

Pengembangan Website Prediksi Gagal Bayar Nasabah Kartu Kredit menggunakan Algoritma Machine Learning

Amin Nur Rais^{1*}, Warjiyono¹

¹ Informatika; Universitas Bina Sarana Informatika; Jl. Kramat Raya No.98, RT.2/RW.9, Kwitang, Kec. Senen, Kota Jakarta Pusat, Daerah Khusus Ibukota Jakarta 10450 (021) 21231170; e-mail: amin.arv@bsi.ac.id

² Sistem Informasi Akuntansi Kampus Kota Tegal; Universitas Bina Sarana Informatika; Jl. Kramat Raya No.98, RT.2/RW.9, Kwitang, Kec. Senen, Kota Jakarta Pusat, Daerah Khusus Ibukota Jakarta 10450 (021) 21231170; e-mail: warjiyono.wrj@bsi.ac.id

* Korespondensi: e-mail: amin.arv@bsi.ac.id

Diterima: 03 Juni 2025; Review: 05 Juni 2025; Disetujui: 18 Juni 2025

Cara sitasi: Rais AR, Warjiyono. 2025. Pengembangan Website Prediksi Gagal Bayar Nasabah Kartu Kredit menggunakan Algoritma Machine Learning. Information Management for Educators and Professionals. Vol 10(1): 73 - 82

Abstrak: Manajemen risiko gagal bayar kartu kredit masih menjadi tantangan utama bagi lembaga keuangan, terutama karena metode konvensional seperti statistik sederhana kurang mampu menangkap pola perilaku nasabah secara kompleks. Penelitian ini bertujuan untuk mengembangkan sistem prediksi risiko gagal bayar berbasis web yang mudah digunakan oleh pengguna non teknis dengan mengintegrasikan algoritma Extreme Gradient Boosting (XGBoost) sebagai pendekatan machine learning yang unggul dalam klasifikasi data historis. Metodologi penelitian meliputi tiga tahap utama: (1) pembangunan model prediktif menggunakan dataset publik "Default of Credit Card Clients" dari Kaggle dengan 30.000 entri dan 24 atribut, (2) pengembangan Application Programming Interface (API) dengan framework Flask untuk integrasi real-time, dan (3) implementasi antarmuka web untuk memudahkan penggunaan oleh pihak non-teknis. Model yang digunakan dalam pengembangan sistem ini menunjukkan akurasi 79,13%, presisi 52,99%, dan recall 50,11%. Sistem ini menerima input dalam format JavaScript Object Notation (JSON) dan menghasilkan klasifikasi risiko menjadi dua kategori: berisiko dan tidak berisiko. Integrasi model ke dalam platform web memungkinkan proses evaluasi risiko kredit dilakukan secara lebih efisien, akurat, dan dapat diakses tanpa keahlian teknis machine learning. Penelitian ini membuka peluang pengembangan sistem serupa untuk produk keuangan lainnya dengan penekanan pada peningkatan transparansi dan penanganan distribusi data yang tidak seimbang.

Kata kunci: prediksi gagal bayar, XGBoost, machine learning, risiko kredit, aplikasi web

Abstract: Managing credit card default risk remains a significant challenge for financial institutions, particularly because conventional methods such as basic statistical analysis often fail to capture complex patterns in customer behavior. This study aims to develop a web-based credit default prediction system that is accessible to non-technical users by integrating the Extreme Gradient Boosting (XGBoost) algorithm, a machine learning approach known for its strong performance in historical data classification. The research methodology consists of three main stages: (1) developing a predictive model using the public "Default of Credit Card Clients" dataset from Kaggle, which includes 30,000 entries and 24 attributes; (2) developing an Application Programming Interface (API) using the Flask framework for real-time integration; and (3) implementing a web interface to support user-friendly access. The model employed in this system achieved an accuracy of 79.13%, a precision of 52.99%, and a recall of 50.11%. The system accepts input in JavaScript Object Notation (JSON) format and provides binary classification results indicating whether a user is at risk or not. Integrating the model into a web platform enables more efficient, accurate, and accessible credit risk evaluation without requiring machine learning

expertise. This research presents an initial step toward developing similar systems for other financial products, with an emphasis on improving model transparency and addressing class imbalance in data distribution.

Keywords: *credit default prediction, XGBoost, machine learning, credit risk, web application*

1. Pendahuluan

Seiring dengan perkembangan teknologi informasi yang semakin pesat dan semakin berkembangnya layanan digitalisasi keuangan, risiko gagal bayar nasabah kartu kredit menjadi salah satu tantangan utama yang harus dihadapi oleh lembaga keuangan saat ini. Risiko gagal bayar ini berpotensi menimbulkan kerugian finansial dan mengganggu stabilitas sistem keuangan dari lembaga keuangan [1]. Dengan menggunakan metode konvensional untuk menilai risiko kredit, yang sering kali dengan proses yang manual atau menggunakan teknik statistik sederhana, kurang mampu menangkap pola kompleks dalam data nasabah sehingga akurasi terbatas. Menurut laporan dari Center for Indonesian Policy Studies (CIPS), model penilaian kredit konvensional dinilai belum mampu menjangkau kelompok masyarakat unbanked dan underbanked, serta memiliki keterbatasan dalam mengantisipasi risiko gagal bayar di tengah perubahan perilaku konsumen dan dinamika ekonomi digital. Hal ini menekankan urgensi untuk mengembangkan pendekatan baru dalam manajemen risiko kredit, seperti penggunaan model berbasis artificial intelligence dan data alternatif dalam inovasi credit scoring (ICS) [2].


Dengan memanfaatkan machine learning, XGBoost merupakan algoritma yang efektif dalam memprediksi risiko gagal bayar, dengan keunggulan pada akurasi dan efisiensi pengolahan data historis. Dibandingkan SVM dan Random Forest, XGBoost menunjukkan performa prediksi yang lebih baik, meskipun memiliki tantangan dalam kompleksitas tuning parameter [3]. Dengan mengintegrasikan model ini ke dalam aplikasi web memungkinkan prediksi dilakukan secara real-time dan interaktif, sehingga memudahkan pengambilan keputusan oleh keuangan [4]. Penelitian Gao et al. menunjukkan bahwa model XGBoost dapat meningkatkan akurasi prediksi gagal bayar hingga 15% dibandingkan dengan metode konvensional, sambil menyediakan interpretasi yang lebih jelas tentang faktor-faktor risiko utama [5]. Tantangan utama dalam implementasi model machine learning untuk prediksi risiko kredit adalah keterbatasan transparansi. Untuk mengatasinya, penggunaan teknologi Explainable Artificial Intelligence (XAI) memungkinkan model tidak hanya memberikan prediksi akurat tetapi juga penjelasan yang dapat dipahami [6].

Penelitian ini bertujuan untuk membangun model prediksi risiko gagal bayar nasabah kartu kredit menggunakan algoritma machine learning, khususnya XGBoost, yang diintegrasikan ke dalam aplikasi berbasis web. Model ini diharapkan mampu memberikan prediksi yang akurat dan real-time serta mendukung pengambilan keputusan keuangan secara lebih efektif. Dataset yang digunakan merupakan data publik nasabah kartu kredit yang tersedia di Kaggle dan telah banyak digunakan dalam studi sejenis [7], yang kemudian dilatih menggunakan metode machine learning untuk menghasilkan pengetahuan yang akan diimplementasikan dalam sistem berbasis web sebagai solusi inovatif dalam manajemen risiko kredit [8].

2. Metode Penelitian

Pada proses penelitian ini dilakukan dalam tiga tahap utama : pembuatan model, pembuatan API, dan pembuatan website [4]. Penelitian ini menggunakan pendekatan kuantitatif dengan desain eksperimental untuk menguji performa algoritma machine learning dalam memprediksi risiko gagal bayar nasabah kartu kredit [9]. Pada tahap pertama, pembuatan model machine learning menggunakan bahasa pemrograman python algoritma XGBoost yang dijalankan di google colabs dengan memanfaatkan dataset nasabah kartu kredit dari Kaggle sebagai bahan utama penelitian [10], yang telah melalui proses pra-pemrosesan. Dataset ini mencakup 30.000 entri dengan 24 atribut dan 1 label target, diproses menggunakan. Data kemudian data dibagi menggunakan teknik stratified sampling dengan rasio 80:20 untuk data pelatihan dan pengujian [11]. Pada kajian pustaka dibahas algoritma lain seperti Random Forest dan SVM, penelitian ini hanya menggunakan XGBoost karena pertimbangan efisiensi, skalabilitas, dan kemampuannya dalam menangani data dengan fitur kompleks. Fokus penelitian ini adalah membangun sistem prediksi yang terintegrasi, bukan melakukan perbandingan algoritmik, dengan tujuan utama menghindari klasifikasi keliru terhadap nasabah tidak layak. Oleh karena itu, evaluasi performa model difokuskan pada metrik akurasi dan presisi, meskipun nilai

recall tetap dicatat sebagai bagian dari hasil. Kedua, pembuatan API yang mengintegrasikan model XGBoost ke dalam layanan backend menggunakan framework Flask, memungkinkan prediksi dilakukan secara real-time dan dapat diakses oleh aplikasi lain secara efisien [12]. Ketiga, pembangunan website interaktif menggunakan teknologi HTML, CSS, JS, dan PHP yang berfungsi sebagai antarmuka pengguna untuk memasukkan data nasabah, menampilkan hasil prediksi, serta memberikan rekomendasi yang mudah dipahami, dengan fokus pada kemudahan akses, serta integrasi dengan backend API [3]. Pendekatan ini menggabungkan kekuatan machine learning dan teknologi web untuk memberikan solusi praktis dalam manajemen risiko kredit.



Sumber: Hasil Penelitian (2025)

Gambar 1. Metode Penelitian

Machine Learning

Machine Learning menjadi salah satu cabang dari artificial intelligence (kecerdasan buatan) yang memungkinkan sistem komputer untuk belajar dan membuat prediksi atau keputusan tanpa diprogram secara eksplisit untuk setiap situasi yang spesifik [13]. Dalam konteks prediksi risiko kredit, machine learning telah terbukti efektif dalam menganalisis pola data historis nasabah untuk mengidentifikasi kemungkinan gagal bayar. Penelitian oleh Nurdin et al. [14] menunjukkan bahwa pendekatan machine learning dapat meningkatkan akurasi prediksi kredit pembayaran dengan menganalisis berbagai variabel yang mempengaruhi kemampuan bayar nasabah.

Stratified Sampling

Stratified sampling merupakan teknik pembagian dataset yang mempertahankan proporsi kelas target dalam data training dan testing [15]. Teknik ini sangat penting dalam klasifikasi risiko kredit untuk memastikan model dapat belajar dari representasi data yang seimbang. Pembagian data dengan rasio 80:20 untuk training dan testing telah menjadi standar dalam machine learning research [16].

XGBoost

XGBoost merupakan algoritma ensemble learning yang terbukti unggul dalam prediksi risiko kredit [17]. Suhendry et al. [18] melaporkan akurasi 95% dan presisi 95% dalam prediksi keterlambatan pembayaran. Untuk mengatasi overfitting dan bias data, XGBoost dapat dioptimalkan dengan teknik seperti SMOTE-Tomek Link untuk penyeimbangan data [17] dan GridSearchCV untuk tuning parameter [18], sehingga meningkatkan stabilitas dan akurasi model pada data riil.

Evaluasi Model

Evaluasi performa model menggunakan metrik accuracy, precision, recall, dan F1-score memberikan gambaran komprehensif mengenai kemampuan prediksi model [19]. Dalam konteks prediksi gagal bayar, recall menjadi metrik yang sangat penting karena cost of missing actual default cases (false negative) umumnya lebih tinggi dibandingkan false positive [20].

API

API merupakan sekumpulan protokol dan tools yang memungkinkan berbagai aplikasi untuk berkomunikasi dan berbagi data secara efisien [21]. Dalam pengembangan sistem prediksi machine learning, API berperan sebagai jembatan antara model prediksi dengan aplikasi front-

end. Framework Flask telah menjadi pilihan populer untuk pengembangan API dalam ekosistem Python karena kesederhanaannya dan fleksibilitas tinggi [22].

Website Development

Website development melibatkan proses perancangan dan pembangunan aplikasi web yang dapat diakses melalui internet browser [23]. Dalam konteks sistem prediksi machine learning, website berfungsi sebagai user interface yang memungkinkan pengguna untuk berinteraksi dengan model prediksi secara intuitif. Teknologi modern seperti HTML5, CSS3, JavaScript, dan PHP memungkinkan pengembangan website yang responsive dan user-friendly [24].

3. Hasil dan Pembahasan

Fokus utama bagian hasil dan pembahasan pada implementasi web prediksi gagal bayar nasabah kartu kredit berbasis XGBoost machine learning. Penelitian ini menghasilkan sistem yang terintegrasi dimana terdiri dari tiga komponen utama yang saling berkolaborasi untuk menghasilkan prediksi berdasarkan model yang sudah dilatih, dimana ini akan menjelaskan secara rinci tahapan utama dalam pembangunan sistem, mulai dari pengembangan model machine learning, pembangunan Application Programming Interface (API) untuk mengintegrasikan model, hingga pengembangan antarmuka website yang dapat digunakan oleh pengguna. Ketiga bagian tersebut dibangun untuk berjalan secara sinergis agar prediksi gagal bayar nasabah kartu kredit dapat dilakukan secara efektif dan efisien.

Pembuatan Model Macnile Learning

Dalam pembuatan model machine learning ini, menggunakan dataset Default of Credit Card Clients yang diambil dari Kaggle public dataset. Dataset ini berisi informasi dari sekitar 30.000 nasabah kartu kredit dengan 24 atribut dan 1 label seperti pada tabel 1.

Tabel 1. Deskripsi Dataset

Nama Fitur	Deskripsi Singkat	Nilai	Rentang Nilai
ID	ID unik setiap klien	Numerik	-
LIMIT_BAL	Jumlah kredit yang diberikan	NT Dollar	≥ 0
SEX	Jenis kelamin	1=Pria, 2=Wanita	1-2
EDUCATION	Tingkat pendidikan	1-6	1-4 (utama), 5-6=Tidak diketahui
MARRIAGE	Status pernikahan	1=Menikah, 2=Lajang, 3=Lainnya	1-3
AGE	Umur dalam tahun	Numerik	≥ 18 (umumnya)
PAY_0	Status pembayaran Sep 2005	-1=sesuai jadwal, ≥ 1 =telat	-2 sampai 9
PAY_2	Status pembayaran Agu 2005	-1=sesuai jadwal, ≥ 1 =telat	-2 sampai 9
PAY_3	Status pembayaran Jul 2005	-1=sesuai jadwal, ≥ 1 =telat	-2 sampai 9
PAY_4	Status pembayaran Jun 2005	-1=sesuai jadwal, ≥ 1 =telat	-2 sampai 9
PAY_5	Status pembayaran Mei 2005	-1=sesuai jadwal, ≥ 1 =telat	-2 sampai 9
PAY_6	Status pembayaran Apr 2005	-1=sesuai jadwal, ≥ 1 =telat	-2 sampai 9
BILL_AMT1	Tagihan bulan Sep 2005	NT Dollar	Bisa negatif
BILL_AMT2	Tagihan bulan Agu 2005	NT Dollar	Bisa negatif
BILL_AMT3	Tagihan bulan Jul 2005	NT Dollar	Bisa negatif
BILL_AMT4	Tagihan bulan Jun 2005	NT Dollar	Bisa negatif
BILL_AMT5	Tagihan bulan Mei 2005	NT Dollar	Bisa negatif
BILL_AMT6	Tagihan bulan Apr 2005	NT Dollar	Bisa negatif
PAY_AMT1	Pembayaran bulan Sep 2005	NT Dollar	≥ 0
PAY_AMT2	Pembayaran bulan Agu 2005	NT Dollar	≥ 0
PAY_AMT3	Pembayaran bulan Jul 2005	NT Dollar	≥ 0
PAY_AMT4	Pembayaran bulan Jun 2005	NT Dollar	≥ 0
PAY_AMT5	Pembayaran bulan Mei 2005	NT Dollar	≥ 0
PAY_AMT6	Pembayaran bulan Apr 2005	NT Dollar	≥ 0
Default payment next month	Gagal bayar bulan depan	1=Ya, 0=Tidak	0-1

Sumber: Hasil Penelitian (2025)

Setelah dataset ditentukan, kemudian dilakukan tahap mulai dari pemuatan dataset dan preprocessing yang mencakup penghapusan fitur ID, encoding variabel kategori seperti jenis kelamin, pendidikan, dan status pernikahan, serta standarisasi fitur numerik agar skala data seragam. Kemudian setelah itu, data dibagi menjadi 2 bagian : data latih dan data uji dengan perbandingan 80:20, lalu model dibangun menggunakan algoritma XGBoost [25]. Hasilnya kemudian dievaluasi menggunakan metrik seperti akurasi, presisi, recall, dan F1-score, kemudian model diekspor dalam format .pkl agar dapat dimanfaatkan lebih lanjut untuk pengembangan sistem prediktif secara berkelanjutan [26]. Hasil model yang digunakan menunjukkan hasil yang menjanjikan, dengan akurasi sebesar 79,13% dan presisi 52,99%, yang mengindikasikan kestabilan performa dalam memproses data historis. Nilai recall yang diperoleh sebesar 50,11% membuka peluang untuk penyempurnaan lebih lanjut dalam meningkatkan sensitivitas terhadap karakteristik nasabah tertentu.

Tabel 2. Hasil Pengolahan Machine Learning

Metrik	Nilai
True Negative	4.083
False Positive	590
False Negative	662
True Positive	665
Accuracy	0,7913
Precision	0,5299
Recall	0,5011
F1-Score	0,5151

Sumber: Hasil Penelitian (2025)

Pembuatan Application Programming Interface (API)

Setelah model dibuat, kemudian dibuat API Untuk menghubungkan model machine learning dengan antarmuka pengguna berbasis website menggunakan Application Programming Interface (API). API yang dibuat menggunakan bahasa pemrograman python dengan framework, mengingat flask sederhana dalam pembuatan serta kemampuannya dalam menangani komunikasi data secara real-time antara server dan klien. Ada 3 tahap yang dibangun dalam flask: 1). Koneksi ke model machine learning, Proses pemodelan machine learning menghasilkan output berupa file dengan ekstensi.pkl (Python pickle), yang berisikan sebagai basis pengetahuan. File ini dapat digunakan oleh API berbasis Flask untuk menerima input dari pengguna dan memberikan keluaran berupa prediksi risiko kredit berdasarkan model yang telah dilatih [27]. 2). Pemformatan endpoint, Endpoint yang berfungsi sebagai jalur komunikasi antara antarmuka aplikasi web dan data prediksi yang sudah dilatih oleh machine learning. Untuk mengaksesnya dirancang pada URL /predict dengan metode POST. Data yang diterima oleh sistem dalam bentuk JSON dan saat menerima data nasabah, sistem akan mengonversi informasi tersebut menjadi format yang sesuai dengan struktur input model prediktif. Selanjutnya, model yang telah dilatih akan dipanggil untuk dilakukan analisa terhadap data tersebut dan menghasilkan output berupa prediksi risiko kredit. Hasil prediksi ini kemudian dibuat ulang dalam format JSON dan dikembalikan ke aplikasi web sebagai respon [28].

Tabel 3. Endpoint

Atribut	Deskripsi
URL	/predict
Metode HTTP	POST
Deskripsi	Endpoint ini menghubungkan antarmuka web dengan model prediktif yang telah dilatih. Data nasabah dikirim dalam format JSON, diolah menjadi input model, dan hasil prediksi risiko dikembalikan dalam bentuk JSON.

Sumber: Hasil Penelitian (2025)

Struktur request API

Struktur request API dirancang untuk menerima data peminjam yang dikirimkan dari aplikasi web ke model machine learning dalam format JSON dan menggunakan metode POST yang menuju endpoint /predict [29]. Format JSON dipilih karena sangat direkomendasikan sebagai format respons REST API, memungkinkan pertukaran data yang efisien dan fleksibel antara client dan server [30]. Setiap field dalam struktur request mewakili variabel yang akan digunakan oleh model untuk memprediksi kemungkinan gagal bayar pinjaman.

Table 4. Struktur Request

Field	Tipe Data
LIMIT_BAL	Float
SEX	Integer
EDUCATION	Integer
MARRIAGE	Integer
AGE	Integer
PAY_0	Integer
PAY_2	Integer
PAY_3	Integer
PAY_4	Integer
PAY_5	Integer
PAY_6	Integer
BILL_AMT1	Float
BILL_AMT2	Float
BILL_AMT3	Float
BILL_AMT4	Float
BILL_AMT5	Float
BILL_AMT6	Float
PAY_AMT1	Float
PAY_AMT2	Float
PAY_AMT3	Float
PAY_AMT4	Float
PAY_AMT5	Float
PAY_AMT6	Float

Sumber: Hasil Penelitian (2025)

Pembuatan Website

Pembuatan website prediksi gagal bayar nasabah kartu kredit dirancang dan dibangun sebagai antarmuka utama yang berguna untuk berinteraksi dengan sistem prediksi risiko kredit berbasis teknologi machine learning [31]. Dengan mempertimbangkan aspek kemudahan penggunaan dan tampilan yang informatif dan mudah digunakan, tampilan website ini terbagi menjadi tiga bagian utama, yaitu halaman awal, halaman form, dan halaman hasil prediksi.

Halaman awal

Halaman ini berfungsi sebagai tampilan pembuka dari website. Di bagian ini, pengguna akan mendapatkan pengantar singkat sebelum masuk ke bagian utama dari website. Desain halaman dibuat sederhana namun tetap mencerminkan kesan profesional agar menciptakan pengalaman awal yang baik bagi pengguna [32].



Sumber: Hasil Penelitian (2025)

Gambar 2. Halaman Awal

Halaman form

Pada halaman ini, pengguna akan diminta untuk mengisi data nasabah yang diperlukan untuk melakukan prediksi risiko kredit. Formulir ini mencakup berbagai informasi yang dibutuhkan sesuai dengan struktur data API, seperti batas kredit (LIMIT_BAL), jenis kelamin (SEX), tingkat pendidikan (EDUCATION), status pernikahan (MARRIAGE), usia (AGE) serta data pendukung lainnya yang sesuai dengan format yang diterima oleh API. Untuk mencegah kesalahan input, disediakan fitur validasi otomatis agar memastikan data yang dimasukkan sesuai dengan ketentuan sistem. Setelah seluruh data diisi, pengguna dapat mengirimkan informasi tersebut ke sistem melalui tombol "Prediksi", dan data tersebut akan diproses oleh model machine learning.

Formulir Prediksi

LIMIT_BAL	SEX
Contoh: 200000 (tanpa titik/koma)	Pilih Jenis Kelamin
EDUCATION	MARRIAGE
Pilih Pendidikan	Pilih Status Perkawinan
AGE	
Contoh: 35	

Histori Pembayaran (PAY_*)
-1: Terlambat > 3 bulan, -2: Terlambat 2-3 bulan, -3: Terlambat 1-2 bulan, 0: Tidak terlambat

PAY_0	
Pilih Status Pembayaran	
PAY_2	PAY_3
Pilih Status Pembayaran	Pilih Status Pembayaran
PAY_4	PAY_5
Pilih Status Pembayaran	Pilih Status Pembayaran
PAY_6	
Pilih Status Pembayaran	

Tagihan Bulanan (BILL_AMT*)
Masukkan jumlah tagihan Anda setiap bulan dalam satuan rupiah, tanpa titik/koma. Contoh: 1500000


BILL_AMT1	BILL_AMT2
Contoh: 1500000	Contoh: 1500000
BILL_AMT3	BILL_AMT4
Contoh: 1500000	Contoh: 1500000
BILL_AMT5	BILL_AMT6
Contoh: 1500000	Contoh: 1500000

Sumber: Hasil Penelitian (2025)

Gambar 3. Halaman Form

Halaman hasil

Bagian pada halaman ini menampilkan output berupa prediksi hasil yang dihasilkan oleh model berdasarkan data yang telah dikirimkan dari halaman form. Pengguna dapat langsung melihat hasil prediksi yang dikelompokkan ke dalam dua kategori utama: "Tidak beresiko" dan "Beresiko". Hasil ditampilkan secara jelas agar memudahkan pengguna dalam memahami tingkat risiko yang dimaksud.



Sumber: Hasil Penelitian (2025)

Gambar 4. Halaman Hasil

4. Kesimpulan

Penelitian ini menunjukkan bahwa pengembangan sistem prediksi risiko gagal bayar nasabah kartu kredit berbasis algoritma XGBoost yang terintegrasi dalam platform web mampu memberikan hasil yang cukup menjanjikan, dengan menggunakan hasil evaluasi akurasi sebesar 79,13%, presisi 52,99%, dan recall 50,11%. Nilai recall ini mengindikasikan bahwa model memiliki kemampuan deteksi terhadap nasabah berisiko yang relatif seimbang, meskipun masih terbuka peluang untuk peningkatan sensitivitas. Integrasi model ke dalam sistem web melalui API Flask memungkinkan prediksi dilakukan secara real-time dan interaktif, sehingga mendukung proses pengambilan keputusan secara lebih efektif. Meskipun demikian, sistem ini masih memiliki keterbatasan dalam menangani distribusi kelas minoritas dan penyajian hasil prediksi yang lebih informatif. Oleh karena itu, pengembangan selanjutnya dapat difokuskan pada optimalisasi model dengan teknik balancing data, pengujian algoritma pembandingan, serta penerapan pendekatan Explainable AI (XAI) untuk memperluas manfaatnya dalam konteks industri keuangan digital.

Daftar Pustaka

- [1] W. Wulansari and D. Purwitasari, "Algoritma Random Forest Pada Prediksi Status Kredit Usaha Rakyat Untuk Mengurangi Nonperforming Loan Rate," *J. Intell. Syst. Comput.*, Vol. 5, No. 2, Pp. 109–114, 2023, Doi: 10.52985/Insyst.V5i2.358.
- [2] D. T. Wijaya, "The Rise Of Innovative Credit Scoring System In Indonesia.," *Cent. Indones. Policy Stud.*, No. 57, 2023.
- [3] M. R. Givari, M. R. Sulaeman, and Y. Umaidah, "Perbandingan Algoritma Svm, Random Forest Dan Xgboost Untuk Penentuan Persetujuan Pengajuan Kredit," *Nuansa Inform.*, Vol. 16, No. 1, Pp. 141–149, 2022, Doi: 10.25134/Nuansa.V16i1.5406.
- [4] A. N. Rais and Warjiyono, "Sistem Informasi Prediksi Risiko Kredit Keuangan Berbasis Web Machine Learning," *Justika J. Sist. Inf. Akunt.*, Vol. 02, 2024.
- [5] J. Gao, W. Sun, and X. Sui, "Research On Default Prediction For Credit Card Users Based On Xgboost-Lstm Model," *Discret. Dyn. Nat. Soc.*, Vol. 2021, 2021, Doi: 10.1155/2021/5080472.
- [6] 2020 Kahrudin Et Al., "Corresponding Author : Pr Ep T N Ot Pe Er Re V Pr Ep Rin T N Ot Pe Er V Ed," *Preprint*, Vol. 11, No. Cicc, Pp. 76–84, 2020.
- [7] A. N. Rais Et Al., "Optimasi Prediksi Risiko Kredit Dengan Preprocessing Dan," Vol. 9, No. 1, Pp. 59–65, 2025.
- [8] Y. U. Rofi'i, "Financial Risk Management In Indonesian Banking: The Integrative Role Of Data Analytics And Predictive Algorithms," *Int. J. Softw. Eng. Comput. Sci.*, Vol. 3, No. 3, Pp. 300–309, 2023, Doi: 10.35870/ijsecs.V3i3.1823.
- [9] A. Alagic Et Al., "Machine Learning For An Enhanced Credit Risk Analysis: A Comparative Study Of Loan Approval Prediction Models Integrating Mental Health Data," *Mach. Learn.*

- Knowl. Extr.*, Vol. 6, No. 1, Pp. 53–77, 2024, Doi: 10.3390/Make6010004.
- [10] M. Zhu, Y. Zhang, Y. Gong, K. Xing, X. Yan, And J. Song, "Ensemble Methodology: Innovations In Credit Default Prediction Using Lightgbm, Xgboost, And Localensemble," In *2024 IEEE 4th International Conference On Electronic Technology, Communication And Information (Icetci)*, May 2024, Pp. 421–426. Doi: 10.1109/Icetci61221.2024.10594630.
- [11] D. Cahya Putri Buani And N. Nuraeni, "Application Of Xgb Classifier For Obesity Rate Prediction," *J. Ris. Inform.*, Vol. 6, No. 1, Pp. 1–6, 2023, Doi: 10.34288/Jri.V6i1.260.
- [12] F. Voron, *Building Data Science Applications With Fastapi: Develop, Manage, And Deploy Efficient Machine Learning Applications With Python*. Packt Publishing, 2023. [Online]. Available: <https://books.google.co.id/books?id=Ncxmeaaaqbaj>
- [13] N. Purwati, W. Harieska, And E. Safitri, "80135-75676736901-1-Pb," Vol. 12, No. 3, Pp. 578–583, 2024, Doi: 10.26418/Justin.V12i3.80135.
- [14] A. Nurdin, R. Amelia Zunaidi, M. Arkan Fauzan Wicaksono, And A. Lobita Japtara Martadinata, "Analisis Kredit Pembayaran Biaya Kuliah Dengan Pendekatan Pembelajaran Mesin," *J. Teknol. Inf. Dan Ilmu Komput.*, Vol. 10, No. 2, Pp. 271–280, 2023, Doi: 10.25126/Jtiik.20231026301.
- [15] B. A. Maulana And N. Hidayati, "Churn Prediction In Credit Customers Using Random Forest And Xgboost Methods," Vol. 6, No. 1, Pp. 81–89, 2025.
- [16] C. Guan, H. Suryanto, A. Mahidadia, M. Bain, And P. Compton, "Responsible Credit Risk Assessment With Machine Learning And Knowledge Acquisition," *Human-Centric Intell. Syst.*, Vol. 3, No. 3, Pp. 232–243, 2023, Doi: 10.1007/S44230-023-00035-1.
- [17] C. Rao, Y. Liu, And M. Goh, "Credit Risk Assessment Mechanism Of Personal Auto Loan Based On Pso-Xgboost Model," *Complex Intell. Syst.*, Vol. 9, No. 2, Pp. 1391–1414, 2023, Doi: 10.1007/S40747-022-00854-Y.
- [18] M. R. Suhendry, G. Firmansyah, N. S. Fatonah, And A. M. Widodo, "Loan Repayment Prediction Using Xgboost And Neural Network In Japan ' S Technical Internship Training," Vol. 9, No. 2, Pp. 822–831, 2025.
- [19] X. He, S. Li, X. T. He, W. Wang, X. Zhang, And B. Wang, "A Novel Ensemble Learning Model Combined Xgboost With Deep Neural Network For Credit Scoring," *J. Inf. Technol. Res.*, Vol. 15, No. 1, Pp. 1–18, 2022, Doi: 10.4018/Jitr.299924.
- [20] A. Arram, M. Ayob, M. A. A. Albadr, A. Sulaiman, And D. Albashish, "Credit Card Score Prediction Using Machine Learning Models: A New Dataset," 2023, [Online]. Available: <http://arxiv.org/abs/2310.02956>
- [21] Imasita And Hirman, "Aplikasi Pengelolaan Disposisi Surat Berbasis Web Pada Dinas Pekerjaan Umum Kota Makassar," *J. Instek (Informatika Sains Dan Teknol.)*, Vol. 7, No. 1, Pp. 106–114, 2022, Doi: 10.24252/Instek.V7i1.28828.
- [22] H. L. Walingkas And P. O. N. Saian, "Penerapan Framework Flask Pada Pembangunan Sistem Informasi Pemasok Barang," *J. Jtik (Jurnal Teknol. Inf. Dan Komunikasi)*, Vol. 7, No. 2, Pp. 227–234, 2023, Doi: 10.35870/Jtik.V7i2.729.
- [23] S. L. Mufreni, A. Mushawwir, P. Studi, T. Informasi, U. Aisyiyah, And S. Management, "Development Of Web - App Using Agile Scrum Method At Pt . Stechoq Robotika Indonesia," Vol. 14, Pp. 917–931, 2025.
- [24] N. Purwati, G. B. Sulistyo, S. Kiswati, N. Hasan, U. Bina, And S. Informatika, "Implementation Of Website Reservation System And Online Promotion For Business Development At Sejati Catering," Vol. 10, No. 3, Pp. 749–756, 2025.
- [25] Jan Melvin Ayu Soraya Dachi And 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, Pp. 87–103, 2023, Doi: 10.55606/Jurrimipa.V2i2.1470.
- [26] A. A. Saputra, B. N. Sari, C. Rozikin, U. Singaperbangsa, And K. Abstrak, "Penerapan Algoritma Extreme Gradient Boosting (Xgboost) Untuk Analisis Risiko Kredit," *J. Ilm. Wahana Pendidik.*, Vol. 10, No. 7, Pp. 27–36, 2024, [Online]. Available: <https://doi.org/10.5281/Zenodo.10960080>
- [27] M. R. Rao, V. Seshubabu, M. Shankar, N. Rakesh, And M. P. Kumar, "Identification And Analysis Of Numerous Diseases Using Supervised Machine Learning," *Int. J. Eng. Res. Sci. Technol.*, Vol. 20, No. 2, 2024.
- [28] M. Firdaus And R. Afwani, "Pengembangan Restful Api Untuk Aplikasi Klasifikasi Jenis Tanah Berbasis Mobile Pada Google Cloud (Restful Api Development For Mobile-Based

- Soil Type,” *J. Teknol. Informasi, Komput. Dan Apl. (Jtika)* Vol. 6, No. 1, Maret 2024, (Terakreditasi Sinta-4, Sk No164/E/Kpt/2021) Issn2657-0327 <http://Jtika.lf.Unram.Ac.Id/Index.Php/Jtika/275>, Vol. 6, No. 1, Pp. 275–287, 2024.
- [29] K. Azkiya, M. Irsan, And M. F. Fathoni, “Implementation Of App Engine And Cloud Storage As Rest Api On Smart Farm Application,” *Sinkron*, Vol. 8, No. 2, Pp. 902–910, 2024, Doi: 10.33395/Sinkron.V8i2.13386.
- [30] Bayu Hermawan, Giri Wahyu Wiriasto, And Lalu A. Syamsul Irfan Akbar, “Aksyaa- Android Application Accounting Information System,” *J. Comput. Sci. Informatics Eng.*, Vol. 7, No. 1, Pp. 68–75, 2023, Doi: 10.29303/Jcosine.V7i1.508.
- [31] A. Rahmawati And I. Yulianti, “Optimalisasi Sistem Pembayaran Administrasi Kesiswaan Berbasis Website,” *Justika J. Sist. Inf. Akunt.*, Vol. 1, No. 2, Pp. 65–72, 2021, Doi: 10.31294/Justika.V1i2.940.
- [32] J. Penerapan, T. Informasi, W. Andriani, G. Gunawan, N. Nabila, And P. Wahyuning, “It-Explore Analisis Perbandingan Machine Learning Untuk Prediksi Kelayakan Kredit Perbankan Pada Bank Bri Tegal,” Vol. 04, No. 27, Pp. 82–92, 2025, Doi: 10.24246/Itexplore.V4i1.2025.Pp82-92.