil di-encode.
Kolom 'Housing' berhasil di-encode.
Kolom 'Saving accounts' berhasil di-encode.
Kolom 'Checking account' berhasil di-encode.
Kolom 'Purpose' berhasil di-encode.
Kolom 'Risk' berhasil di-encode.

Nama kolom dalam dataset setelah encoding: ['Age', 'Sex', 'Job', 'Housing',
↔ 5 Baris Pertama Dataset Setelah Encoding:
    Age  Sex  Job  Housing  Saving accounts  Checking account  Credit amount
0    67   1   2     1             0                 0             1169
1    22   0   2     1             0                 1             5951
2    49   1   1     1             0                 0             2096
3    45   1   2     0             0                 0             7882
4    53   1   2     0             0                 0             4870

    Duration  Purpose  Risk
0           6         5     0
1          48         5     0
2          12         3     0
3          42         4     0
4          24         1     0
    
```

Gambar 3. Enkoding Data kategorikal

- d. Normalisasi data numerik kolom numerik diidentifikasi menggunakan `df.select_dtypes(include=[np.number]).columns` dan dinormalisasi menggunakan `StandardScaler` untuk mengubah data ke distribusi dengan rata-rata nol dan deviasi standar satu (`X_scaled = scaler.fit_transform(X)`). Normalisasi ini mempercepat konvergensi algoritma dan menjaga konsistensi skala fitur selama pelatihan model. Hasil gambar normalisasi data ditunjukkan pada gambar 4.

```

--- Normalisasi Data ---
Data fitur berhasil dinormalisasi.

--- Data Fitur yang Sudah Dinormalisasi ---
[[ 2.76645648  0.67028006  0.14694918 ... -0.74513141 -1.23647786
  1.07326286]
 [-1.19140394 -1.49191369  0.14694918 ...  0.94981679  2.24819436
  1.07326286]
 [ 1.18331231  0.67028006 -1.38377145 ... -0.41656241 -0.73866754
  0.06170503]
 ...
 [ 0.21583532  0.67028006  0.14694918 ... -0.87450324 -0.73866754
  1.07326286]
 [-1.10345149  0.67028006  0.14694918 ... -0.50552769  1.9992892
  1.07326286]

```

Gambar 4. Normalisasi Data

- e. Analisis korelasi fitur setelah penskalaan, heatmap korelasi fitur dibuat menggunakan `sns.heatmap` untuk memvisualisasikan hubungan antar fitur yang membantu dalam pemahaman data sebelum modeling.
- f. SMOTE (Synthetic Minority Over-sampling Technique) adalah metode oversampling yang bertujuan menyeimbangkan distribusi kelas pada data tidak seimbang dengan menciptakan instance sintesis khusus untuk kelas minoritas, guna memaksimalkan akurasi dan efektivitas algoritma klasifikasi (Ismail et al., 2023). SMOTE menghasilkan sampel sintetis untuk kelas minoritas (*Risiko Tinggi*), alhasil proporsi kelas jadi lebih seimbang. Visualisasi distribusi kelas sebelum serta setelah SMOTE dilakukan menggunakan `sns.countplot` untuk memperlihatkan efektivitasnya (misalnya, simulasi SMOTE dengan `X_smote, y_smote = smote.fit_resample(X_scaled, y)`).

Model Klasifikasi

Empat model klasifikasi diimplementasikan dan dievaluasi, dengan masing-masing model diintegrasikan dalam *pipeline* yang mencakup SMOTE dan *StandardScaler* untuk konsistensi pra-pemrosesan:

a. Naïve Bayes (Bayesian Classification)

Salah satu cara untuk memperkirakan kemungkinan menjadi bagian dari kelas tertentu adalah menggunakan Naïve Bayes, sebuah pendekatan klasifikasi statistik. Seperti pohon keputusan dan jaringan saraf tiruan, Klasifikasi Bayesian bergantung pada teorema Bayes, yang dapat mengkategorikan data secara efektif. Ketika digunakan pada kumpulan data besar, Klasifikasi Bayesian telah memperlihatkan kecepatan dan akurasi yang tinggi. Dengan menggunakan karakteristik termasuk usia, jumlah pinjaman, dan jangka waktu pinjaman dari kumpulan data Kredit Jerman, algoritma Naïve Bayes digunakan untuk mengkategorikan risiko kredit konsumen dalam kerangka riset ini. Rumus ini memanfaatkan Teorema Bayes dengan asumsi independensi fitur, memungkinkan perhitungan probabilitas kelas secara efisien (Raharjo, 2021).

b. Adaboost (Adaboost Classifier)

Atau algoritma ensemble yang membangun strong learner dari serangkaian weak learner. Dalam riset ini, GaussianNB digunakan sebagai base estimator dengan `n_estimator=50`, yang berarti 50 weak learner akan dilatih. *Adaboost* membentuk strong learner dari kombinasi weak

learners, dengan rumus prediksinya yang ditunjukkan untuk menghasilkan gabungan hasil prediksi akhir(Perwira 2019).

c. Random forest (Random Forest Classifier)

Algoritma ensemble berbasis pohon keputusan yang membangun banyak pohon keputusan secara independent selama pelatihan dan menghasilkan prediksi dengan mengambil rata-rata (untuk regresi) atau suara mayoritas(untuk klasifikasi) dari prediksi masing-masing pohon (Bintoro et al., n.d.). Parameter $n_estimator=100$ digunakan, yang berarti 100 pohon keputusan akan dibangun untuk memaksimalkan klasifikasi risiko kredit nasabah pada dataset German Credit.

Setiap pohon dilatih mempergunakan sampel acak (*bootstrap sampling*) serta subset acak dari fitur. Prediksi akhir memperoleh melalui mekanisme voting mayoritas(mode) dari keseluruhan pohon. Dengan pendekatan ini, *Random Forest* mampu mengurangi varians model dan memaksimalkan akurasi prediksi karena hasil tidak hanya bergantung pada satu pohon keputusan, melainkan pada gabungan banyak pohon. Pada rumus akhir *Random Forest* yang menghasilkan gabungan banyak pohon.

d. XGBoost

XGBoost, sebuah algoritma gradient boosting canggih yang diperkenalkan oleh Dr. Tianqi Chen pada tahun 2014, digunakan dalam riset ini dengan parameter $n_estimators=100$ dan $eval_metric='logloss'$. Algoritma ini secara iteratif menyesuaikan parameter untuk meminimalkan fungsi kerugian, menangani tugas klasifikasi dengan efektif sambil mengurangi risiko overfitting melalui penyederhanaan fungsi tujuan dan integrasi regularisasi. Dipilih karena efisiensi komputasi dan kemampuan menangani ketidakseimbangan kelas, XGBoost mencapai keseimbangan antara kompleksitas model dan performa, membuatnya pilihan optimal untuk klasifikasi risiko kredit (Permata & Nababan, 2023). Hyperparameter tuning dilakukan dengan GridSearchCV(10-fold) pada Random Forest ($n_estimators: 100-500$, $max_depth: 10-30$) dan XGBoost ($learning_rate:0.01-0.3$, $n_estimators: 100-400$).

Pengujian dan evaluasi model

Setiap model latih pada data latih (x_train, y_train) dan kemudian dievaluasi kinerjanya pada data uji (x_test, y_test). Metrik evaluasi yang dipergunakan mencakup (Budi et al., 2024):

- a. Akurasi (Accuracy) :Proporsi prediksi yang benar dari total prediksi pada rumus 7.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \dots\dots\dots(7)$$

- b. Presisi (Precision) : Proporsi kasus positif yang diperkirakan dengan benar dari keseluruhan kasus yang diperkirakan positif pada rumus 8.

$$Precision = \frac{TP}{TP+FP} \dots\dots\dots(8)$$

- c. Recall (Recall/Sensitivitas: Proporsi kasus positif yang diperkirakan dengan benar dari keseluruhan kasus positif actual pada rumus 9.

$$Recall = \frac{TP}{TP+FN} \dots\dots\dots(9)$$

- d. F1-Score: Rata-rata dari presisi dan recall memberikan keseimbangan diantara keduanya pada rumus 10.

$$F1 = \frac{Precision \cdot Recall}{Precision + Recall} \dots \dots \dots (10)$$

- e. Confusion matrix: Tabel yang memperlihatkan jumlah true positif(TP). True Negative (TN), False Positif(FP), dan False Negatif (FN). Dalam confusion tersebut sangat penting untuk memahami jenis kesalahan yang dibuat model pada rumus 11.

$$\begin{bmatrix} TN & FP \\ FN & TP \end{bmatrix} \dots \dots \dots (11)$$

True Positif (TP), True Negative (TN), False Positif (FP), False Negatif (FN).


- f. Validasi Silang(Cross-Validation): dilaksanakan 10-fold *Cross Validation* pada seluruh datasets (x_scaled, y) untuk mendapat estimasi kinerja model yang lebih robust dan mengurangi bias yang mungkin timbul dari satu pembagian data.
- g. UC adalah metrik dari kurva ROC yang memperlihatkan trade-off antara True Positive Rate (recall) dan False Positif rate pada berbagai threshold. Nilainya antara 0-1, makin dekat ke 1, model makin baik membedakan fraud dan non fraud. AUC independent dari threshold spesifik, alhasil memberikan evaluasi komprehensif. Metrik ini menawarkan pandangan dengan keseluruhan performa model (Irawan, 2025).
- h. Analisis Interpretabilitas dengan Explainable Artificial Intelligence dengan SHAP
 Untuk memaksimalkan interpretabilitas model, teknik Explainable Artificial Intelligence (XAI) berupa SHapley Additive exPlanations (SHAP) diterapkan pada model terbaik guna menganalisis kontribusi fitur terhadap prediksi risiko kredit. XAI, sebagai pendekatan baru dalam pembelajaran mesin, menangani keterbatasan model black box dengan memvisualisasikan hubungan antar fitur dan besarnya pengaruhnya, alhasil menghasilkan sistem yang lebih mudah dipahami. Berbasis konsep teori permainan, SHAP menghitung nilai Shapley untuk setiap fitur mempergunakan shap.Explainer dan shap.summary_plot, memberikan wawasan mendalam tentang cara model menghasilkan prediksi. Dalam riset ini, SHAP Summary Plot mengungkapkan bahwa fitur seperti Jumlah Kredit dan Durasi Pinjaman memiliki pengaruh terbesar terhadap risiko kredit, memungkinkan ilmuwan data dan pemangku kepentingan di perbankan untuk memahami proses pengambilan keputusan model secara transparan dan mendukung pengembangan model yang lebih terpercaya (Ghildiyal et al., 2025).

HASIL DAN PEMBAHASAN

Riset ini tujuannya untuk mengkategorikan risiko kredit nasabah mempergunakan algoritma *machine learning*(*Naïve Bays, Adaboost, Random Forest, dan XGBoost*) dengan dataset German Credit Data yang terdiri dari 1000 entri nasabah riset ini dilakukan dengan mengikuti alur kerja machine learning, yang mencakup pemuatan dataset,pra-pemrosesan data, pembagian data, pelatihan model, evaluasi model dengan 10-fold cross-validation, dan analisis interpretabilitas mempergunakan teknik Explainable AI berupa SHAP. Untuk menangani ketidakseimbangan kelas, teknik SMOTE(*Synthetic Minority Oversampling Technique*) diterapkan dalam model. Dalam riset ini mempergunakan pustaka Python seperti Pandas, Scikit-Learn, XGBoost, dan SHAP, serta dijalankan pada tools Google Colaboratory. Tujuan utama adalah

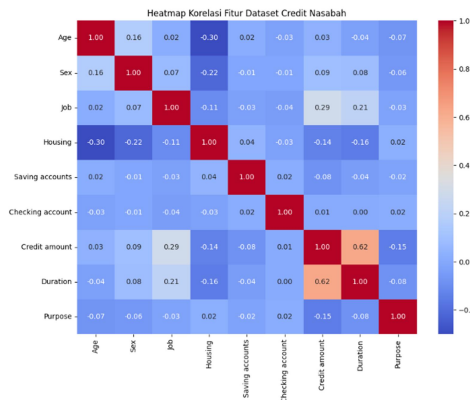
memperbandingkan performa algoritma dan mengidentifikasi fitur-fitur yang paling berpengaruh terhadap prediksi risiko kredit, alhasil mendukung pengambilan keputusan yang lebih akurat dan transparan di sektor perbankan.

Visualisasi distribusi kelas target (Risk) sebelum dan sesudah penerapan SMOTE ditampilkan melalui dua grafik berdampingan (countplot), mencerminkan perubahan signifikan dalam komposisi data. Sebelum SMOTE, terlihat ketidakseimbangan dengan sekitar 700 entri untuk kelas Risiko Rendah (0) dibandingkan 300 entri untuk Risiko Tinggi (1), namun setelah penerapan SMOTE melalui simulasi `smote.fit_resample(X_scaled, y)`, distribusi jadi lebih seimbang dengan jumlah sampel sintesis yang merata. Visualisasi ini relevan karena memperlihatkan efektivitas SMOTE dalam memaksimalkan recall kelas minoritas, yang menjadi dasar penting untuk peningkatan akurasi model pada tahap evaluasi berikutnya. Visualisasi distribusi kelas target sebelum dan sesudah disajikan pada gambar 5.



Gambar 5. Visualisasi Distribusi Kelas Sebelum dan Sesudah SMOTE.

Analisis data eksploratif pada dataset kredit nasabah mengungkapkan ketidakseimbangan kelas target risk, dengan 700 entri untuk kelas Low Risk (0) dan 300 untuk High Risk (1) dari total 1000 nasabah. Visualisasi distribusi ini dilengkapi dengan heatmap korelasi antar fitur setelah normalisasi mempergunakan StandardScaler, yang memperlihatkan hubungan linear antar variabel dengan skala warna 'coolwarm' dan anotasi nilai, seperti korelasi positif signifikan ~ 0.62 antara Credit amount dan Duration (mengindikasikan durasi pinjaman cenderung meningkat seiring jumlah pinjaman), serta korelasi moderat antara Job dan Age. Korelasi ini dapat memengaruhi kinerja model klasifikasi, khususnya algoritma yang sensitif terhadap multikolinearitas, alhasil heatmap ini memberikan dasar empiris untuk menganalisis dependensi fitur, mendukung pemilihan fitur, dan memfasilitasi interpretasi hasil model terkait pengaruh fitur utama terhadap risiko kredit disajikan dalam bentuk heatmap pada gambar 6



Gambar 6. Heatmap Korelasi Fitur Dataset Credit Nasabah

Evaluasi model Naïve Bayes melalui 10-fold cross-validation, dengan metrik utama yang mencakup akurasi rata-rata (Mean: 0.805, Std: 0.052), precision(Mean: 0.889), recall (Mean: 0.805), F1-score (Mean: 0.822), dan ROC-AUC (Mean: 0.908) yang dihitung mempergunakan cross_validate dengan scoring weighted. Confusion matrix memberikan gambaran distribusi prediksi, memperlihatkan 41 prediksi benar untuk kelas negatif dan 1 untuk kelas positif, dengan 36 dan 122 kesalahan masing-masing. Hasil ini relevan untuk menganalisis performa model secara kuantitatif dalam konteks klasifikasi risiko kredit, dengan standar deviasi yang memperlihatkan stabilitas model di berbagai lipatan validasi. Evaluasi ditujukan pada table 2 dan table 3 untuk pemodelan Naïve Bayes

Tabel 2. Evaluasi Naïve Bayes

Evaluasi Model	Cross Validation 10-fold Accuracy Mean	Standar Deviasi (Std)	Precision Mean	Recall Mean	F1 Score	ROC-AUC
Naïve Bayes	0,805	0,052	0,889	0,805	0,822	0,908

Tabel 3. Confusion Matrix Naïve Bayes

	Diprediksi 0 (Low Risk)	Diprediksi 1(High Risk)
Aktual 0 (Low Risk)	41(TN)	1 (FP)
Aktual 1 (High Risk)	36 (FN)	122 (TP)

Hasil evaluasi model Adaboost melalui 10-fold cross-validation, dengan akurasi rata-rata (Mean: 0.805, Std: 0.052), Precision (Mean: 0.889), recall (Mean: 0.805), F1-score (Mean: 0.822), dan ROC-AUC (Mean: 0,908) dihitung mempergunakan cross_validate dengan scoring weighted, confusion matrix memperlihatkan prediksi yang mencerminkan 41 True Negatives, 122 True Positives, 1 False Positives, dan 36 False Negatives. Dibandingkan dengan Naïve Bayes yang memiliki akurasi memiliki kesamaan (0,805), Adaboost memperlihatkan performa yang sama dalam mendeteksi kelas minoritas dengan recall dan precision yang sama. Namun memiliki perbedaan melalui ROC-AUC lebih kecil dibandingkan Naïve Bayes. Jika presi adalah mengurangi false negatives, Adaboost terbukti belum efektif, karena dilihat pada hasil memiliki kesamaan antara naïve bayes dan Adaboost. untuk keseimbangan metrik yang lebih baik, penyesuaian lebih lanjut mungkin diperlukan. Evaluasi ditujukan pada table 4 dan table 5 untuk evaluasi model adaboost confusion matrix

Tabel 4. Evaluasi Model Adaboost

Evaluasi Model	Cross Validation 10-fold Accuracy Mean	Standar Deviasi (Std)	Precision Mean	Recall Mean	F1 Score	ROC-AUC
AdaBoost	0,805	0,052	0,889	0,805	0,822	0,886

Tabel 5. Confusion Matrix Adaboost

Diprediksi 0 (Low Risk)	Diprediksi 1(High Risk)
Aktual 0 (Low Risk)	41 (TN) 1 (FP)
Aktual 1 (High Risk)	36(FN) 122 (TP)

Hasil evaluasi model Random Forest melalui 10-fold cross-validation, dengan metrik utama yang mencakup akurasi rata-rata (Mean: 0.870, Std: 0.036), presisi (Mean: 0.879), recall (Mean: 0.870), F1-score (Mean: 0.873), dan ROC-AUC (Mean: 0,931) dihitung mempergunakan cross_validate dengan scoring weighted, confusion matrix memperlihatkan prediksi 36 True Negatives, 140 True Positives, 6 False Positives, dan 18 False Negatives. Hasil ini menyoroti performa luar biasa model ini dalam klasifikasi risiko kredit, dengan stabilitas tinggi di berbagai lipatan validasi, membuatnya pilihan unggul dibandingkan model lain seperti Naïve Bayes atau Adaboost berdasarkan akurasi dan inkonsistensi 0,805 ke 0,870 metrik evaluasi. Evaluasi ditujukan pada table 6 dan table 7 untuk evaluasi model Random Forest dan Confussion Matrix.

Tabel 6. Evaluasi Model Random Forest

Evaluasi Model	Cross Validation 10-fold Accuracy Mean	Standar Deviasi (Std)	Precision Mean	Recall Mean	F1 Score	ROC-AUC
Random Forest	0,870	0,036	0,879	0,870	0,873	0,931

Tabel 7. Confusion Matrix Random Forest

Diprediksi 0 (Low Risk)	Diprediksi 1(High Risk)
Aktual 0 (Low Risk)	36 (TN) 6 (FP)
Aktual 1 (High Risk)	18 (FN) 140 (TP)

Hasil evaluasi model XGBoost melalui 10-fold cross-validation, dengan metrik utama yang mencakup akurasi rata-rata (Mean: 0.854, Std: 0.041), presisi (Mean: 0.873), recall (Mean: 0.854), F1-score (Mean: 0.859), dan ROC-AUC (Mean: 0.928) dihitung mempergunakan cross_validate dengan scoring weighted, serta matriks konfusi 34 True Negatives, 137 True Positives, False Positif 8 dan False Negative 21. Hasil ini mengindikasikan performa XGBoost

kompetitif dengan Random Forest, dengan keunggulan efisiensi komputasi, meskipun recall sedikit lebih rendah. Evaluasi ditujukan pada tabel 8 untuk evaluasi Model XGBoost dan Confussion Matrix.


Tabel 8. Tabel Evaluasi Model XGBoost

Evaluasi Model	Cross Validation 10-fold Accuracy Mean	Standar Deviasi (Std)	Precision Mean	Recall Mean	F1 Score	ROC-AUC
XGBoost	0,854	0,041	0,873	0,854	0,859	0,928

Tabel 9. Confusion Matrix XGBoost

	Diprediksi 0 (Low Risk)	Diprediksi 1 (High Risk)
Aktual 0 (Low Risk)		34 (TN) 8 (FP)
Aktual 1 (High Risk)		21 (FN) 137 (TP)

SHAP Summary Plot untuk model terbaik (Random Forest), yang memperlihatkan kontribusi relatif setiap fitur terhadap prediksi risiko kredit. Fitur seperti Credit amount dan Duration memiliki pengaruh terbesar, dihitung menggunakan shap.Explainer dan shap.summary_plot. Plot ini menggambarkan nilai Shapley per fitur, dengan warna memperlihatkan arah pengaruh (merah: memaksimalkan risiko tinggi). Relevansinya adalah memaksimalkan interpretabilitas model, memenuhi kebutuhan transparansi dalam pengambilan keputusan perbankan, dan mendukung kesimpulan bahwa fitur keuangan utama adalah prediktor kunci risiko. Berikut gambar hasil dari SHAP Summary Plot ditujukan pada gambar 5.



Gambar 5. SHAP Summary Plot untuk Random Forest.

Hal ini konsisten dengan temuan dari analisis SHAP, yang memperlihatkan *Credit amount* dan *Duration* adalah fitur paling berpengaruh terhadap prediksi risiko kredit. *SHAP Summary Plot* mengindikasikan bahwa nilai *Credit amount* yang lebih tinggi memaksimalkan probabilitas prediksi *Risiko Tinggi*, sedangkan fitur lain seperti *Saving accounts* dan *Checking account* juga memberikan kontribusi signifikan, meskipun lebih kecil. Penggunaan SHAP memaksimalkan interpretabilitas model, memungkinkan bank untuk memahami faktor-faktor utama yang mendorong keputusan kredit dan memenuhi kebutuhan transparansi dalam pengambilan Keputusan.

Random Forest memperlihatkan akurasi tertinggi dengan stabilitas yang baik, ditunjukkan oleh standar deviasi yang rendah. Penerapan SMOTE dalam *pipeline* memaksimalkan *recall* kelas minoritas (*Risiko Tinggi*), memungkinkan model untuk lebih baik mengidentifikasi nasabah berisiko tinggi tanpa mengorbankan akurasi keseluruhan. XGBoost juga memperlihatkan performa kompetitif, dengan keunggulan dalam efisiensi komputasi berkat optimisasi gradien. Naïve Bayes, meskipun sederhana dan cepat, memiliki akurasi yang lebih rendah dibandingkan model *ensemble* seperti Random Forest dan XGBoost, kemungkinan karena asumsi independensi fitur yang tidak sepenuhnya terpenuhi dalam dataset. Adaboost, dengan *GaussianNB* sebagai *base estimator*, memperlihatkan peningkatan dibandingkan Naïve Bayes standalone, tetapi tidak melampaui Random Forest atau XGBoost.

Secara keseluruhan, riset ini memperlihatkan metode *ensemble* seperti Random Forest dan XGBoost, yang didukung oleh SMOTE untuk menangani ketidakseimbangan kelas, lebih unggul dalam akurasi dan stabilitas dibandingkan metode probabilistik seperti Naïve Bayes. Penggunaan SHAP memberikan nilai tambah dengan menjelaskan kontribusi fitur, mendukung aplikasi praktis dalam pengambilan keputusan kredit yang lebih akurat dan transparan. Hasil ini berkontribusi pada pengembangan model klasifikasi risiko kredit yang lebih robust dan dapat dipercaya di sektor perbankan.

Perbandingan Kinerja Model

Perbandingan kinerja model secara keseluruhan, termasuk hasil akurasi validasi silang (10-fold), disajikan pada Tabel 11

Tabel 10. Perbandingan Hasil Kinerja Model

Model	Akurasi (Mean)	Akurasi (Std)	Precision Mean	Recall Mean	F1-Score Mean	AUC (Area Under the Curve)
<i>Naïve Bayes</i>	81%	0.052	0.889	0.805	0.822	0.908
<i>Adaboost</i>	81%	0.052	0.889	0.805	0.822	0.886
<i>Random Forest</i>	87%	0.036	0.879	0.870	0.873	0.931
<i>XGBoost</i>	85%	0.041	0.874	0.859	0.866	0.928

Berdasarkan Tabel 11, Random Forest menyentuh akurasi rata-rata tertinggi sejumlah 87% dengan standar deviasi rendah 0.036, diikuti XGBoost (85%, Std: 0.041), sementara Naïve Bayes dan AdaBoost sama-sama berada di 81% (Std: 0.052). Meskipun XGBoost merupakan algoritma boosting yang lebih modern dengan optimisasi gradien dan regularisasi bawaan, Random Forest unggul dalam riset ini terutama karena pendekatan bagging paralelnya yang lebih efektif mengurangi varians pada dataset berukuran sedang seperti German Credit (1000 entri) dengan fitur relatif sederhana. XGBoost cenderung lebih sensitif terhadap tuning hyperparameter dan memperlihatkan stabilitas sedikit lebih rendah (standar deviasi lebih tinggi), alhasil kurang optimal dalam setting eksperimen ini. Namun, keduanya tetap kompetitif pada metrik ROC-AUC (masing-masing 0.931), dengan Random Forest juga unggul pada recall (0.87) dan F1-score (0.87) yang lebih seimbang, membuatnya pilihan paling adaptif untuk klasifikasi risiko kredit dengan dimensi data rendah.

Tabel 11. Hasil Penelitian Sebelumnya

Nama Peneliti	Model	Akurasi (Data Uji)	AUC (<i>Area Under the Curve</i>)
Jurnal Achmad Yani dan Ega Hegarini	<i>Artificial Neural Network (ANN) dan Backpropagation</i>	71,33 %	0.72
Jurnal Budi Prasoj dan Emy Haryatmi	<i>Random Forest</i>	83%	0.83

Pada penelitian sebelumnya Achmad Yani dan Ega Hegarini [3] dalam penelitiannya mempergunakan metode Artificial Neural Network (ANN) dengan Backpropagation pada dataset German Credit (1000 data), riset ini menyentuh akurasi data uji 71,%. Dari hasil penelitian tersebut tidak mempergunakan akurasi secara spesifik precision, atau recall secara rinci. AUC sejumlah 0,72 mengkategorikan model sebagai Fair Model, menandakan efektivitas sedang tetapi memerlukan optimasi lebih lanjut untuk menangani pola secara kompleks dalam data kredit. Hasil tersebut ditunjukkan pada tabel 6. Penelitian selanjutnya dari Prasoj dan Emy Haryatmi [4] dengan mempergunakan metode *Random Forest* pada dataset yang sama German Credit (1000 data) dan memperoleh akurasi data uji 83%. Tidak ada akurasi cross-validation seperti halnya pada penelitian sebelumnya. Namun AUC sejumlah 0,83 mengkategorikan model sebagai “*Very Good Model*”, memperlihatkan performa yang kuat dalam prediksi kelayakan kredit dengan teknik ensemble yang menggabungkan multiple pohon keputusan. Hasil tersebut ditunjukkan pada table 12.

KESIMPULAN

Riset ini berhasil mengimplementasikan algoritma Naïve Bayes, AdaBoost, Random Forest, dan XGBoost untuk mengkategorikan risiko kredit nasabah mempergunakan dataset German Credit yang terdiri dari 1000 entri. Untuk menangani permasalahan ketidakseimbangan kelas, dipergunakan metode *Synthetic Minority Over-sampling Technique* (SMOTE), serta metode Shapley Additive explanations (SHAP) untuk memaksimalkan tingkat interpretabilitas model.

Berlandaskan hasil evaluasi mempergunakan metode 10-fold cross-validation, Random Forest memperlihatkan kinerja terbaik dengan akurasi rata-rata sejumlah 87% (standar deviasi: 0,036), precision sejumlah 0,879, recall sejumlah 0,870, F1-score sejumlah 0,873, dan nilai ROC-AUC sejumlah 0,931. Sementara itu, XGBoost memperlihatkan performa yang kompetitif dengan akurasi sejumlah 85% (standar deviasi: 0,041) dan nilai ROC-AUC sejumlah 0,928, namun memiliki tingkat stabilitas dan recall yang relatif lebih rendah. Di sisi lain, Naïve Bayes dan AdaBoost memperlihatkan kinerja yang lebih rendah dengan akurasi sejumlah 81%.

Keunggulan Random Forest dibandingkan XGBoost dapat dikaitkan dengan penggunaan pendekatan bagging secara paralel yang efektif dalam mengurangi variansi, khususnya pada dataset berukuran sedang dengan karakteristik fitur yang relatif sederhana. Sebaliknya, XGBoost memiliki sensitivitas yang lebih tinggi terhadap konfigurasi hyperparameter, alhasil memerlukan proses optimasi yang lebih mendalam untuk mencapai performa optimal. Analisis interpretabilitas mempergunakan SHAP memperlihatkan fitur Credit Amount dan Duration merupakan variabel yang paling berpengaruh dalam menentukan tingkat risiko kredit tinggi, dengan nilai korelasi sekitar 0,62, alhasil memaksimalkan transparansi serta kepercayaan terhadap model yang dihasilkan.

Selain itu, penerapan SMOTE terbukti efektif dalam memaksimalkan kemampuan model dalam mengidentifikasi kelas minoritas tanpa mengurangkan kinerja keseluruhan. Hasil riset ini juga memperlihatkan peningkatan performa dibandingkan penelitian sebelumnya[3], yang menampilkan akurasi sejumlah 71,33% mempergunakan Artificial Neural Network dan 83% mempergunakan Random Forest. Peningkatan tersebut didukung oleh integrasi teknik SMOTE dan metode ensemble learning, alhasil Random Forest dapat direkomendasikan sebagai model yang adaptif untuk klasifikasi risiko kredit. Namun demikian, riset ini masih memiliki keterbatasan, khususnya terkait penggunaan dataset publik yang belum merepresentasikan kondisi perbankan di Indonesia.

DAFTAR PUSTAKA

- Ardana, Y., Wulandari, W., & Septiadi, D. (2021). Perbankan dan pertumbuhan ekonomi di Indonesia: Analisis error correction model. *Jurnal Masharif Al-Syariah: Jurnal Ekonomi dan Perbankan Syariah*, 6(3), 674. <https://doi.org/10.30651/jms.v6i3.7578>
- Aryani, Y., & Wijayanto, A. W. (2021). Klasifikasi pengembalian radar dari ionosfer mempergunakan SVM, Naïve Bayes dan Random Forest. *Komputika: Jurnal Sistem Komputer*, 10(2), 111–117. <https://doi.org/10.34010/komputika.v10i2.4347>
- Bintoro, I. P. P., Ratnasari, R., Wihardjo, E., & Asari, A. (n.d.). *Pengantar machine learning*.
- Budi, E. S., Chan, A. N., Alda, P. P., & Idris, M. A. F. (2024). Optimasi model machine learning untuk klasifikasi dan prediksi citra menggunakan algoritma convolutional neural network. *RESOLUSI: Rekayasa Teknik Informatika dan Informasi*, 4(5), 502–509.
- Chang, V., Xu, Q. A., Akinloye, S. H., Benson, V., & Hall, K. (2024). Prediction of bank credit worthiness through credit risk analysis: An explainable machine learning study. *Annals of Operations Research*. <https://doi.org/10.1007/s10479-024-06134-x>
- Fauzihan, A., Sajiwo, B., Rahmat, B., & Junaidi, A. (2024). Klasifikasi indeks standar pencemaran udara (ISPU) menggunakan XGBoost dengan teknik imbalanced data. *[Nama Jurnal]*, 12(3).
- Ghildiyal, V., Danu, A., Verma, V., & Bhat, A. (2025). Explainable AI. <https://doi.org/10.1201/9781003536901-8>

- Ismafillah, D., Rohana, T., & Cahyana, Y. (2023). Analisis algoritma pohon keputusan untuk memprediksi penyakit diabetes menggunakan oversampling SMOTE. [*Nama Jurnal*], 4, 27–36.
- Momole, G. M. (2022). Perbandingan Naïve Bayes dan Random Forest dalam klasifikasi bahasa daerah. *JATISI (Jurnal Teknik Informatika dan Sistem Informasi)*, 9(2), 855–863. <https://doi.org/10.35957/jatisi.v9i2.1857>
- Permata, I., & Nababan, E. S. M. (2023). Analisis perbandingan algoritma XGBoost dan algoritma Random Forest ensemble learning pada klasifikasi keputusan kredit. *Jurnal Riset Rumpun Matematika dan Ilmu Pengetahuan Alam*, 2(2), 65–71.
- Perwira. (2019). *Pembuatan sistem deteksi serangan DOS menggunakan algoritma Adaboost classifier dan Raspberry PI3*. <http://eprints.upnyk.ac.id/31575/1/BUKU%20Adabost.pdf>
- Prasojo, B., & Haryatmi, E. (2021). Analisa prediksi kelayakan pemberian kredit pinjaman dengan metode Random Forest. *Jurnal Nasional Teknologi dan Sistem Informasi*, 7(2), 79–89. <https://doi.org/10.25077/teknosi.v7i2.2021.79-89>
- Qurahman, T., Mustakim, & Jaini, A. (2019). Penerapan algoritma Naïve Bayes classifier dan probabilistic neural network untuk klasifikasi nasabah bank dalam membayar kredit. *Seminar Nasional Teknologi Informasi, Komunikasi dan Industri*, 205–213.
- Raharjo, B. (2021). *Pembelajaran mesin*. Codepolitan. <https://www.codepolitan.com/mengenal-teknologi-machine-learning-pembelajaran-mesin>
- Santoso, J. T. (2023). *Ilmu data* (Vol. 1).
- Sari, V., Firdausi, F., & Azhar, Y. (2020). Perbandingan prediksi kualitas kopi Arabika dengan menggunakan algoritma SGD, Random Forest dan Naive Bayes. *Edumatic: Jurnal Pendidikan Informatika*, 4(2), 1–9. <https://doi.org/10.29408/edumatic.v4i2.2202>
- Scheule, H. (2020). *Deep credit risk*.
- Yani, A. (2019). Analisa kelayakan kredit menggunakan artificial neural network dan backpropagation (Studi kasus German credit data). *Jurnal Ilmiah Komputasi*, 18(4), 385–390. <https://doi.org/10.32409/jikstik.18.4.2672>