

Prediksi *Credit Card Approval* Menggunakan Algoritma *Random Forest*

Anindita Puspa Ayu Prayogi¹, Altha Inas Shofyana², Dewi Putriani³

^{1,2,3} Sistem Informasi, Universitas Nusantara PGRI Kediri
Kediri, Indonesia

aninditapuspa3@gmail.com¹, althainas02@gmail.com², dewiptr098@gmail.com³

Abstract. *The credit card approval process is a significant challenge for financial institutions because it involves analyzing various factors, such as income, credit history, and financial commitment of prospective customers. This research aims to build a credit card approval prediction model using the Random Forest algorithm by utilizing public datasets from Kaggle. The Random Forest algorithm was chosen because of its advantages in handling large data, overcoming the problem of unbalanced data, and preventing overfitting to produce accurate predictions. The results show that the model has high performance with an accuracy of 88.89%, as well as an average accuracy of 85.50% based on cross-validation. In addition, the precision, recall, and F1-score metrics show balanced performance for both target classes. This model has the potential to be implemented on an industrial scale by considering challenges such as data privacy and scalability.*

Keywords: *Credit Card, Random Forest, Machine Learning.*

Abstrak. Proses persetujuan kartu kredit merupakan tantangan signifikan bagi institusi keuangan karena melibatkan analisis berbagai faktor, seperti pendapatan, riwayat kredit, dan komitmen finansial calon nasabah. Penelitian ini bertujuan membangun model prediksi persetujuan kartu kredit menggunakan algoritma *Random Forest* dengan memanfaatkan dataset publik dari Kaggle. Algoritma *Random Forest* dipilih karena keunggulannya dalam menangani data besar, mengatasi masalah data tidak seimbang, serta mencegah *overfitting* untuk menghasilkan prediksi yang akurat. Hasil penelitian menunjukkan bahwa model memiliki performa tinggi dengan akurasi sebesar 88,89%, serta akurasi rata-rata 85,50% berdasarkan *cross-validation*. Selain itu, metrik *precision*, *recall*, dan *F1-score* menunjukkan keseimbangan performa untuk kedua kelas target. Model ini berpotensi diimplementasikan dalam skala industri dengan mempertimbangkan tantangan seperti privasi data dan skalabilitas.

Kata Kunci: Kartu Kredit, *Random Forest*, *Machine Learning*.

I. PENDAHULUAN

Kartu kredit telah menjadi alat transaksi yang sangat penting dalam dunia modern karena memberikan kemudahan dalam melakukan pembayaran dan pengelolaan keuangan [1]. Namun, proses persetujuan aplikasi kartu kredit bukanlah hal yang sederhana. Institusi keuangan harus mempertimbangkan berbagai faktor seperti pendapatan, status pekerjaan, riwayat kredit, hingga komitmen finansial calon nasabah untuk meminimalkan risiko gagal bayar [2]. Proses ini menjadi semakin kompleks dengan banyaknya data yang harus dianalisis, sehingga keputusan manual sering kali memakan

waktu dan rentan terhadap kesalahan dalam pengambilan keputusan. Selain itu, bagi lembaga keuangan, persetujuan kredit tetap menjadi tantangan besar karena sulit untuk memprediksi calon nasabah mana yang memiliki risiko kredit yang dapat diterima dan layak diberikan kredit [3][4].

Kartu kredit pada industri pembiayaan konsumen memiliki risiko kredit yang merupakan potensi kerugian yang muncul akibat kegagalan debitur dalam memenuhi kewajibannya untuk membayar utang. Hal tersebut menjadi perhatian utama bagi institusi keuangan, karena kegagalan dalam mengelola risiko dapat berdampak signifikan pada stabilitas keuangan perusahaan [5]. Dengan demikian, penerapan teknologi seperti data *mining* dan algoritma prediksi menjadi sangat penting untuk membantu lembaga keuangan dalam memitigasi risiko tersebut dan meningkatkan efisiensi proses pengambilan keputusan.

Teknologi data *mining* telah berkembang pesat dalam era *big data* dan transformasi digital, menjadi alat penting untuk mengolah dan menganalisis data dalam skala besar. Salah satu pendekatan utama dalam data *mining* adalah penggunaan *machine learning*, yang memungkinkan identifikasi pola-pola kompleks di dalam dataset besar untuk menghasilkan prediksi yang lebih akurat [6]. Dalam praktiknya, *machine learning* menjadi komponen penting dalam data *mining*, karena metode ini dirancang untuk mengolah basis data besar secara terstruktur, sehingga memungkinkan analisis yang sebelumnya sulit dilakukan secara manual [7].

Sebelumnya telah dilakukan penelitian yang menunjukkan keberhasilan dengan menggunakan *machine learning* dalam memecahkan masalah klasifikasi data *Credit Card Approval*. Penelitian tersebut berjudul “Implementasi Algoritma *Random Forest* pada Klasifikasi Dataset *Credit Card Approval*” oleh Nur Widjiyati tahun 2021 membahas mengenai perbandingan beberapa algoritma yaitu K-NN, C4.5, SVM, NN, *Naive Bayes*, serta *Random Forest* dalam memprediksi persetujuan kartu kredit nasabah bank. Hasil dari perbandingan menunjukkan algoritma *Random Forest* mampu menghasilkan kinerja akurasi yang lebih baik dibandingkan algoritma yang lain yaitu 87.3% dengan *True Positive Rate* (TPR) sebesar 86% dan *True Negative Rate* (TNR) sebesar 89% [8]. Terdapat juga penelitian lain yang menggunakan

dataset sama yaitu penelitian oleh Andre Alvi Agustian berjudul “*Data Mining Optimization Using Sample Bootstrapping and Particle Swarm Optimization in the Credit Approval Classification*”. Penelitian tersebut menggunakan algoritma *C4.5* dan *Naive Bayes* yang menghasilkan akurasi sebesar 85.99% untuk model *C4.5* dan 83.09% untuk model *Naive Bayes* [2].

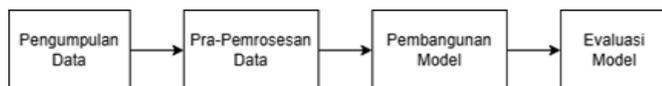
Melanjutkan dari penelitian terdahulu, algoritma *Random Forest* dipilih sebagai model dalam penelitian ini karena mampu mengenali pola dalam data besar dan menghasilkan prediksi yang lebih akurat dan cepat dibandingkan metode tradisional. *Random Forest* bekerja berdasarkan pohon keputusan dengan memilih subset secara acak untuk menyeleksi fitur terbaik. Algoritma ini termasuk salah satu yang unggul dalam klasifikasi data keuangan, serta terkenal dengan stabilitas, akurasi, kemampuannya menangani masalah data tidak seimbang dan mencegah *overfitting* [9].

Penelitian ini bertujuan untuk membangun model prediksi persetujuan kartu kredit menggunakan algoritma *Random Forest*. Dengan menggunakan dataset publik dari Kaggle, penelitian ini berfokus pada analisis performa model berdasarkan matrik evaluasi seperti akurasi, presisi, *recall*, *F1-score*. Model yang dihasilkan diharapkan dapat memberikan wawasan mengenai analisis data keuangan dengan menggunakan algoritma *Random Forest*, serta dapat menjadi referensi untuk pengembangan model prediksi yang akurat dan efisien dalam pengambilan keputusan khususnya pada masalah persetujuan kartu kredit.

Dalam penelitian ini, teknik yang digunakan adalah klasifikasi, yaitu pendekatan yang berfungsi untuk mengelompokkan data calon nasabah ke dalam dua kategori utama, yaitu *approved* (disetujui) dan *not approved* (tidak disetujui). Klasifikasi merupakan proses untuk menemukan sebuah model atau pola yang mampu menggambarkan serta membedakan kelas pada suatu dataset [10]. Tujuannya adalah agar model tersebut dapat digunakan untuk memprediksi objek dengan label kelas yang belum diketahui, berdasarkan analisis data latih [8]. Model yang dihasilkan dari klasifikasi ini juga dapat dimanfaatkan untuk memprediksi tren data di masa depan, sehingga memberikan nilai tambah dalam pengambilan keputusan berbasis data [8].

II. METODE PENELITIAN

Pada penelitian ini akan diproses berdasarkan tahapan berikut yang ditunjukkan pada gambar 1.



Gambar 1. Metode Penelitian

Selanjutnya adalah penjelasan tiap tahapan dari metode penelitian yaitu sebagai berikut.

A. Pengumpulan Data

Pada penelitian ini dataset yang digunakan berasal dari Kaggle, yaitu platform yang menyediakan dataset publik untuk berbagai keperluan analisis data. Dataset yang digunakan adalah *Credit Card Approval* yang berasal dari laman <https://www.kaggle.com/datasets/samueltcortinhas/credit-card-approval-clean-data>. Dataset tersebut dipilih karena bersifat publik dan mudah diakses. Selain itu, dataset ini memiliki struktur data lengkap dan beberapa atribut yang mencerminkan proses evaluasi persetujuan kartu kredit di dunia nyata.

B. Pra-Pemrosesan Data

Tahap pra-pemrosesan data dimulai dengan melakukan pengecekan terhadap nilai kosong (*missing values*) untuk memastikan kualitas data yang digunakan. Setelah dilakukan pengecekan, tidak ditemukan adanya *missing values* pada dataset, sehingga data dapat langsung digunakan tanpa perlu penanganan tambahan. Selanjutnya, atribut kategorikal seperti industri pekerjaan, etnis, dan status kewarganegaraan yang berbentuk data non-numerik diubah menjadi format numerik menggunakan teknik *one-hot encoding*. Proses ini dilakukan untuk memastikan bahwa data dapat diolah oleh algoritma *Random Forest*, yang membutuhkan semua input dalam format numerik agar dapat berfungsi dengan optimal. Pra-pemrosesan ini menjadi langkah penting untuk meningkatkan kompatibilitas dan kualitas data sebelum membangun model prediksi.

C. Pembangunan Model

Pembangunan model dimulai dengan membagi dataset menjadi data latih (*training data*) dan data uji (*testing data*) menggunakan rasio 70:30, di mana 70% data digunakan untuk melatih model, dan sisanya 30% digunakan untuk menguji performa model. Algoritma *Random Forest* diterapkan untuk membangun model prediksi, dengan proses *parameter tuning* dilakukan untuk mengoptimalkan performa model. Parameter yang disesuaikan mencakup jumlah pohon dalam hutan (*n_estimators*), kedalaman maksimum pohon (*max_depth*), dan jumlah fitur yang dipertimbangkan untuk pemisahan di setiap simpul (*max_features*). Penyesuaian parameter ini bertujuan untuk menemukan kombinasi terbaik yang dapat meningkatkan akurasi prediksi sekaligus mencegah risiko *overfitting*. Model yang telah dibangun kemudian dievaluasi pada data uji untuk menilai kemampuannya dalam memprediksi persetujuan aplikasi kartu kredit secara akurat.

D. Evaluasi Model

Evaluasi model dilakukan dengan menggunakan berbagai metrik untuk memastikan kinerja yang optimal dalam memprediksi persetujuan aplikasi kartu kredit. Metrik yang digunakan meliputi akurasi, presisi, *recall*, dan *F1-score*. Akurasi digunakan untuk mengukur proporsi prediksi yang benar dari total keseluruhan prediksi, sementara presisi dan *recall* mengukur ketepatan dan sensitivitas model dalam mengklasifikasikan aplikasi yang disetujui dan ditolak. *F1-*

score, yang merupakan harmoni antara presisi dan *recall*, juga dihitung untuk memberikan gambaran performa model secara keseluruhan. Selain itu, untuk memastikan kestabilan hasil dan mengurangi risiko *overfitting*, penerapan *cross-validation* dilakukan dengan membagi data menjadi beberapa bagian dan melakukan pelatihan serta pengujian model pada masing-masing subset data. Proses *cross-validation* ini membantu memberikan evaluasi yang lebih reliabel terhadap performa model, memastikan bahwa model tidak hanya berfungsi baik pada data latih, tetapi juga dapat digeneralisasi dengan baik pada data yang belum pernah dilihat sebelumnya.

III. HASIL DAN PEMBAHASAN

A. Deskripsi Data

Dataset yang digunakan dalam penelitian ini memiliki 690 baris data yang merepresentasikan aplikasi kartu kredit, dengan setiap baris berisi informasi calon nasabah. Terdapat 15 atribut yang mencakup beberapa aspek yaitu antara lain digambarkan dalam tabel 1.

Tabel 1. Deskripsi Data

Atribut	Tipe Data	Keterangan
Gender	Integer	Jenis kelamin
Age	Integer	Usia
Debt	Integer	Jumlah hutang
Married	Binomial	Status pernikahan
Bank Customer	Binomial	Kepemilikan akun bank
Indusrtly	Polynomial	Kategori Pekerjaan
Ethnicity	Polynomial	Etnis
YearsEmployed	Integer	Lama bekerja
PriorDefault	Binomial	Status karyawan
CreditScore	Integer	Riwayat kredit
DriversLicense	Binomial	Lisensi mengemudi
Citizen	Polynomial	Kewarganegaraan
ZipCode	Integer	Kode ZIP
Income	Integer	Penghasilan
Approved	Binomial	Status pengajuan (Label)

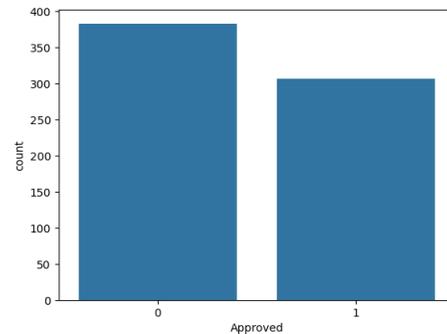
B. Pembahasan

Data yang digunakan dalam penelitian ini merupakan data publik yang diunduh dari platform *Kaggle*. Setelah data berhasil diunduh, langkah pertama adalah memuat dataset ke dalam lingkungan pemrograman menggunakan *Python*. Pemeriksaan struktur dataset dilakukan dengan menggunakan perintah *df.info()* untuk memastikan data telah dimuat dengan benar dan tidak terdapat nilai kosong. Dataset terdiri dari 10 kolom, termasuk kolom target, tanpa adanya nilai yang hilang.

Pada tahap pra-pemrosesan data, dilakukan beberapa langkah penting untuk memastikan data siap digunakan dalam proses pelatihan model.

Pemeriksaan nilai hilang (*missing value*) dilakukan menggunakan perintah *print(df.isnull().sum())* pada *Python* untuk menghitung jumlah nilai kosong di setiap kolom dataset. Hasil pemeriksaan menunjukkan bahwa tidak terdapat nilai kosong (*missing value*) atau nilai *null* pada dataset ini, sehingga data siap untuk tahap pemrosesan lebih lanjut tanpa memerlukan langkah imputasi atau penanganan khusus lainnya.

Distribusi kelas target menunjukkan bahwa kelas "*Approved*" memiliki jumlah yang hampir seimbang dengan kelas "*Not Approved*", masing-masing sebesar 52% dan 48%. Meskipun terdapat sedikit perbedaan dalam jumlah antara kelas "*Approved*" dan "*Not Approved*", distribusi ini dapat dianggap cukup seimbang. Hal ini karena *Random Forest* sebagai algoritma *ensemble* memiliki kemampuan untuk menangani ketidakseimbangan kelas secara efektif. Gambar 2 adalah visualisasi distribusi kelas target.



Gambar 2. Distribusi Kelas Target

Tahap *encoding* dilakukan untuk mengubah tiga fitur kategorikal, yaitu *industry*, *ethnicity*, dan *citizen*, menjadi bentuk numerik agar dapat diolah oleh algoritma. Proses *encoding* menggunakan metode *OneHotEncoder* dari pustaka *sklearn.preprocessing*. Dengan metode ini, setiap kategori dalam fitur tersebut diubah menjadi representasi numerik berbasis vektor biner, sehingga informasi tetap terjaga tanpa memberikan bobot berlebihan pada kategori tertentu. Langkah ini memastikan bahwa data kategorikal dapat digunakan secara efektif dalam pelatihan model.

Pada proses pembangunan model terdapat beberapa langkah yaitu antara lain, *Split* data dilakukan dengan menggunakan $X=df.drop('Approved',axis)$ dan $y=df['Approved']$, yang berarti X adalah fitur dan y adalah target. Setelah itu, data dibagi menjadi dua set, yaitu data latih (*train*) dan data uji (*test*), dengan proporsi 70% untuk data latih dan 30% untuk data uji menggunakan parameter *test_size=0.3*. Pembagian ini bertujuan untuk melatih model menggunakan data latih dan menguji performa model pada data yang belum pernah dilihat sebelumnya.

Pada tahap pembangunan model, algoritma *Random Forest* digunakan untuk melakukan klasifikasi dengan mengkonfigurasi beberapa parameter penting. Model diinisialisasi dengan 100 pohon keputusan (*n_estimators=100*) dan pembatasan kedalaman pohon hingga

10 (*max_depth=10*) untuk menghindari *overfitting*. Setiap pohon dipastikan memiliki minimal 4 sampel pada daun (*min_samples_leaf=4*) dan 10 sampel untuk pemisahan (*min_samples_split=10*) agar pembagian data signifikan. Selain itu, hanya akar kuadrat dari jumlah total fitur yang dipertimbangkan dalam setiap pemisahan pohon (*max_features='sqrt'*) untuk meningkatkan keberagaman antar pohon. Parameter *random_state=42* digunakan untuk memastikan hasil yang konsisten pada setiap eksperimen. Setelah konfigurasi ini, model dilatih dengan data latih menggunakan metode *fit()*, sehingga model dapat mempelajari pola dari data dan siap untuk evaluasi lebih lanjut.

Setelah model *Random Forest* dilatih, langkah selanjutnya adalah melakukan prediksi pada data uji (*X_test*) dengan menggunakan metode *predict()*. Hasil prediksi (*y_pred*) kemudian dibandingkan dengan nilai target sebenarnya (*y_test*) untuk mengevaluasi kinerja model. Dengan menggunakan *accuracy_score()* dari pustaka *scikit-learn*, diperoleh akurasi model sebesar 88.89%, yang menunjukkan bahwa model berhasil memprediksi dengan tepat sekitar 89% dari data uji. Akurasi ini menunjukkan performa yang baik dan memberikan gambaran bahwa model cukup efektif dalam melakukan klasifikasi berdasarkan data yang tersedia.

Evaluasi pertama menggunakan *Confusion Matrix*, yang memberikan gambaran tentang jumlah prediksi yang benar dan salah pada model. Berikut tabel 2 berisi mengenai hasil *confusion matrix*.

Tabel 2. *Confusion Matrix*

Prediksi/Aktual	Not Approved (0)	Approved (1)
Not Approved (0)	107	8
Approved (1)	15	77

Berdasarkan tabel 2 hasil *confusion matrix* menunjukkan bahwa model berhasil mengklasifikasikan sebagian besar data dengan benar. Untuk kelas "0" (*Not Approved*), model memprediksi dengan benar sebanyak 107 sampel, sementara hanya 8 sampel yang salah terklasifikasi sebagai kelas "1". Begitu juga untuk kelas "1" (*Approved*), model memprediksi 77 sampel dengan benar dan 15 sampel salah terklasifikasi sebagai kelas "0". Hasil ini menunjukkan bahwa model memiliki performa yang cukup baik dalam membedakan antara kedua kelas target.

Tahapan ini memberikan metrik tambahan seperti *precision*, *recall*, *f1-score* untuk masing masing kelas. Gambar 3 akan menampilkan output dari tahapan ini. Berdasarkan gambar 3 hasil dari *classification report* menunjukkan bahwa untuk kelas "0" (*Not Approved*), model memiliki *precision* sebesar 0.88, *recall* sebesar 0.93, dan *f1-score* 0.90, yang menandakan model dapat dengan baik mengenali kelas ini dan memiliki keseimbangan yang baik antara *precision* dan *recall*. Untuk kelas "1" (*Approved*), *precision* mencapai 0.91, *recall* 0.84, dan *f1-score* 0.87, yang menunjukkan bahwa model juga cukup efektif dalam mengklasifikasikan kelas ini meskipun ada sedikit penurunan dalam *recall*. Secara keseluruhan,

akurasi model adalah 88.89%, dengan *macro avg* dan *weighted avg* yang cukup seimbang, menandakan bahwa model bekerja dengan baik di kedua kelas.

	precision	recall	f1-score	support
0	0.88	0.93	0.90	115
1	0.91	0.84	0.87	92
accuracy			0.89	207
macro avg	0.89	0.88	0.89	207
weighted avg	0.89	0.89	0.89	207

Gambar 3. *Classification Report*

Evaluasi terakhir dilakukan menggunakan *cross-validation* dengan pembagian 5-fold untuk menguji kestabilan model pada data yang berbeda. Hasil *cross-validation* menunjukkan akurasi rata-rata sebesar 85.50%, yang sedikit lebih rendah dibandingkan dengan akurasi pada data uji tunggal. Namun, hasil ini menunjukkan bahwa model memiliki performa yang konsisten di berbagai subset data dan tidak terpengaruh secara signifikan oleh pemisahan data tertentu. Ini memberikan keyakinan bahwa model memiliki kestabilan yang baik dan dapat diandalkan untuk digunakan pada data baru di masa mendatang.

IV. KESIMPULAN

Penelitian ini berhasil membangun model prediksi persetujuan kartu kredit menggunakan algoritma *Random Forest* dengan performa yang baik. Hasil evaluasi menunjukkan bahwa model mencapai akurasi sebesar 88,89% dengan *precision*, *recall*, dan *f1-score* yang seimbang untuk kedua kelas target. Evaluasi melalui *confusion matrix* membuktikan bahwa model mampu mengklasifikasikan mayoritas sampel dengan benar, sementara hasil *cross-validation* dengan rata-rata akurasi 85,50% menunjukkan kestabilan model dalam menangani berbagai subset data. Namun, penelitian ini memiliki keterbatasan pada skenario pengujian, seperti penggunaan dataset yang relatif seimbang dan belum mempertimbangkan skenario data tidak seimbang. Oleh karena itu, penelitian selanjutnya disarankan untuk membandingkan performa model *Random Forest* dengan algoritma lain seperti *XGBoost* atau *LightGBM*, yang sering menunjukkan performa tinggi dalam tugas klasifikasi, serta menguji model pada dataset yang lebih besar dan kompleks untuk melihat skalabilitas dan efisiensinya. Selain itu, metode penanganan data tidak seimbang seperti *oversampling* dan *undersampling* dapat diterapkan guna mengevaluasi performa model pada skenario yang lebih realistis. Dengan demikian, penelitian ini memberikan kontribusi penting dalam pengembangan sistem prediksi yang membantu lembaga keuangan mengevaluasi calon nasabah dengan lebih efisien dan akurat.

DAFTAR PUSTAKA

[1] J. Khatib Sulaiman, A. Syakur, R. Purwandi Putra, C. Juliane, S. LIKMI Bandung, and S. Tinggi Ilmu Kesehatan Sukabumi, "Optimalisasi Metode *Naive Bayes Classifier* Untuk Prediksi Persetujuan Kredit,"

- Indonesian Journal of Computer Science Attribution, vol. 13, no. 1, pp. 2024–1091, doi: <https://doi.org/10.33022/ijcs.v13i1.3622>.
- [2] A. A. Agustian and A. Bisri, “Data *Mining* Optimization Using Sample Bootstrapping and Particle Swarm Optimization in the Credit Approval Classification,” *Indonesian Journal of Artificial Intelligence and Data Mining*, vol. 2, no. 1, Mar. 2019, doi: <http://dx.doi.org/10.24014/ijaidm.v2i1.6299>.
- [3] S. Bansal and T. Punjabi, “Comparison of Different Supervised Machine Learning Classifiers to Predict Credit Card Approvals,” *International Research Journal of Engineering and Technology*, 2021, [Online]. Available: www.irjet.net
- [4] Y. Oktafriani, G. Firmansyah, B. Tjahyono, and A. M. Widodo, “Analysis of Data *Mining* Applications for Determining Credit Eligibility Using Classification Algorithms C4.5, Naïve Bayes, K-NN, and Random Forest,” *Indonesia*, Sep. 2023. doi: <https://doi.org/10.59888/ajosh.v1i12.119>.
- [5] N. Handayani, H. Wahyono, J. Trianto, and D. S. Permana, “Prediksi Tingkat Risiko Kredit dengan Data *Mining* Menggunakan Algoritma Decision Tree C.45,” *JURIKOM (Jurnal Riset Komputer)*, vol. 8, no. 6, p. 198, Dec. 2021, doi: [10.30865/jurikom.v8i6.3643](https://doi.org/10.30865/jurikom.v8i6.3643).
- [6] I. Sugiyarto, “Perbandingan Kinerja Algoritma Data *Mining* Prediksi Persetujuan Kartu Kredit,” *Faktor Exacta*, vol. 12, no. 3, p. 180, Nov. 2019, doi: [10.30998/faktorexacta.v12i3.4310](https://doi.org/10.30998/faktorexacta.v12i3.4310).
- [7] I. Suryani, “Comparison Of Decision Tree, Naive Bayes And Random Forest Algorithm To Get The Best Performance Of Algorithm For Customer Credit Classification,” *Jurnal Riset Informatika*, vol. 6, no. 1, 2023, doi: [10.34288/jri.v6i1.XXX](https://doi.org/10.34288/jri.v6i1.XXX).
- [8] N. Widjiyati, “Implementasi Algoritme Random Forest Pada Klasifikasi Dataset Credit Approval,” *Jurnal Janitra Informatika dan Sistem Informasi*, vol. 1, no. 1, pp. 1–7, Apr. 2021, doi: [10.25008/janitra.v1i1.118](https://doi.org/10.25008/janitra.v1i1.118).
- [9] A. Arisusanto, N. Suarna, and G. Dwilestari, “Analisa Klasifikasi Data Harga Handphone Menggunakan Algoritma Random Forest Dengan Optimize Parameter Grid,” *Jurnal Teknologi Ilmu Komputer*, vol. 1, no. 2, pp. 43–47, 2023, doi: [10.56854/jtik.v1i2.51](https://doi.org/10.56854/jtik.v1i2.51).
- [10] A. Muqtadir, A. A. Suryanto, A. Arifia, and F. Amaluddin, “Classification to predict credit card application acceptance using support vector machine,” p. 2023, 2024, doi: [10.31603/bistyc.135](https://doi.org/10.31603/bistyc.135).