

## KOMPARASI DAN IMPLEMENTASI ALGORITMA MACHINE LEARNING UNTUK KLASIFIKASI KREDIT BERMASALAH PADA PT BPR NUSUMMA KLATEN

### COMPARISON AND IMPLEMENTATION OF MACHINE LEARNING ALGORITHMS FOR CLASSIFYING NON-PERFORMING LOANS AT PT BPR NUSUMMA KLATEN

Teguh Muryanto<sup>1</sup>, Aji Nurrohman<sup>2</sup>, Rachmat Setiabudi<sup>3</sup>, Wibisono<sup>4</sup>, Berliyanto<sup>5</sup>

Teknik Informatika, Institut Teknologi Budi Utomo, Jakarta, Indonesia<sup>1,2,3,4,5</sup>

teguh@itbu.ac.id<sup>1</sup>, [ajinurrohman@itbu.ac.id](mailto:ajinurrohman@itbu.ac.id)<sup>1</sup>, [rachmats@itbu.ac.id](mailto:rachmats@itbu.ac.id)<sup>3</sup>, [wibisono@itbu.ac.id](mailto:wibisono@itbu.ac.id)<sup>4</sup>,  
[berliyanto@itbu.ac.id](mailto:berliyanto@itbu.ac.id)<sup>5</sup>

#### ABSTRACT

*A high level of non-performing loans can disrupt the financial stability of banking institutions, making it essential to have an accurate classification system to detect potential defaults at an early stage. This study aims to develop and compare credit risk classification models using machine learning algorithms, namely Random Forest, XGBoost, and Support Vector Machine (SVM). The issues addressed in this research include inaccurate customer classification, lack of utilization of historical data, and the absence of intelligent algorithm-based analytical methods. The research methodology follows the Cross-Industry Standard Process for Data Mining (CRISP-DM), which includes business understanding, data exploration, data preprocessing, modeling, model evaluation, and implementation. The dataset used was sourced from historical credit reports of customers at PT BPR Nusumma Klaten. The models were evaluated based on accuracy, precision, recall, F1-score, and AUC. The results indicate that the Random Forest algorithm performed best, showing more stable evaluation scores compared to XGBoost and SVM. These findings are expected to assist financial institutions in enhancing the efficiency of credit risk analysis processes and enabling data-driven decision-making.*

**Keywords:** Non-performing Loans, Random Forest, XGBoost, SVM, Classification.

#### ABSTRAK

Tingkat kredit bermasalah yang tinggi dapat mengganggu stabilitas keuangan lembaga perbankan, sehingga diperlukan sistem klasifikasi yang akurat untuk mendeteksi potensi gagal bayar sejak dini. Penelitian ini bertujuan untuk membangun dan membandingkan model klasifikasi risiko kredit menggunakan algoritma machine learning, yaitu Random Forest, XGBoost, dan Support Vector Machine (SVM). Permasalahan yang diangkat dalam penelitian ini meliputi ketidakakuratan dalam klasifikasi nasabah, kurangnya pemanfaatan data historis, serta belum diterapkannya metode analitik berbasis algoritma cerdas. Metode penelitian mengikuti pendekatan Cross-Industry Standard Process for Data Mining (CRISP-DM) yang mencakup pemahaman bisnis, eksplorasi data, praproses data, pemodelan, evaluasi model, hingga tahap implementasi. Dataset yang digunakan berasal dari laporan historis nasabah kredit di PT BPR Nusumma Klaten. Evaluasi dilakukan dengan mengukur akurasi, precision, recall, F1-score, dan AUC. Hasil penelitian menunjukkan bahwa algoritma Random Forest memiliki kinerja terbaik dengan nilai evaluasi yang lebih stabil dibandingkan XGBoost dan SVM. Temuan ini diharapkan dapat membantu lembaga keuangan dalam meningkatkan efisiensi proses analisis risiko kredit dan pengambilan keputusan berbasis data.

**Kata Kunci:** Kredit Bermasalah, Random Forest, XGBoost, SVM, Klasifikasi

#### PENDAHULUAN

Dalam dunia perbankan dan lembaga keuangan, risiko kredit menjadi salah satu tantangan utama yang harus dihadapi. Kredit bermasalah atau non-performing loan (NPL) dapat berdampak negatif pada kesehatan keuangan suatu institusi, sehingga diperlukan sistem yang efektif untuk mengklasifikasikan nasabah berdasarkan potensi gagal bayar. Dengan

meningkatnya volume data keuangan, pemanfaatan metode berbasis kecerdasan buatan seperti Random Forest, Extreme Gradient Boosting (XGBoost) dan Support Vector Machine (SVM) menjadi solusi yang dapat meningkatkan akurasi dalam prediksi risiko kredit.

Di banyak lembaga keuangan, proses penentuan tingkat risiko kredit masih dilakukan secara manual menggunakan

pendekatan tradisional, seperti analisis laporan keuangan dan wawancara dengan calon debitur. Namun, metode ini memiliki keterbatasan karena bergantung pada subjektivitas penilai dan sering kali kurang efisien dalam menangani jumlah data yang besar. Seiring berkembangnya teknologi data mining dan machine learning, muncul kebutuhan untuk menerapkan sistem otomatis yang dapat membantu mengidentifikasi risiko kredit secara lebih akurat dan cepat.

Salah satu permasalahan utama dalam pengelolaan kredit adalah bagaimana mengklasifikasikan nasabah ke dalam kategori kredit lancar atau bermasalah berdasarkan riwayat pembayaran. Beberapa nasabah memiliki saldo tabungan tinggi tetapi masih mengalami kesulitan dalam membayar cicilan, sementara yang lain memiliki pinjaman kecil tetapi tetap mengalami gagal bayar. Tantangan ini membuat lembaga keuangan perlu menemukan pola-pola risiko yang lebih akurat berdasarkan data historis kredit.

Untuk mengatasi tantangan tersebut, penelitian ini mengusulkan penggunaan algoritma Random Forest, XGBoost dan SVM sebagai metode klasifikasi risiko kredit. Random Forest merupakan teknik ensemble learning yang mampu mengurangi overfitting dan bekerja dengan baik pada data kompleks. XGBoost digunakan untuk mengatasi masalah klasifikasi atau regresi dengan data yang besar dan kompleks. Sementara SVM dapat memisahkan kelas data dengan margin maksimal untuk menghasilkan prediksi yang lebih akurat. Ketiga algoritma ini akan digunakan untuk menentukan model terbaik dalam memprediksi nasabah dengan risiko gagal bayar tinggi.

Dengan menerapkan pendekatan berbasis machine learning, diharapkan lembaga keuangan dapat meningkatkan efektivitas dalam manajemen risiko kredit. Penggunaan algoritma Random Forest, XGBoost, dan SVM tidak hanya dapat membantu dalam mengidentifikasi calon debitur yang berpotensi bermasalah, tetapi

juga dapat meningkatkan efisiensi pengambilan keputusan, mengurangi jumlah kredit bermasalah, serta mendukung stabilitas keuangan perusahaan dalam jangka panjang.

## **METODE PENELITIAN**

### **1. Jenis Penelitian**

Penelitian ini menggunakan pendekatan kuantitatif eksploratif-komparatif. Pendekatan ini dipilih karena fokus utama dari penelitian adalah melakukan pengukuran dan evaluasi performa tiga algoritma machine learning Random Forest, XGBoost, dan SVM dalam mengklasifikasikan status kolektibilitas nasabah. Tujuan komparatif di sini adalah untuk mengetahui metode mana yang paling optimal secara statistik dan teknis dalam kasus klasifikasi tingkat kredit bermasalah. Jenis penelitian yang digunakan adalah eksperimen komputasional berbasis data historis nasabah dari BPR Nusumma Klaten, dengan pengolahan data dilakukan secara sistematis melalui pendekatan CRISP-DM.

### **2. Kerangka Pemikiran**

Permasalahan kredit bermasalah merupakan tantangan utama yang dihadapi oleh lembaga keuangan, termasuk PT BPR Nusumma Klaten. Selama ini, proses penilaian risiko kredit dilakukan secara manual dan bersifat subjektif, sehingga berpotensi menghasilkan klasifikasi yang kurang akurat. Untuk mengatasi permasalahan tersebut, diperlukan pendekatan berbasis teknologi yang mampu mengklasifikasikan tingkat risiko kredit secara otomatis, objektif, dan efisien.

Kerangka pemikiran dalam penelitian ini dimulai dari perumusan masalah, yaitu bagaimana meningkatkan Accuracy klasifikasi tingkat kredit bermasalah melalui pemanfaatan data historis nasabah menggunakan algoritma machine learning. Permasalahan ini dianalisis dan diselesaikan melalui pendekatan CRISP-DM yang terdiri dari enam tahapan utama: business understanding, data

understanding, data preparation, modeling, evaluation, dan deployment.

Tahap awal dalam proses ini adalah pengumpulan data, yang menggunakan data sekunder berupa laporan nominatif kredit nasabah dari PT BPR Nusumma Klaten per 31 Maret 2025. Data tersebut mencakup atribut penting yang berkaitan dengan risiko kredit, seperti baki debit, tunggakan pokok, tunggakan bunga, saldo tabungan, dan kolektibilitas.

Selanjutnya, dilakukan tahap persiapan data atau data preparation, yang mencakup pembersihan data, transformasi variabel, pengkodean label, normalisasi, serta pembagian data menjadi data latih dan data uji. Tujuan dari tahap ini adalah untuk memastikan bahwa data yang digunakan memenuhi standar teknis pemodelan.

Tahap berikutnya adalah pemodelan atau modeling, di mana tiga algoritma machine learning diterapkan untuk membangun model klasifikasi, yaitu Random Forest, XGBoost, dan SVM. Masing-masing model dilatih menggunakan data latih, kemudian diuji performanya menggunakan data uji.

Hasil dari pemodelan selanjutnya dievaluasi pada tahap evaluasi model, dengan menggunakan metrik evaluasi seperti accuracy, precision, recall, dan F1-score. Evaluasi ini bertujuan untuk mengukur dan membandingkan performa model dalam mengklasifikasikan data secara akurat serta memilih model terbaik.

Model dengan kinerja tertinggi kemudian diimplementasikan melalui tahap deployment, yakni integrasi ke dalam aplikasi web interaktif berbasis Streamlit. Aplikasi ini memungkinkan petugas kredit untuk memasukkan data nasabah dan memperoleh hasil klasifikasi kolektibilitas secara otomatis. Tahapan ini bertujuan agar hasil penelitian dapat dioperasionalkan dalam praktik nyata di lingkungan kerja.

Selanjutnya, dilakukan tahap pembahasan, yang berfokus pada analisis terhadap hasil evaluasi model, perbandingan performa antar algoritma, serta keterkaitannya dengan konteks bisnis

yang dihadapi oleh BPR Nusumma Klaten. Analisis ini juga mengevaluasi kelebihan dan keterbatasan masing-masing algoritma.

Sebagai penutup, dilakukan penarikan kesimpulan, yang berisi jawaban atas rumusan masalah, ringkasan temuan utama, serta rekomendasi terhadap penerapan sistem klasifikasi berbasis machine learning dalam mendukung proses pengambilan keputusan kredit. Untuk memperjelas alur penelitian, kerangka pemikiran disajikan dalam bentuk diagram berikut:



**Gambar 1. Kerangka Pemikiran**

## METODE PENELITIAN

### 1) Metode Pengumpulan Data

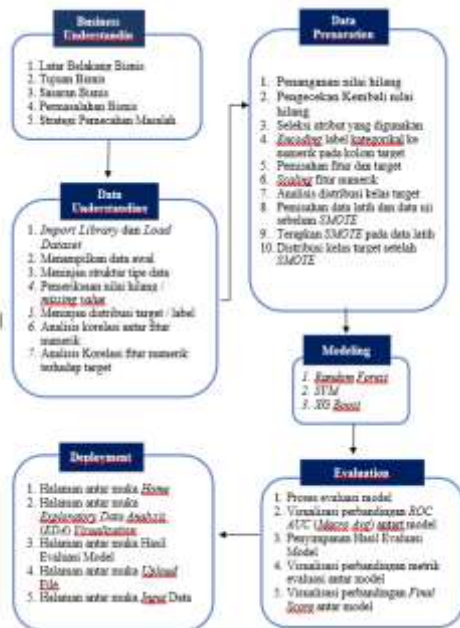
Pengumpulan data dalam penelitian ini dilakukan dengan menggunakan metode dokumen. Data yang digunakan berupa data sekunder, yang diperoleh dari PT BPR Nusumma Klaten dalam bentuk file CSV yang berisi laporan nominatif kredit per tanggal 31 Maret 2025.

Proses pengumpulan data dilakukan melalui izin resmi dari pihak BPR Nusumma Klaten dan digunakan secara terbatas untuk keperluan penelitian akademik. Data yang telah diperoleh kemudian digunakan dalam seluruh tahapan analisis mulai dari eksplorasi sampai evaluasi.

### 2) Skema Pelaksanaan Penelitian

Untuk mempermudah pemahaman mengenai tahapan-tahapan yang dilakukan dalam penelitian ini, maka disusun sebuah skema pelaksanaan

penelitian berdasarkan pendekatan CRISP-DM. Skema ini menggambarkan alur proses yang dimulai dari pemahaman bisnis hingga evaluasi dan hasil akhir penelitian. Setiap tahapan dalam skema ini merepresentasikan proses yang saling terkait dan dilakukan secara sistematis guna mencapai tujuan dari penelitian. Skema pelaksanaan penelitian dapat dilihat pada Gambar berikut:



Gambar 1. Diagram proses Tahapan

## HASIL DAN PEMBAHASAN

### 1. Business Understanding

BPR Nusumma Klaten merupakan lembaga keuangan yang fokus pada penyaluran kredit kepada masyarakat, khususnya pelaku usaha kecil dan menengah. Dalam menjalankan fungsinya, BPR menghadapi tantangan dalam menjaga kualitas kredit yang disalurkan. Salah satu indikator utama kinerja bank adalah tingkat kredit bermasalah atau Non-Performing Loan, yang dapat memengaruhi kesehatan keuangan dan kepercayaan nasabah terhadap institusi. Proses penilaian kelayakan kredit yang masih dilakukan secara manual atau berdasarkan intuisi petugas berisiko menghasilkan keputusan yang kurang akurat.

Tujuan bisnis dari penelitian ini adalah untuk membantu BPR Nusumma Klaten dalam meningkatkan efektivitas dan

efisiensi proses penilaian kelayakan kredit dengan cara menyediakan sistem berbasis machine learning yang mampu mengklasifikasikan tingkat risiko kredit secara otomatis. Dengan adanya sistem ini, diharapkan bank dapat:

1. Mengurangi jumlah kredit bermasalah.
2. Meningkatkan kualitas portofolio kredit.
3. Mempercepat proses analisis kredit.
4. Mengoptimalkan pengambilan keputusan yang berbasis data.

Permasalahan utama yang dihadapi oleh BPR Nusumma Klaten berkaitan dengan kurang optimalnya proses seleksi calon debitur, yang berisiko menimbulkan terjadinya kredit bermasalah. Terdapat sejumlah permasalahan spesifik yang mengindikasikan ketidakefisienan serta ketidaktepatan dalam penilaian kelayakan calon debitur, antara lain:

1. Tidak adanya sistem yang dapat memprediksi potensi risiko kredit secara otomatis.
2. Penilaian subjektif oleh petugas yang rentan terhadap bias.
3. Tingginya rasio kredit bermasalah dalam beberapa periode tertentu.
4. Keterbatasan waktu dan sumber daya untuk menganalisis data nasabah secara menyeluruh.

Untuk menjawab permasalahan tersebut, strategi yang ditawarkan dalam penelitian ini adalah menerapkan metode klasifikasi berbasis machine learning guna membangun model prediksi terhadap potensi kredit bermasalah. Strategi ini mencakup beberapa tahapan, yaitu:

1. Pengumpulan serta pemahaman terhadap data historis nasabah dari BPR Nusumma Klaten.
2. Praproses data dan eksplorasi fitur yang memiliki relevansi terhadap risiko kredit.
3. Implementasi dan komparasi beberapa algoritma klasifikasi seperti Random Forest, XGBoost, dan SVM.
4. Evaluasi kinerja model menggunakan metrik seperti akurasi, precision, recall, dan F1-score.




No.	Kolektibilitas	Jumlah nasabah	Keterangan
1	Lancar	677	Mayoritas pinjaman berada dalam kondisi lancar, yang berarti nasabah membayar angsuran tepat waktu tanpa tunggakan.
2	Dalam Perhatian Khusus	16	Nasabah yang mulai menunjukkan indikasi keterlambatan, biasanya 2-3 bulan.
3	Kurang Lancar	16	Tunggakan antara 3-4 bulan, memerlukan pemantauan intensif.
4	Diragukan	12	Tunggakan lebih dari 4 bulan dan potensi gagal bayar mulai tinggi.
5	Macet	6	Pinjaman tidak tertagih, perlu tindakan penvelamatan atau penegasan buku.

kolektibilitas lancar, sedangkan sisanya 6,9% tersebar di kategori risiko yang lebih tinggi yaitu Dalam perhatian Khusus, Kurang Lancar, Diragukan, dan Macet.

Distribusi ini menunjukkan bahwa secara umum, portofolio kredit masih berada dalam kondisi sehat, meskipun tetap perlu perhatian khusus terhadap nasabah yang berada di luar kategori "Lancar".

### 5) Analisis Korelasi Pearson antar Fitur Numerik

Analisis korelasi digunakan untuk mengetahui tingkat hubungan linear antar variabel numerik dalam dataset. Dalam penelitian ini, korelasi dihitung menggunakan metode Pearson, yang merupakan teknik statistik untuk mengukur kekuatan dan arah hubungan linear antara dua variable.



**Gambar 6. Output Matriks Korelasi antar fitur numerik**

Berdasarkan Gambar 6 dilakukan analisis korelasi antar variabel numerik guna mengidentifikasi hubungan linier yang kuat maupun lemah antar fitur.

#### 1. Korelasi Positif Kuat

- 1) Jumlah\_pinjaman sangat berkorelasi dengan :

- baki\_debet (**0.93**)
- tunggakan\_pokok (**0.40**)
- total\_tunggakan (**0.43**)

1) baki\_debet memiliki korelasi tinggi dengan :

- jumlah\_pinjaman (**0.93**)
- total\_tunggakan (**0.51**)

2) tunggakan\_pokok, tunggakan\_bunga, dan total\_tunggakan menunjukkan korelasi sangat tinggi antar satu sama lain :

- tunggakan\_pokok dengan total\_tunggakan: **0.99**
- tunggakan\_bunga dengan total\_tunggakan: **0.50**
- tunggakan\_pokok dengan tunggakan\_bunga: **0.36**
- ft\_pokok dengan ft\_bunga: **0.95**

#### 2. Korelasi Negatif atau Lemah

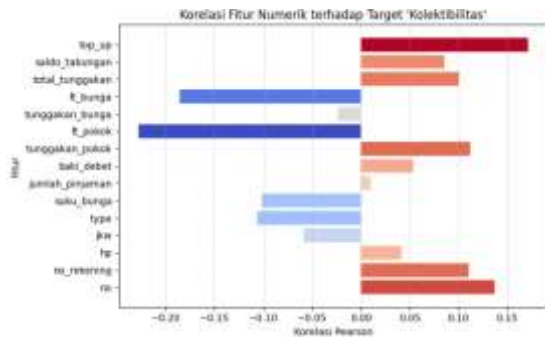
1) no, no\_rekening, dan hp memiliki korelasi sangat lemah atau mendekati nol terhadap semua fitur — wajar karena sifatnya lebih sebagai pengenalan identitas atau ID.

2) type dan suku\_bunga tidak menunjukkan hubungan yang kuat terhadap fitur numerik lainnya.

3) top\_up cenderung memiliki korelasi rendah dengan semua variabel (maksimal sekitar **0.40** dengan baki\_debet).

### 6) Analisis Korelasi Fitur Numerik terhadap Target

Tahap ini melakukan analisis korelasi antara fitur numerik dan variabel target kolektibilitas guna menilai kontribusi masing-masing fitur dalam proses klasifikasi kredit bermasalah. Tahapan ini diperlukan untuk menilai tingkat keterkaitan setiap fitur dan membantu pemilihan variabel yang paling relevan terhadap model klasifikasi.



**Gambar 7. Output Korelasi fitur terhadap target kolektibilitas**

Dari visualisasi gambar 7, terlihat bahwa nilai korelasi antar fitur terhadap target bervariasi, baik positif maupun negatif.

**Tabel 2. Penjelasan hasil analisis korelasi fitur numerik terhadap target**

No	Nama fitur	Nilai korelasi	Interpretasi singkat
1	Top up	0.17	Korelasi positif sedang; makin tinggi top up, maka makin rentan kolektibilitas
2	No	0.14	Positif, fitur ini mungkin mengandung informasi urutan atau volume
3	No rekening	0.11	Positif; bisa jadi efek teknis, perlu kajian lebih lanjut
4	Tunggakan pokok	0.11	Positif; logis bahwa makin tinggi tunggakan pokok, risiko kolektibilitas naik
5	Total tunggakan	0.10	Positif; mendukung logika bahwa total tunggakan memengaruhi kolektibilitas
6	Saldo tabungan	0.09	Positif lemah; makin tinggi tabungan tidak selalu mengurangi risiko
7	Hp	0.04	Korelasi lemah; kemungkinan noise atau tidak relevan
8	Jumlah pinjaman	0.01	Sangat lemah; tidak ada pengaruh signifikan
9	Baki debet	0.05	Positif lemah; bisa jadi terkait jumlah pinjaman tersedia
10	Tunggakan bunga	-0.02	Negatif sangat lemah; tidak signifikan
11	Jku	-0.06	Negatif lemah; makin panjang jangka waktu, maka potensi risiko menurun
12	Suku bunga	-0.10	Negatif lemah; suku bunga tinggi cenderung menurunkan kolektibilitas
13	Type	-0.11	Negatif; mungkin menunjukkan segmentasi nasabah tertentu
14	Ft bunga	-0.19	Negatif sedang; anomali, bisa jadi karena penalti bunga ditoleransi
15	Ft pokok	-0.23	Negatif tinggi; makin besar ft pokok, semakin rendah kolektibilitas

### 3. Data Preparation

#### 1) Penanganan nilai Hilang

Berikut ini merupakan kode program Untuk menangani nilai hilang pada kolom HP, digunakan metode imputasi dengan nilai rata-rata (mean).

```
# Isi missing value numerik dengan rata-rata
df.fillna(df.mean(numeric_only=True), inplace=True)
```

**Gambar 8. Perintah Penanganan Nilai Hilang**

#### 2) Pemeriksaan nilai hilang setelah penanganan

Setelah dilakukan pengisian nilai hilang, dilakukan pengecekan ulang untuk memastikan bahwa seluruh nilai kosong telah teratasi.

```

jumlah Missing Values per Kolom:
no                0
no_rekening      0
hp                0
nama_pinjaman   0
alamat           0
nama_no          0
realisasi        0
jku              0
j_tempo          0
type             0
suku_bunga       0
jumlah_pinjaman 0
baki_debet       0
tunggakan_pokok 0
ft_pokok         0
tunggakan_bunga 0
ft_bunga         0
total_tunggakan 0
saldo_tabungan   0
kolektibilitas   0
otp              0
top_up           0
dtype: int64

```

**Gambar 9. Output**

#### Pemeriksaan Ulang nilai hilang

Berdasarkan Gambar 9, seluruh kolom pada dataset sudah tidak memiliki nilai hilang. Dengan demikian, proses penanganan data hilang telah berhasil

#### 3) Encoding Label Kategorikal ke Numerik pada Kolom kolektibilitas

Dalam proses pra-pemrosesan data atau preprocessing, langkah penting yang perlu dilakukan adalah mengubah data kategorikal menjadi data numerik agar bisa diproses oleh algoritma machine learning. Salah satu metode yang digunakan adalah Label Encoding, yaitu memberi representasi angka pada setiap kategori.

```

Mapping label ke angka:
Dalam Perhatian Khusus --> 0
Diragukan --> 1
Kurang Lancar --> 2
Lancar --> 3
Macet --> 4

```

**Gambar 10. Output konversi label kategorikal ke numerik**

Hasil dari proses encoding pada gambar 10 tersebut menghasilkan mapping sebagai berikut:

Tabel 3 Mapping label ke angka

kolektibilitas	Angka
Dalam perhatian khusus	0
Diragukan	1
kurang lancar	2
Lancar	3
Macet	4

#### 4)Pemisahan Fitur Dan Target

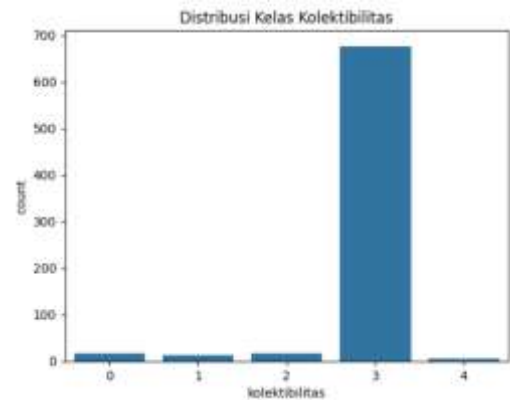
Langkah berikutnya adalah memisahkan antara fitur dan target. Pada tahap ini, variabel kolektibilitas dipisahkan dari DataFrame utama dan disimpan ke dalam variabel y sebagai target yang akan diprediksi. Sementara itu, seluruh fitur selain kolektibilitas disimpan dalam variabel X yang akan digunakan sebagai input pada model klasifikasi. Pemisahan ini bertujuan untuk memudahkan proses pelatihan model serta evaluasi performa berdasarkan label yang telah ditentukan.

#### 5)Scaling fitur numerik

Langkah selanjutnya yang dilakukan adalah proses scaling atau penyesuaian skala data numerik. Penyesuaian ini bertujuan untuk menyamakan skala antar fitur, agar tidak terdapat fitur dengan skala nilai yang jauh lebih besar dibandingkan fitur lainnya, yang dapat mempengaruhi kinerja beberapa algoritma pembelajaran mesin.

#### 6)Analisis Distribusi Kelas Target

Tahap berikutnya adalah dilakukan analisis terhadap distribusi kelas pada variabel target kolektibilitas. Tujuan dari analisis ini adalah untuk mengetahui apakah terdapat ketidakseimbangan jumlah data antar kelas atau class imbalance, yang dapat berdampak negatif terhadap kinerja model pembelajaran mesin.



**Gambar 11. Output Distribusi kelas kolektibilitas**

Dari gambar 11 menunjukkan bahwa:

- 1) Kelas 3 atau lancar mendominasi secara signifikan dengan jumlah sekitar 677 data poin.
- 2) Kelas lainnya (0, 1, 2, 4) hanya memiliki 16, 12, 16, dan 6 data poin secara berturut-turut.

Kelas minoritas sangat sedikit dan berpotensi diabaikan oleh model machine learning, karena model cenderung mengikuti pola mayoritas. Dampak pada Model *Machine Learning* :

1. *Overfitting* ke kelas mayoritas: Model bisa memprediksi semua data sebagai kelas "Lancar" dan tetap memperoleh *Accuracy* tinggi secara semu.
2. Rendahnya sensitivitas terhadap kelas minoritas: Model sulit mendeteksi nasabah yang bermasalah karena jumlah datanya sangat sedikit.
3. Bias keputusan: Sistem rekomendasi atau risiko kredit bisa menjadi tidak adil atau tidak akurat.

Untuk mengatasi ketidakseimbangan distribusi kelas pada data target, dilakukan teknik penyeimbangan data menggunakan metode *Synthetic Minority Over-sampling Technique (SMOTE)* Metode ini bekerja dengan mensintesis data baru pada kelas minoritas agar proporsinya menjadi seimbang dengan kelas mayoritas,


sehingga model dapat belajar secara adil terhadap seluruh kelas.

### 7) Pemisahan data latih dan data uji sebelum SMOTE

Pemisahan ini bertujuan untuk menghindari overfitting serta untuk mengukur kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya.

Pada tahap ini, data dibagi menjadi dua bagian, yaitu data latih 80 % dan data uji 20 %. Pemisahan dilakukan secara stratified, yaitu mempertahankan proporsi distribusi kelas pada data latih dan data uji agar tetap sama seperti data awal. Parameter `random_state=42` digunakan agar hasil pembagian data bersifat reproducible.

### 8) Distribusi Kelas Target setelah SMOTE



Gambar 12 Output Distribusi kelas kolektibilitas setelah SMOTE

Gambar 12 menunjukkan distribusi kelas kolektibilitas setelah dilakukan proses penyeimbangan data menggunakan metode SMOTE. Terlihat bahwa jumlah sampel pada masing-masing kelas telah merata, masing-masing sekitar 581 sampel. Hal ini menunjukkan bahwa teknik SMOTE berhasil mengatasi permasalahan ketidakseimbangan kelas atau class imbalance dalam data, sehingga model klasifikasi yang dibangun nantinya tidak bias terhadap kelas mayoritas.

### 4. Modeling

Pada tahap ini, dilakukan proses pemodelan menggunakan tiga algoritma klasifikasi, yaitu *Random*

*Forest*, *SVM*, dan *XGBoost*. Untuk memastikan bahwa setiap model memperoleh data yang telah diproses secara konsisten, diterapkan pipeline yang terdiri atas tiga tahapan utama:

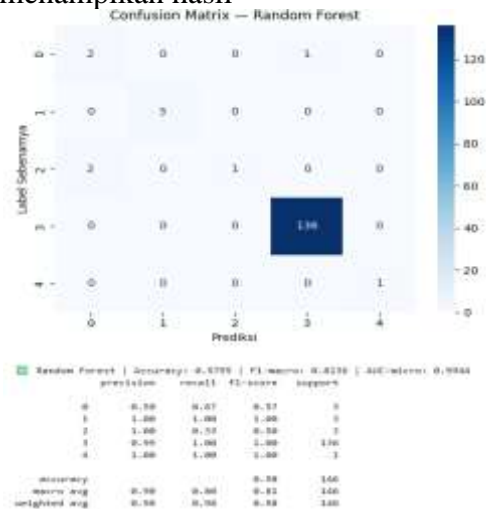
1. Standarisasi dengan *StandardScaler()* untuk menyamakan skala fitur numerik.
2. Penyeimbangan kelas dengan teknik *SMOTE*, guna menangani ketidakseimbangan distribusi kelas. Nilai parameter *k\_neighbors* disesuaikan secara dinamis berdasarkan jumlah minimum sampel per kelas.
3. Klasifikasi, menggunakan algoritma yang digunakan.

Pipeline ini dibentuk menggunakan *Pipeline* dari pustaka *imblearn*, sehingga seluruh tahapan preprocessing dan pelatihan model dapat dilakukan secara terintegrasi. Hal ini penting untuk menjaga konsistensi saat training dan testing

### 5. Evaluation

#### 1) Proses evaluasi model

Pada tahap ini, setiap model yang telah dilatih menggunakan data latih akan diuji terhadap data pengujian. Proses evaluasi dilakukan dengan menghitung nilai accuracy, ROC AUC, precision, recall, dan f1-score dari hasil prediksi terhadap data uji. Kode program untuk menampilkan hasil

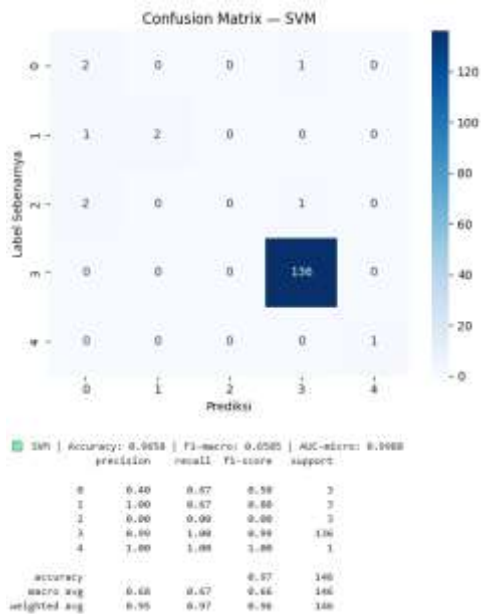


Gambar 13. Output Hasil evaluasi model Random Forest

Pada gambar 13 diinterpretasikan kedalam penjelasan pada table 3

**Tabel 3. metrik model random forest**


Model	Accuracy	ROC AUC	Precision (Macro)	Recall (Macro)	F1-score (Macro)
Random Forest	0.9795	0.9944	0.90	0.80	0.81



**Gambar 14. Output Hasil evaluasi model SVM**

Pada gambar 14 diinterpretasikan kedalam penjelasan pada table 4

Model	Accuracy	ROC AUC	Precision (Macro)	Recall (Macro)	F1-score (Macro)
SVM	0.9658	0.9988	0.68	0.67	0.66




**Gambar 15. Output Hasil evaluasi model XGBoost**

Pada gambar 15 diinterpretasikan kedalam penjelasan pada table 5

**Tabel 5. metrik model XGBoost**

Model	Accuracy	ROC AUC	Precision (Macro)	Recall (Macro)	F1-score (Macro)
XGBoost	0.9795	0.9992	0.72	0.80	0.75

**2) Visualisasi perbandingan final score antar model**



**Gambar 16. Output perbandingan final score antar model**

Gambar 16 menyajikan perbandingan nilai Final Score dari tiga algoritma klasifikasi yang diuji, yaitu Random Forest, SVM, dan XGBoost.

Berdasarkan visualisasi tersebut, model Random Forest memperoleh nilai tertinggi sebesar 0,9291, diikuti oleh XGBoost dengan nilai 0,9093, dan SVM dengan nilai 0,8744

Final Score diperoleh dari rata-rata tiga metrik evaluasi utama, yaitu Accuracy, F1-score, dan ROC AUC, sehingga dapat mencerminkan performa model secara lebih menyeluruh.

Dengan hasil tersebut, dapat disimpulkan bahwa Random Forest merupakan model dengan performa terbaik secara keseluruhan dan paling layak untuk digunakan dalam klasifikasi tingkat kolektibilitas nasabah.

**6. Deployment**

**1) Halaman antar muka Home**



**Gambar 17. Tampilan menu Home**

Home Merupakan halaman beranda yang memberikan informasi umum mengenai tujuan dari aplikasi, yaitu untuk memprediksi kolektibilitas nasabah dengan memasukkan data secara manual ataupun melalui unggahan file.

## 2) Halaman antar muka EDA Visualization



**Gambar 18. Tampilan menu EDA Visualization**

Menu *Exploratory Data Analysis (EDA)* pada aplikasi ini berfungsi untuk menyajikan visualisasi eksploratif terhadap data yang digunakan dalam proses klasifikasi kolektibilitas nasabah. Tujuan utama dari menu ini adalah untuk membantu pengguna memahami pola distribusi, hubungan antar variabel, serta kecenderungan karakteristik data berdasarkan kelas kolektibilitas.

Beberapa fitur visualisasi yang tersedia dalam menu *EDA* antara lain:

### 1. Distribusi Fitur berdasarkan kolektibilitas

Visualisasi ini bertujuan untuk menunjukkan sebaran nilai dari sejumlah variabel numerik terhadap masing-masing kategori kolektibilitas. Dengan plot ini, dapat diamati bagaimana karakteristik data menyebar di tiap kelompok kolektibilitas, serta mendeteksi adanya outlier atau pola khusus yang dapat memengaruhi hasil analisis lebih lanjut. Perbedaan distribusi antar kelompok dapat menjadi indikasi bahwa fitur tersebut memiliki

relevansi terhadap status kolektibilitas nasabah.

### 2. Matriks Korelasi Antar Fitur Numerik

Visualisasi ini menunjukkan tingkat keterkaitan linear antara setiap pasangan variabel numerik. Nilai korelasi berkisar dari -1 hingga 1, di mana angka mendekati 1 menunjukkan hubungan positif yang kuat, sedangkan mendekati -1 menunjukkan hubungan negatif yang kuat. Matriks ini berguna untuk mengidentifikasi variabel-variabel yang memiliki hubungan saling mempengaruhi,

Matriks korelasi antar fitur numerik disajikan dalam dua bentuk visualisasi, yaitu tabel korelasi untuk menunjukkan nilai hubungan antar variabel secara detail, dan heatmap guna mempermudah identifikasi pola keterkaitan melalui gradasi warna.

### 3. Perbandingan Fitur terhadap kolektibilitas

Pada bagian ini disediakan visualisasi interaktif yang bertujuan untuk mengevaluasi keterkaitan antara masing-masing variabel numerik dengan kategori kolektibilitas nasabah. Pengguna dapat memilih satu fitur numerik tertentu dan

memvisualisasikannya berdasarkan tingkatan kolektibilitas menggunakan tiga jenis grafik, yaitu *boxplot*, *violinplot*, atau *barplot* rata-rata. Visualisasi ini membantu dalam mengidentifikasi perbedaan distribusi atau kecenderungan nilai dari suatu fitur pada setiap kategori kolektibilitas. Hasil perbandingan ini dapat digunakan untuk menilai relevansi suatu fitur terhadap status pembayaran kredit, serta memberikan gambaran awal mengenai fitur mana yang

berpotensi signifikan dalam proses klasifikasi tingkat kolektibilitas nasabah.

#### 4. *Countplot* Kolektibilitas Berdasarkan Fitur Kategorikal

Visualisasi ini bertujuan untuk menunjukkan sebaran jumlah nasabah pada masing-masing kategori kolektibilitas berdasarkan fitur bertipe kategorikal yang dipilih. Dengan memanfaatkan grafik batang atau *countplot*, pengguna dapat melihat bagaimana frekuensi setiap kelas kolektibilitas berubah di dalam masing-masing kategori fitur. Analisis ini berguna untuk mengetahui apakah ada kecenderungan tingkat kredit bermasalah yang lebih tinggi pada kelompok-kelompok tertentu, sehingga fitur tersebut dapat dipertimbangkan sebagai variabel penting dalam pemodelan klasifikasi kolektibilitas.

#### 5. Distribusi Kolektibilitas Nasabah

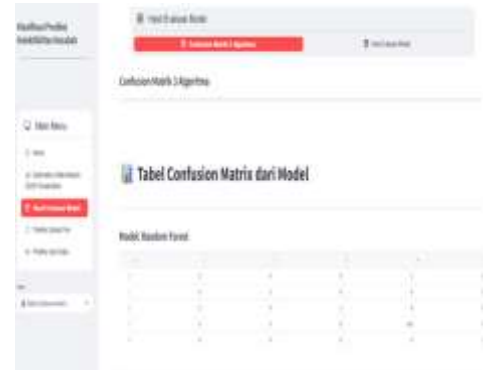
Visualisasi ini menyajikan jumlah nasabah pada masing-masing kategori kolektibilitas dalam bentuk grafik batang. Tujuan dari tampilan ini adalah untuk memberikan gambaran umum mengenai proporsi kelas kolektibilitas, apakah data bersifat seimbang atau mengalami ketimpangan antar kelas.

#### 6. Komposisi Kolektibilitas (*Pie/Donut*)

Visualisasi ini menampilkan persentase distribusi masing-masing kelas kolektibilitas dalam bentuk *pie chart* atau *donut chart*. Tujuan dari grafik ini adalah untuk memberikan gambaran proporsi jumlah nasabah di tiap kategori secara visual yang lebih intuitif. Dengan melihat komposisi ini, peneliti dapat mengetahui dominasi salah satu kelas serta

mengidentifikasi potensi ketidakseimbangan data.

### 3) Halaman antar muka Hasil Evaluasi Model



**Gambar 19. Tampilan menu hasil evaluasi model**

Evaluasi performa model klasifikasi dilakukan dengan menggunakan sejumlah metrik, antara lain Accuracy, presisi, recall, F1-score, dan ROC AUC. Berdasarkan hasil yang diperoleh, model XGBoost menunjukkan performa paling unggul dengan nilai Accuracy dan Final Score tertinggi, diikuti oleh algoritma Random Forest dan SVM. Hasil tersebut diperkuat oleh visualisasi confusion matrix yang mengindikasikan bahwa XGBoost mampu melakukan prediksi yang lebih tepat, khususnya pada kelas mayoritas

### 4) Halaman antar muka Prediksi Upload File



**Gambar 20. Tampilan menu Prediksi Upload File**

Pada Gambar 20 menunjukkan halaman ini pengguna diberikan kemudahan untuk mengunggah file data berformat .xlsx atau .csv yang berisi informasi kredit dari nasabah. Pengguna dapat mengunggah file dengan cara menyeret file ke area

yang telah disediakan dengan drag and drop atau memilih file secara manual melalui tombol Browse files. Aplikasi membatasi ukuran file yang dapat diunggah hingga 200MB per file guna menjaga performa sistem dan efisiensi pemrosesan. Setelah file diunggah, sistem akan secara otomatis memproses data dan menjalankan model klasifikasi untuk memprediksi tingkat kolektibilitas kredit nasabah.

Implementasi ini bertujuan untuk mendukung proses pengambilan keputusan kredit secara objektif, cepat, dan efisien, serta membuktikan bahwa model yang telah dibangun dapat diterapkan secara nyata dalam lingkungan operasional perbankan.

#### 5) Halaman antar muka Prediksi Input Data



**Gambar 21. Tampilan menu Prediksi Input Data**

Gambar 21, menunjukkan pengguna dapat memasukkan nilai untuk sejumlah variabel, antara lain total tunggakan, tunggakan pokok, baki debit, saldo tabungan, nilai top up, *ft\_pokok*, dan *ft\_bunga*. Input dilakukan secara numerik dengan antarmuka yang interaktif dan sederhana. Setelah data dimasukkan, pengguna dapat menekan tombol Prediksi untuk memperoleh hasil klasifikasi secara langsung. Fitur ini memungkinkan evaluasi kredit dilakukan secara individual tanpa perlu mengunggah berkas, sehingga mendukung fleksibilitas penggunaan dalam operasional perbankan.

## KESIMPULAN

Berdasarkan hasil penelitian yang dilakukan mengenai penerapan dan perbandingan *algoritma machine learning* dalam klasifikasi tingkat kredit bermasalah di PT BPR Nusumma Klaten, dapat disimpulkan beberapa hal sebagai berikut:

1. Berdasarkan hasil evaluasi model, penerapan *algoritma machine learning* terbukti mampu meningkatkan ketepatan dalam mengklasifikasikan nasabah berdasarkan risiko kredit. Di antara algoritma yang diuji, *Random Forest* menunjukkan performa paling stabil dan unggul dalam seluruh metrik evaluasi seperti *accuracy*, *presisi*, *recall*, *F1-score*, dan *AUC*. Hal ini menunjukkan bahwa pendekatan berbasis *machine learning* lebih unggul dibanding metode manual dalam proses klasifikasi kredit bermasalah.
2. Data historis nasabah memberikan kontribusi besar dalam pembangunan model prediksi yang akurat. Melalui tahapan *data preparation* dan analisis mendalam, informasi dari data historis berhasil dimanfaatkan untuk menemukan pola-pola tertentu yang berkaitan dengan kemungkinan gagal bayar. Dengan demikian, pemanfaatan data historis terbukti efektif dalam menunjang sistem klasifikasi risiko kredit berbasis *machine learning*.
3. Setiap algoritma memiliki keunggulan dan kelemahan masing-masing, namun dalam konteks penelitian ini, *Random Forest* menjadi pilihan terbaik karena mampu menangani data tidak seimbang dan menghasilkan klasifikasi yang konsisten. Oleh karena itu, pemilihan metode klasifikasi yang sesuai dengan karakteristik data sangat penting untuk mencapai hasil yang optimal dalam prediksi kredit bermasalah.

## UCAPAN TERIMA KASIH

Terima kasih disampaikan kepada pihak-pihak yang telah mendukung terlaksananya penelitian ini.

## REFERENSI

- [1] Mustika, Y. Ardilla, A. Manuhutu, N. Ahmad, I. Hasbi, Guntoro, M. A. Manuhutu, M. Ridwan, Hozairi, A. K. Wardhani, S. Alim, I. Romli, Y. Religia, D. T. Octafian, U. U. Sufandi and I. Ernawati, *Data Mining dan Aplikasinya*. Bandung: Widina Bhakti Persada Bandung, 2021.
- [2] I. Zulfa, R. Rayuwati, and K. Koko, “Implementasi data mining untuk menentukan strategi penjualan buku bekas dengan pola pembelian konsumen menggunakan metode apriori”, *Teknika: Jurnal Sains dan Teknologi*, vol. 16, no. 1, pp. 69–82, 2020.
- [3] K. Erwansyah, B. Andika, and R. Gunawan, “Implementasi data mining menggunakan asosiasi dengan algoritma Apriori untuk mendapatkan pola rekomendasi belanja produk pada Toko Avis Mobile”, *Jurnal Teknologi Sistem Informasi dan Sistem Komputer TGD*, vol. 4, no. 1, pp. 148–161, 2021.
- [4] D. A. Pamungkas, A. Amali, and U. D. Soer, “Analisis sentimen publik terhadap polusi udara di Kota Jakarta: Perbandingan algoritma Support Vector Machine, Naive Bayes, dan Random Forest”, *JUTISI: Jurnal Ilmiah Teknik Informatika dan Sistem Informasi*, vol. 13, no. 3, 2025.
- [5] L. W. Maahiroh, *Klasifikasi turnover karyawan menggunakan algoritma XGBoost (Studi kasus: Divisi Engineering, Perusahaan Jasa Pertambangan)*, Universitas Islam Indonesia, 2024.
- [6] S. E. H. Yulianti, O. Soesanto, and Y. Sukmawaty, “Penerapan metode Extreme Gradient Boosting (XGBoost) pada klasifikasi nasabah kartu kredit”, *JOMTA: Journal of Mathematics: Theory and Applications*, vol. 4, no. 1, pp. 21–26, 2022.
- [7] F. Asadi, “Studi literatur regulasi dan etika artificial intelligence (AI) dalam kebijakan kedokteran presisi (precision medicine)”, *Jurnal Fasilkom*, vol. 14, no. 1, pp. 59–65, 2024.
- [8] K. N. Erawati, N. N. D. Ardiani, and G. A. Santiago, “E-module interaktif berbasis flipbook pada matakuliah machine learning untuk meningkatkan kreatifitas mahasiswa”, *Jurnal Penjaminan Mutu*, vol. 10, no. 1, pp. 45–51, 2024.
- [9] R. Kaestria and E. F. Himmah, “Implementasi bahasa pemrograman python untuk path analysis”, *Jurnal Komputasi*, vol. 11, no. 2, pp. 105–117, 2023.
- [10] S. Rahman, A. Sembiring, D. Siregar, H. Khair, I. G. Prahmana, R. Puspadini, and M. Zen, *Python: Dasar dan Pemrograman Berorientasi Objek*. Yogyakarta: Tahta Media, 2023.
- [11] R. R. P. Asyrofi and R. Asyrofi, “Implementasi aplikasi Jupyter Notebook sebagai analisis kriteria plagiasi dengan teknik semantik”, *JUPI: Jurnal Ilmiah Penelitian dan Pembelajaran Informatika*, vol. 8, no. 2, pp. 627–637, 2023.
- [12] A. N. Khusna, *Pengelompokan reseller potensial menggunakan algoritma clustering K-Means pada Toko Premium Shopping*, Universitas PGRI Semarang, 2022.
- [13] A. N. C. Putra, *Sentimen analisis komentar mahasiswa EDOM dengan metode Support Vector Machine (SVM)*, Universitas Islam Sultan Agung Semarang, 2022.
- [14] R. A. Febriyanto, *Deteksi kesalahan data pada wireless sensor network menggunakan metode Undersampling dan algoritma klasifikasi Extra-Tree*, Universitas Islam Negeri Syarif Hidayatullah Jakarta, 2021.
- [15] N. A. R. Putra, *Website Artificial Intelligence untuk deteksi dini danker*

- darah menggunakan CNN,  
Universitas Dinamika, 2024.
- [16] I. G. A. Gunarsa and G. A. A. P. Dewi, “Kredit bermasalah dalam skor kolektibilitas 5 dan dampaknya bagi debitur,” *Jurnal Kertha Semaya*, vol. 12, no. 3, pp. 295–311, 2023.