

Pengembangan Aplikasi *Flask* untuk Prediksi *Churn* Nasabah Bank sebagai Pendukung Keputusan

Development of a Flask-based Application for Bank Customer Churn Prediction as a Decision Support Tool

¹Suluh Arif Wibowo*, ²Muhammad Rezky, ³Ali Ibrahim*, ⁴Mira Afrina, ⁵Fathoni

^{1,2,3,4,5}Magister Ilmu Komputer, Fakultas Ilmu Komputer, Universitas Sriwijaya
^{1,2,3,4,5}Jl. Srijaya Negara, Bukit Besar, Kec. Ilir Bar. I, Kota Palembang, Sumatera Selatan 30128, Indonesia

*e-mail: suluharif.w@gmail.com, rezkymfl@gmail.com, aliibrahim@unsri.ac.id,
miraafрина@unsri.ac.id, fathoni@unsri.ac.id

(received: 16 March 2026, revised: 1 April 2026, accepted: 4 April 2026)

Abstrak

Prediksi *churn* nasabah merupakan aspek krusial dalam industri perbankan untuk mempertahankan loyalitas pelanggan dan mengurangi biaya akuisisi nasabah baru. Penelitian ini bertujuan untuk mengembangkan sistem pendukung keputusan berbasis web yang mampu memprediksi potensi *churn* nasabah bank menggunakan algoritma *Gradient Boosting Machine* (GBM). Dataset yang digunakan adalah *Bank Customer Churn* Dataset yang terdiri dari 10.000 data nasabah dengan 14 atribut. Tahapan penelitian mencakup analisis eksplorasi data, pra-pemrosesan yang meliputi pembersihan data, *encoding* fitur kategorikal, rekayasa fitur (*BalanceSalaryRatio*, *TenureByAge*, *CreditScoreGivenAge*), serta penyeimbangan data menggunakan SMOTE untuk mengatasi ketidakseimbangan kelas. Model GBM dilatih dengan data yang telah diseimbangkan dan dievaluasi menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Hasil evaluasi menunjukkan bahwa model mencapai *accuracy* 83,95% dengan *recall* sebesar 67,32% pada kelas *churn*, yang mengindikasikan kemampuan model dalam mendeteksi nasabah berisiko *churn* cukup baik. Analisis *feature importance* mengungkapkan bahwa *Age* dan *NumOfProducts* merupakan dua fitur paling dominan dengan kontribusi 77% terhadap prediksi. Model kemudian diimplementasikan ke dalam aplikasi web berbasis Flask dengan antarmuka HTML dan CSS, memungkinkan pengguna non-teknis untuk melakukan prediksi *churn* secara *real-time*. Sistem ini diharapkan dapat membantu institusi perbankan dalam merancang strategi retensi yang lebih terarah dan berbasis data.

Kata kunci: *churn prediction, decision support system, flask, gradient boosting machine, SMOTE*

Abstract

Customer churn prediction is a crucial aspect of the banking industry for maintaining customer loyalty and reducing the cost of acquiring new customers. This study aims to develop a web-based decision support system capable of predicting potential customer churn using the Gradient Boosting Machine (GBM) algorithm. The dataset used is the Bank Customer Churn Dataset, consisting of 10,000 customer records with 14 attributes. The research stages include exploratory data analysis and preprocessing, which involves data cleaning, categorical feature encoding, feature engineering (BalanceSalaryRatio, TenureByAge, CreditScoreGivenAge), and data balancing using SMOTE to address class imbalance. The GBM model was trained on the balanced dataset and evaluated using accuracy, precision, recall, and F1-score metrics. The evaluation results show that the model achieved an accuracy of 83.95%, with a recall of 67.32% for the churn class, indicating a strong capability in identifying customers at risk of churn. Feature importance analysis reveals that Age and NumOfProducts are the most dominant features, contributing approximately 77% to the prediction. The model was then implemented in a Flask-based web application with an HTML and CSS interface, enabling non-technical users to perform real-time churn predictions. This system is expected to assist banking institutions in designing more targeted and data-driven customer retention strategies.

Keywords: *churn prediction, decision support system, flask, gradient boosting machine, SMOTE*

<http://sistemasi.ftik.unisi.ac.id>

1 Pendahuluan

Retensi nasabah merupakan faktor strategis dalam menjaga keberlanjutan dan profitabilitas industri perbankan. *customer churn* berdampak signifikan terhadap kinerja keuangan bank karena menyebabkan hilangnya pendapatan serta meningkatnya biaya akuisisi nasabah baru yang relatif lebih besar dibandingkan biaya mempertahankan nasabah yang sudah ada. Penelitian terbaru menunjukkan bahwa identifikasi dan prediksi *churn* secara dini memungkinkan bank mengimplementasikan strategi retensi yang lebih tepat sasaran, sehingga dapat meningkatkan customer lifetime value dan profitabilitas jangka panjang [1], [2].

Perkembangan teknologi digital mendorong pengambilan keputusan bisnis menuju pendekatan berbasis data dan kecerdasan buatan. Sejumlah studi menunjukkan bahwa *machine learning* efektif dalam menganalisis pola perilaku pelanggan yang kompleks dan non-linear, sedangkan pendekatan *ensemble learning* menawarkan stabilitas dan *accuracy* yang lebih baik pada data finansial berskala besar [3]. Oleh karena itu, pemanfaatan model prediktif menjadi penting bagi perbankan modern.

Meskipun berbagai pendekatan *machine learning* telah diterapkan untuk prediksi *churn*, permasalahan ketidakseimbangan data dan rendahnya interpretabilitas model masih menjadi tantangan utama dalam implementasi nyata. Model dengan *accuracy* tinggi sering kali bersifat *black-box*, sehingga sulit dipahami oleh pengambil keputusan non-teknis [4], [5].

Perkembangan teknologi digital mendorong sektor perbankan untuk mengadopsi pendekatan berbasis data dan kecerdasan buatan dalam mendukung pengambilan keputusan. Berbagai penelitian menunjukkan bahwa *machine learning* efektif dalam menganalisis pola perilaku pelanggan yang kompleks dan non-linear, sehingga dapat digunakan untuk mengidentifikasi nasabah yang berpotensi melakukan *churn* [3]. Dalam konteks prediksi *churn*, pendekatan klasifikasi yang dikombinasikan dengan interpretabilitas model menjadi penting agar hasil prediksi tidak hanya akurat, tetapi juga dapat dipahami dan digunakan pihak bank sebagai dasar strategi retensi nasabah [4]. Oleh karena itu, penelitian ini mengembangkan aplikasi web berbasis Flask untuk memprediksi *churn* nasabah bank dengan sistem pendukung keputusan.

2 Tinjauan Literatur

Churn didefinisikan sebagai kondisi ketika pelanggan menghentikan hubungan atau berhenti menggunakan layanan yang diberikan oleh suatu perusahaan dalam periode waktu tertentu. Dalam konteks perbankan, *churn* umumnya merujuk pada nasabah yang secara sadar memilih untuk menutup rekening, menghentikan penggunaan produk, atau berpindah ke institusi keuangan lain. Literatur juga membedakan *churn* menjadi *churn* aktif (*voluntary churn*), yaitu keputusan pelanggan untuk meninggalkan layanan, dan *churn* pasif (*involuntary churn*) yang terjadi akibat faktor eksternal seperti penutupan akun oleh perusahaan. Prediksi *churn* dalam sektor perbankan lebih difokuskan pada *churn* aktif karena jenis ini masih dapat dicegah melalui strategi retensi dan intervensi manajerial yang tepat [6].

Customer churn memberikan dampak signifikan terhadap industri jasa keuangan, khususnya sektor perbankan, karena secara langsung memengaruhi pendapatan, stabilitas nasabah, dan daya saing institusi keuangan. Studi empiris menunjukkan bahwa biaya untuk memperoleh nasabah baru dapat mencapai lima hingga enam kali lipat dibandingkan biaya mempertahankan nasabah yang sudah ada, sehingga tingkat *churn* yang tinggi berpotensi menimbulkan kerugian finansial yang substansial. Selain kehilangan pendapatan, *churn* juga berdampak pada menurunnya loyalitas pelanggan dan melemahnya posisi kompetitif bank di tengah meningkatnya persaingan serta diversifikasi produk keuangan digital. Oleh karena itu, kemampuan bank dalam mengantisipasi dan mengelola *churn* secara proaktif menjadi faktor kunci dalam menjaga keberlanjutan bisnis, memperpanjang siklus hidup nasabah, dan mengurangi risiko kerugian jangka panjang [7].

Prediksi *churn* pada umumnya dimodelkan sebagai permasalahan klasifikasi biner, dimana pelanggan dikategorikan ke dalam dua kelas yaitu *churn* dan non-*churn*. Pendekatan ini merepresentasikan kondisi pelanggan yang berhenti menggunakan layanan sebagai kelas positif dan pelanggan yang bertahan sebagai kelas negatif. Sebagian besar penelitian *churn* menggunakan

algoritma klasifikasi biner seperti Logistic Regression, Decision Tree, Support Vector Machine (SVM), Random Forest, serta metode *ensemble* berbasis boosting untuk mempelajari pola perilaku pelanggan [8].

Pendekatan *machine learning* untuk prediksi *churn* dengan memodelkannya sebagai permasalahan klasifikasi biner menggunakan logistic regression yang diperluas melalui teknik regularisasi penalti campuran. Metode yang digunakan adalah *penalized logistic regression* dengan kombinasi *elastic net*, yang dirancang untuk mengatasi permasalahan *overfitting*, *multikolinearitas* fitur, dan ketidakseimbangan kelas yang umum terjadi pada data *churn*. Pendekatan ini memungkinkan seleksi fitur yang lebih efektif sekaligus menjaga stabilitas model, sehingga meningkatkan kinerja prediksi dibandingkan *logistic regression* tanpa regularisasi [9], [10].

Metode Random Forest untuk prediksi *churn* dalam konteks bisnis B2B non-kontraktual dengan memodelkan *churn* sebagai masalah klasifikasi biner antara pelanggan yang bertahan dan pelanggan yang berhenti bertransaksi. Random Forest dapat menangani hubungan non-linear, interaksi antar fitur, serta ketidakseimbangan kelas yang umum pada data *churn* [11].

Gradient Boosting Machine (GBM) merupakan metode *ensemble learning* yang membangun model prediktif secara iteratif dengan menggabungkan sejumlah *weak learner* untuk meminimalkan fungsi kerugian secara bertahap. GBM sebagai pendekatan klasifikasi biner untuk membedakan pelanggan *churn* dan *non-churn* dengan memanfaatkan kemampuan GBM dalam menangkap hubungan non-linear dan interaksi kompleks antar fitur. Model GBM bekerja dengan menyesuaikan model baru pada residual kesalahan dari model sebelumnya sehingga performa prediksi meningkat pada setiap tahap *boosting* [12].

Gradient Boosting Machine (GBM) merupakan metode *ensemble learning* yang membangun model prediktif secara bertahap melalui penggabungan sejumlah *weak learner*, umumnya berupa pohon keputusan berukuran kecil. Konsep dasar GBM terletak pada mekanisme *boosting*, di mana setiap model baru dilatih untuk memperbaiki kesalahan prediksi yang dihasilkan oleh model sebelumnya. Proses ini dilakukan dengan meminimalkan fungsi kerugian menggunakan pendekatan berbasis gradien, sehingga setiap iterasi secara aditif menurunkan nilai kesalahan model secara keseluruhan. Dengan mempelajari *residual error* pada setiap tahap, GBM mampu menangkap hubungan non-linear dan interaksi kompleks antar fitur secara lebih efektif. Dalam konteks prediksi *churn*, pendekatan ini menjadikan GBM adaptif terhadap karakteristik data pelanggan yang heterogen dan tidak seimbang, serta meningkatkan kemampuan model dalam membedakan pelanggan *churn* dan *non-churn* [13].

seimbang, serta meningkatkan kemampuan model dalam membedakan pelanggan *churn* dan *non-churn* [13]. Oleh karena itu, *Gradient Boosting Machine* (GBM) dipilih karena menggunakan mekanisme *boosting* yang membangun model secara bertahap dan iteratif untuk meminimalkan kesalahan model sebelumnya. Pendekatan ini memungkinkan GBM lebih adaptif dalam menangkap pola kompleks pada data pelanggan. Selain itu, GBM memiliki fleksibilitas dalam pengaturan fungsi kerugian dan hiperparameter (misalnya *learning rate*, jumlah estimator, dan kedalaman pohon), sehingga proses optimasi model dapat dilakukan secara lebih terarah untuk meningkatkan performa prediksi *churn* [14], [15].

Decision Support System (DSS) merupakan sistem yang berbasis komputer yang dirancang untuk melakukan pengambilan keputusan dalam menghadapi permasalahan semi-terstruktur dan kompleks melalui integrasi data, model analitik, serta mekanisme penyajian informasi yang dapat ditindaklanjuti. Peran utama DSS bukan sekadar menghasilkan prediksi, tetapi menyediakan wawasan yang dapat dipahami dan digunakan secara langsung oleh pengambil keputusan, khususnya dalam konteks bisnis [16].

DSS berperan sebagai sarana untuk meningkatkan kualitas pengambilan keputusan bisnis dengan mengintegrasikan data, model analitik, dan umpan balik pengguna ke dalam satu kerangka kerja yang sistematis. DSS memiliki fungsi untuk menjembatani hasil analisis berbasis kecerdasan buatan dengan kebutuhan praktis pengambil keputusan, khususnya dalam konteks bisnis yang kompleks dan dinamis [17]. Dengan menerapkan pendekatan *human-in-the-loop* (HITL), DSS memungkinkan pengambil keputusan untuk memahami, mengevaluasi, dan membangun kepercayaan terhadap keluaran model analitik, termasuk model *machine learning* yang bersifat *black-box*. Peran ini menjadikan DSS tidak hanya sebagai alat prediksi, tetapi juga sebagai mekanisme untuk menghasilkan wawasan yang dapat ditindaklanjuti (*actionable insights*). Dengan demikian, DSS mampu mendukung perumusan strategi

<http://sistemasi.ftik.unisi.ac.id>

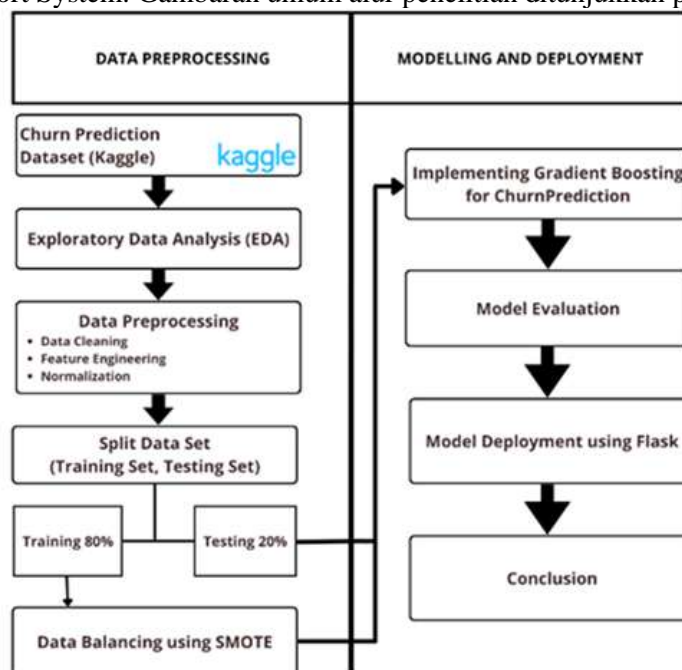
bisnis yang lebih tepat, transparan, dan selaras dengan tujuan organisasi [18].

Flask merupakan *framework* web berbasis *Python* yang bersifat ringan (*lightweight*) dan fleksibel karena tidak menerapkan arsitektur monolitik maupun komponen bawaan yang berlebihan. Flask menyediakan fungsi inti untuk pengelolaan routing, permintaan (*request*), dan respons (*response*), serta memungkinkan pengembang menambahkan komponen lain sesuai kebutuhan sistem. Karakteristik ini menjadikan Flask mudah diintegrasikan dengan model *machine learning* dan pustaka analitik, sehingga cocok digunakan dalam pengembangan aplikasi berbasis data dan sistem pendukung keputusan. Selain itu, penggunaan template engine seperti Jinja2 dan dukungan ORM memudahkan pemisahan antara logika aplikasi, tampilan, dan pengelolaan data, yang mendukung pengembangan sistem web yang sederhana, terstruktur, dan mudah dipelihara [19].

Integrasi *machine learning* dan *web application* memungkinkan proses analitik berbasis data diimplementasikan secara *end-to-end* dalam sebuah sistem yang dapat diakses langsung oleh pengguna. Model *machine learning* tidak berdiri sebagai komponen terpisah, tetapi diintegrasikan ke dalam arsitektur aplikasi web sehingga seluruh tahapan dimulai dari pengolahan data, pelatihan model, evaluasi, hingga penyajian hasil didapat untuk menjalankan melalui antarmuka web. Pendekatan ini menjadikan *machine learning* lebih mudah digunakan oleh pengguna non-teknis karena proses komputasi kompleks disembunyikan di sisi *backend*, sementara pengguna berinteraksi melalui antarmuka web yang intuitif. Integrasi *machine learning* ke dalam *web application* juga meningkatkan fleksibilitas dan skalabilitas sistem, serta mendukung pemanfaatan hasil analisis sebagai dasar pengambilan keputusan secara *real-time* [20].

3 Metode Penelitian (or Research Method)

Penelitian ini menggunakan pendekatan eksperimen dengan membangun sistem prediksi *churn* nasabah secara *end-to-end*, mulai dari pengolahan data hingga implementasi model dalam aplikasi web berbasis Flask. Alur penelitian terdiri dari dua tahapan utama, yaitu data *preprocessing* serta *modelling* dan *deployment*. Tahapan pertama berfokus pada pengolahan dan persiapan data, sedangkan tahapan kedua mencakup pembangunan model, evaluasi, serta implementasi sistem sebagai Decision Support System. Gambaran umum alur penelitian ditunjukkan pada Gambar 1.



Gambar 1 Alur penelitian

Pada Gambar 1, menunjukkan alur penelitian dalam pengembangan sistem prediksi *churn* nasabah bank yang dibagi menjadi dua tahap utama, yaitu *data preprocessing* serta *modelling* dan *deployment*. Pada tahap awal, penelitian menggunakan dataset *churn* prediction sebagai sumber data utama. Data kemudian dianalisis melalui Exploratory Data Analysis (EDA) untuk memahami

karakteristik data, distribusi variabel, serta pola awal yang berpotensi memengaruhi *churn* nasabah. Setelah itu, dilakukan data *preprocessing* yang meliputi data *cleaning*, *feature engineering*, dan *normalization* agar data lebih siap digunakan dalam proses pemodelan. Selanjutnya, dataset dibagi menjadi data *training* sebesar 80% dan data *testing* sebesar 20%. Pada data *training* dilakukan data balancing menggunakan SMOTE untuk mengatasi ketidakseimbangan kelas antara kelas nasabah yang *churn* dan tidak *churn*, sehingga model dapat belajar secara lebih seimbang. Tahap berikutnya masuk ke bagian *modelling and deployment*, yaitu dengan mengimplementasikan algoritma Gradient Boosting untuk prediksi *churn*. Model yang dihasilkan kemudian dievaluasi untuk mengukur kinerjanya berdasarkan data pengujian. Setelah diperoleh model dengan performa yang memadai, model tersebut dideploy ke dalam aplikasi web menggunakan Flask agar dapat dimanfaatkan sebagai sistem pendukung keputusan. Alur ini diakhiri dengan penarikan kesimpulan berdasarkan hasil pengolahan data, pemodelan, evaluasi, dan implementasi sistem.

Dataset yang digunakan dalam penelitian ini merupakan Bank Customer *Churn* Dataset yang diperoleh dari platform Kaggle. Dataset terdiri dari 10.000 data nasabah dengan 14 atribut yang mencerminkan karakteristik pelanggan, hubungan dengan bank, serta status *churn*. Variabel target dalam penelitian ini adalah kolom *Exited*, yang menunjukkan apakah nasabah berhenti menggunakan layanan bank (*churn*) atau tetap bertahan. Atribut dalam dataset meliputi *RowNumber* sebagai nomor indeks data, *CustomerId* sebagai identitas unik nasabah, dan *Surname* sebagai nama belakang pelanggan. Selain itu, terdapat atribut yang berkaitan dengan karakteristik finansial dan demografis nasabah seperti *CreditScore*, *Geography*, *Gender*, *Age*, *Tenure*, *Balance*, *NumOfProducts*, *HasCrCard*, *IsActiveMember*, serta *EstimatedSalary*. Dalam proses pemodelan, atribut yang bersifat identitas seperti *RowNumber*, *CustomerId*, dan *Surname* tidak digunakan karena tidak memiliki pengaruh langsung terhadap perilaku *churn*. Dataset ini kemudian digunakan sebagai dasar dalam pembangunan model prediksi *churn* nasabah.

Exploratory Data Analysis (EDA) dilakukan untuk memahami karakteristik dataset sebelum memasuki tahap pemodelan. Analisis ini mencakup pemeriksaan jumlah data, tipe variabel, distribusi fitur, serta proporsi kelas target. Dataset terdiri dari 10.000 data nasabah dengan kombinasi fitur numerik dan kategorikal yang merepresentasikan karakteristik demografis dan finansial pelanggan. Hasil analisis awal menunjukkan bahwa sebagian besar fitur numerik seperti *Age*, *balance*, dan *estimated salary* memiliki distribusi yang bervariasi, sedangkan fitur kategorikal seperti *geography* dan *gender* menunjukkan distribusi yang tidak merata pada beberapa kategori. Selain itu, analisis distribusi kelas target menunjukkan adanya ketidakseimbangan antara jumlah nasabah *churn* dan *non-churn*, di mana kelas *non-churn* lebih dominan. Kondisi ini berpotensi menyebabkan bias model terhadap kelas mayoritas apabila tidak ditangani dengan tepat. Oleh karena itu, diperlukan tahapan *preprocessing* lanjutan, termasuk penyeimbangan data, agar model mampu mengenali pola *churn* secara lebih optimal.

Tahap *preprocessing* dilakukan untuk meningkatkan kualitas data sebelum digunakan dalam proses pelatihan model *machine learning*. Langkah pertama adalah melakukan data *cleaning* dengan memeriksa adanya data duplikat, *missing values*, serta memastikan konsistensi format data. Selanjutnya, dilakukan seleksi fitur dengan menghapus atribut yang tidak relevan terhadap prediksi *churn*, yaitu *RowNumber*, *CustomerId*, dan *Surname*, karena atribut tersebut hanya berfungsi sebagai identitas dan tidak memiliki pengaruh terhadap perilaku nasabah. Setelah itu, fitur kategorikal seperti *Geography* dan *Gender* dikonversi ke dalam bentuk numerik menggunakan teknik *encoding* agar dapat diproses oleh algoritma *machine learning*. Pada tahap berikutnya, dilakukan normalisasi atau standarisasi terhadap fitur numerik untuk menyamakan skala data dan meningkatkan stabilitas proses pembelajaran model. Proses *preprocessing* diakhiri dengan pembagian dataset menjadi data latih dan data uji untuk memastikan evaluasi model yang objektif.

Setelah melalui tahap *preprocessing*, dataset dibagi menjadi data latih (*training set*) dan data uji (*testing set*) menggunakan rasio 80:20. Pembagian ini bertujuan untuk mengevaluasi kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya. Data latih digunakan untuk membangun dan melatih model *machine learning*, sedangkan data uji digunakan untuk mengukur performa model secara objektif. Proses pembagian data dilakukan secara acak (*random split*) untuk menghindari bias distribusi data antara kedua subset.

Dataset *churn* umumnya memiliki distribusi kelas yang tidak seimbang, di mana jumlah nasabah *non-churn* lebih dominan dibandingkan *churn*. Ketidakseimbangan ini dapat menyebabkan model

<http://sistemasi.ftik.unisi.ac.id>

cenderung bias terhadap kelas mayoritas dan menurunkan kemampuan deteksi terhadap kelas minoritas. Untuk mengatasi permasalahan tersebut, penelitian ini menggunakan teknik *Synthetic Minority Over-sampling Technique* (SMOTE) pada data latih. SMOTE bekerja dengan menghasilkan sampel sintesis pada kelas minoritas berdasarkan kedekatan antar data dalam ruang fitur, sehingga distribusi kelas menjadi lebih seimbang tanpa mengurangi informasi pada kelas mayoritas. Penerapan SMOTE diharapkan dapat meningkatkan kemampuan model dalam mendeteksi nasabah yang berpotensi *churn*.

Model prediksi *churn* dikembangkan menggunakan algoritma *Gradient Boosting Machine* (GBM). Algoritma ini dipilih karena kemampuannya dalam mempelajari hubungan non-linear dan interaksi kompleks antar fitur melalui mekanisme boosting. Model dilatih menggunakan data *training* yang telah diseimbangkan dengan SMOTE untuk meningkatkan kemampuan deteksi nasabah *churn*. Implementasi model dilakukan menggunakan pustaka *machine learning* berbasis *Python* seperti *Scikit-learn* atau *XGBoost*. Proses pelatihan melibatkan pengaturan hiperparameter seperti jumlah estimator, learning rate, dan kedalaman pohon keputusan untuk memperoleh performa optimal.

$$F_M(x) = F_{M-1}(x) + \eta\gamma_m h_m(x) \quad (1)$$

Persamaan (1) menunjukkan proses pembaruan model secara bertahap pada GBM. Pada tahap ini, setiap pohon keputusan berusaha memperbaiki kesalahan prediksi yang dihasilkan oleh model pada iterasi sebelumnya.

$$F_M(x) = F_0(x) + \sum_{m=1}^M \eta\gamma_m h_m(x) \quad (2)$$

Persamaan (2) merupakan bentuk akhir dari model GBM yang diperoleh dari akumulasi seluruh lerner selama proses *training*. Setiap model memberikan kontribusi terhadap pembentukan fungsi prediksi akhir sehingga hasil mencerminkan kombinasi dari seluruh pola yang telah dipelajari dari data *training*. Dengan demikian, model dapat menghasilkan representasi yang lebih akurat terhadap kecenderungan *churn* nasabah.

$$P(y = 1|x) = \frac{1}{1+e^{-F_M(x)}} \quad (3)$$

Persamaan (3) digunakan untuk mengubah nilai keluaran model menjadi probabilitas terjadinya *churn*. Nilai fungsi prediksi pada GBM dipetakan ke rentang 0 dan 1 menggunakan fungsi logistik sehingga hasil prediksi dapat diinterpretasikan sebagai peluang seorang nasabah akan *churn* atau tidak. Dalam hal ini, nilai probabilitas ini menjadi dasar bagi sistem pendukung keputusan untuk menampilkan hasil prediksi kepada pengguna.

Evaluasi model dilakukan menggunakan data testing untuk mengukur kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya. Penilaian kinerja model didasarkan pada komponen *confusion matrix*, yang terdiri dari *True Positive* (TP) sebagai data positif yang terprediksi benar, *True Negative* (TN) sebagai data negatif yang terprediksi benar, *False Positive* (FP) sebagai data negatif yang salah diprediksi positif, dan *False Negative* (FN) sebagai data positif yang salah diprediksi negatif. Berdasarkan komponen tersebut, metrik evaluasi yang digunakan meliputi *accuracy* untuk mengukur proporsi prediksi benar terhadap seluruh data, *precision* untuk menunjukkan akurasi prediksi positif, serta *recall* untuk mengukur kemampuan model dalam mendeteksi seluruh data yang benar-benar positif. Selain itu, digunakan pula *F1-score* sebagai rata-rata harmonis antara *precision* dan *recall* yang memberikan penilaian seimbang terhadap performa model secara keseluruhan. Dari matriks ini, beberapa metrik evaluasi dapat dihitung, yaitu:

a. *Accuracy*

Mengukur seberapa besar proporsi prediksi yang benar terhadap seluruh data.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (4)$$

b. *Precision*

Menunjukkan seberapa banyak prediksi positif yang benar-benar positif.

$$Precision = \frac{TP}{TP+FP} \quad (5)$$

c. Recall

Mengukur kemampuan model dalam mendeteksi seluruh data yang benar-benar positif.

$$Recall = \frac{TP}{TP+FN} \quad (6)$$

d. F1-score

Merupakan rata-rata harmonis antara *precision* dan *recall* yang memberikan penilaian seimbang terhadap kinerja model.


$$F1 - Score = 2x \frac{Precision \times Recall}{Precision+Recall} \quad (7)$$

Model yang telah dilatih kemudian diimplementasikan ke dalam aplikasi web sebagai sistem pendukung keputusan berbasis *machine learning*. Proses *deployment* menggunakan *Python* sebagai *backend* dengan *framework* Flask untuk mengelola logika aplikasi, memproses input pengguna, serta menjalankan model prediksi *churn* secara *real-time*. Model yang telah diserialisasi dimuat pada server sehingga dapat digunakan untuk melakukan prediksi berdasarkan data yang dimasukkan pengguna.

Pada sisi *frontend*, antarmuka aplikasi dikembangkan menggunakan HTML dan CSS untuk menyediakan tampilan yang sederhana dan mudah digunakan. Pengguna dapat memasukkan data nasabah melalui form web, kemudian sistem memproses data tersebut di *backend* dan menampilkan hasil prediksi pada halaman yang sama. Integrasi antara *Python* Flask sebagai *backend* dan HTML-CSS sebagai *frontend* memungkinkan sistem berjalan secara *end-to-end* dan dapat digunakan sebagai Decision Support System oleh pengguna non-teknis.

4 Hasil dan Pembahasan

Analisis awal dilakukan untuk memahami karakteristik dataset sebelum pemodelan. Eksplorasi terhadap variabel target *Exited* menunjukkan adanya ketidakseimbangan kelas, di mana jumlah nasabah non-*churn* jauh lebih dominan dibandingkan nasabah *churn*. Kondisi ini berisiko menyebabkan model bias terhadap kelas mayoritas jika tidak ditangani.



Gambar 2 Visualisasi data

Hasil visualisasi distribusi variabel target *Exited* pada Gambar 2 memperlihatkan ketidakseimbangan kelas yang signifikan, di mana jumlah nasabah yang bertahan (80%) jauh melampaui nasabah yang *churn* (20%). Secara statistik, rasio 4:1 ini mengindikasikan adanya risiko

bias mayoritas, di mana model cenderung memiliki *accuracy* semu yang tinggi namun gagal mendeteksi nasabah *churn* secara akurat. Temuan ini menjadi landasan teknis diperlukannya intervensi *oversampling* menggunakan *SMOTE* pada tahap pra-pemrosesan untuk meningkatkan sensitivitas model.



Gambar 3 Visualisasi korelasi data

Analisis korelasi pada Gambar 3 memberikan gambaran awal mengenai kekuatan hubungan linear antar fitur terhadap status *churn*. Fitur *Age* menunjukkan korelasi positif terkuat, yang mengimplikasikan bahwa peningkatan usia nasabah berbanding lurus dengan probabilitas mereka untuk meninggalkan bank. Sebaliknya, *IsActiveMember* menunjukkan korelasi negatif, menegaskan bahwa nasabah yang aktif berinteraksi dengan layanan bank memiliki tingkat retensi yang lebih stabil. Informasi korelasi ini digunakan untuk memvalidasi hasil *feature engineering* dan memastikan fitur yang masuk ke tahap pemodelan memiliki relevansi prediktif yang kuat.

Berdasarkan temuan korelasi tersebut, tahap pra-pemrosesan data dilakukan secara intensif untuk meningkatkan kualitas dataset sebelum memasuki proses pemodelan. Langkah pertama dimulai dengan menghapus atribut yang bersifat identitas seperti *RowNumber*, *CustomerId*, dan *Surname* karena tidak memiliki kontribusi informatif terhadap prediksi *churn*. Selanjutnya, untuk mengakomodasi temuan korelasi pada fitur non-numerik, fitur kategorikal ditangani dengan menerapkan *one-hot encoding* pada kolom *Geography* dan *Gender*. Teknik ini mengubah variabel kategorikal menjadi bentuk numerik biner, seperti *Geography_France*, *Geography_Germany*, dan *Gender_Male*, sehingga algoritma *machine learning* dapat memproses data tanpa mengasumsikan adanya tingkatan antar kategori. Sebagai pelengkap, normalisasi juga diterapkan pada fitur numerik untuk menyamakan skala data, sehingga meningkatkan stabilitas dan kinerja model selama fase pelatihan.

Selain pembersihan dan transformasi data, dilakukan pula rekayasa fitur untuk menciptakan variabel baru yang diharapkan dapat menangkap pola yang lebih kompleks dari data yang ada. Beberapa rasio fitur baru diperkenalkan, yaitu *BalanceSalaryRatio* yang merupakan rasio antara saldo dan gaji nasabah, *TenureByAge* yang menstandarisasi masa keanggotaan terhadap usia, serta *CreditScoreGivenAge* yang mengukur skor kredit relatif terhadap usia. Penambahan fitur-fitur ini

bertujuan untuk memberikan perspektif baru kepada model dalam memahami perilaku nasabah, seperti proporsi kekayaan terhadap pendapatan atau kewajaran skor kredit berdasarkan tahapan usia. Hasil dari seluruh rangkaian pra-pemrosesan ini menghasilkan dataset yang lebih kaya, bersih, dan siap digunakan dalam proses pelatihan model.

Tahapan *preprocessing* yang dilakukan mencakup pembersihan data, transformasi variabel kategorikal, rekayasa fitur, dan normalisasi. Ringkasan perubahan struktur dataset sebelum dan sesudah *preprocessing* disajikan pada Tabel 1.

Tabel 1 Tahapan sebelum dan sesudah *preprocessing*

Tahap	Jumlah Fitur	Fitur	Keterangan
Sebelum Processing	11	<i>RowNumber, CustomerId, Geography, Gender, Age, Tenure, Balance, NumOfProducts, HasCrCard, IsActiveMember, EstimatedSalary</i>	Masih terdapat fitur identitas yang tidak relevan; fitur kategorikal (<i>Geography</i> dan <i>Gender</i>) belum siap diproses model
Sesudah Processing	12	<i>Age, Balance, NumOfProducts, IsActiveMember, Geography_France, Geography_Germany, Geography_Spain, Gender_Male, Gender_Female, BalanceSalaryRatio, TenureByAge, CreditScoreGivenAge</i>	Fitur identitas dihapus; fitur kategorikal di- <i>encoding</i> ; tiga fitur baru hasil rekayasa ditambahkan

Untuk mengatasi ketidakseimbangan distribusi kelas yang telah diidentifikasi pada tahap analisis dataset, penelitian ini menerapkan Synthetic Minority Over-sampling Technique (SMOTE) pada data latih. Sebelum penerapan SMOTE, distribusi kelas menunjukkan ketimpangan yang signifikan dengan jumlah nasabah *non-churn* (kelas 0) sebanyak 6.370 sampel, sementara nasabah *churn* (kelas 1) hanya berjumlah 1.630 sampel. Ketimpangan ini berpotensi menyebabkan model menjadi bias terhadap kelas mayoritas dan kurang sensitif dalam mendeteksi nasabah yang benar-benar berisiko *churn*. Setelah penerapan SMOTE pada data latih, jumlah sampel pada kelas minoritas ditingkatkan dengan menciptakan sampel sintetis sehingga distribusi kelas menjadi seimbang. Hasilnya, kelas *churn* (1) meningkat menjadi 6.370 sampel, menyamai jumlah kelas *non-churn* (0) yang juga berjumlah 6.370 sampel. Dengan distribusi yang seimbang ini, model diharapkan dapat mempelajari pola kedua kelas secara lebih adil dan optimal, sehingga kemampuannya dalam mengidentifikasi nasabah yang berpotensi *churn* meningkat secara signifikan.

Tabel 2 Hasil labeling data

Tahap	Kelas Non-Churn	Kelas Churn	Total Sampel
Sebelum SMOTE	6.370	1.630	8.000
Setelah SMOTE	6.370	6.370	12.740

Pada Tabel 2 menunjukkan, hasil distribusi jumlah data pada kelas *Non-Churn* dan *Churn* sebelum dan sesudah melakukan penerapan metode SMOTE. Sebelum dilakukan SMOTE, jumlah data pada kelas *Non-Churn* berjumlah 1.630 sampel dengan total keseluruhan 8.000 sampel. Kondisi ini menunjukkan adanya ketidakseimbangan kelas karena jumlah data kelas *Non-Churn* jauh lebih banyak dibandingkan kelas *Churn*. Setelah melakukan metode SMOTE, jumlah data pada kelas *Churn* meningkat dari 1.630 menjadi 6.370 sampel yang mengakibatkan total dari keseluruhan data meningkat menjadi 12.740 sampel. Hasil ini menunjukkan bahwa SMOTE bekerja dengan menambah sampel sintetis pada kelas minoritas tanpa mengubah jumlah data pada kelas mayoritas. Penerapan SMOTE ini bertujuan untuk mengurangi bias model terhadap kelas mayoritas serta meningkatkan kemampuan model dalam mengenali pola pada kelas minoritas.

Model *Gradient Boosting Machine* (GBM) dilatih menggunakan data yang telah melalui tahap *preprocessing* dan penyeimbangan kelas dengan metode SMOTE. Evaluasi performa model dilakukan menggunakan data uji yang belum pernah dilihat selama pelatihan, dengan metrik *accuracy*, *precision*, *recall*, dan *F1-score*. Ringkasan hasil evaluasi model disajikan pada Tabel 3.

Tabel 3 Hasil evaluasi model

Metrics	Scores
<i>Accuracy</i>	83,95%
<i>Precision</i>	59,31%
<i>Recall</i>	67,32%
<i>F1-score</i>	63,06%
<i>Specificity</i>	88,20%

Untuk mengatasi ketidakseimbangan distribusi kelas yang telah diidentifikasi pada tahap analisis dataset, penelitian ini menerapkan Synthetic Minority Over-sampling Technique (SMOTE) pada data latih. Sebelum penerapan SMOTE, distribusi kelas menunjukkan ketimpangan yang signifikan dengan jumlah nasabah *non-churn* (kelas 0) sebanyak 6.370 sampel, sementara nasabah *churn* (kelas 1) hanya berjumlah 1.630 sampel. Ketimpangan ini berpotensi menyebabkan model menjadi bias terhadap kelas mayoritas dan kurang sensitif dalam mendeteksi nasabah yang benar-benar berisiko *churn*. Setelah penerapan SMOTE pada data latih, jumlah sampel pada kelas minoritas ditingkatkan dengan menciptakan sampel sintesis sehingga distribusi kelas menjadi seimbang. Hasilnya, kelas *churn* (1) meningkat menjadi 6.370 sampel, menyamai jumlah kelas *non-churn* (0) yang juga berjumlah 6.370 sampel. Dengan distribusi yang seimbang ini, model diharapkan dapat mempelajari pola kedua kelas secara lebih adil dan optimal, sehingga kemampuannya dalam mengidentifikasi nasabah yang berpotensi *churn* meningkat secara signifikan.

Hasil pengujian menunjukkan bahwa model mencapai *accuracy* sebesar 83,95% , dengan nilai *precision* 59.31%, *recall* 67.32%, dan *F1-score* 63.06%. Nilai *recall* sebesar 67.32% pada kelas *churn* menunjukkan bahwa model mampu mengidentifikasi sekitar 67% dari total nasabah yang benar-benar berpotensi *churn*. Dalam konteks bisnis perbankan, kemampuan ini cukup penting karena deteksi dini terhadap nasabah *churn* memungkinkan institusi untuk melakukan intervensi retensi sebelum nasabah benar-benar meninggalkan layanan. Meskipun nilai *precision* berada di angka 59.31% yang berarti tidak semua prediksi *churn* akurat, kesalahan prediksi (*false positive*) umumnya memiliki dampak lebih rendah dibandingkan kehilangan nasabah yang tidak terdeteksi (*false negative*). Analisis *confusion matrix* memberikan gambaran lebih rinci mengenai kinerja klasifikasi model. Distribusi hasil klasifikasi disajikan pada Tabel 4.

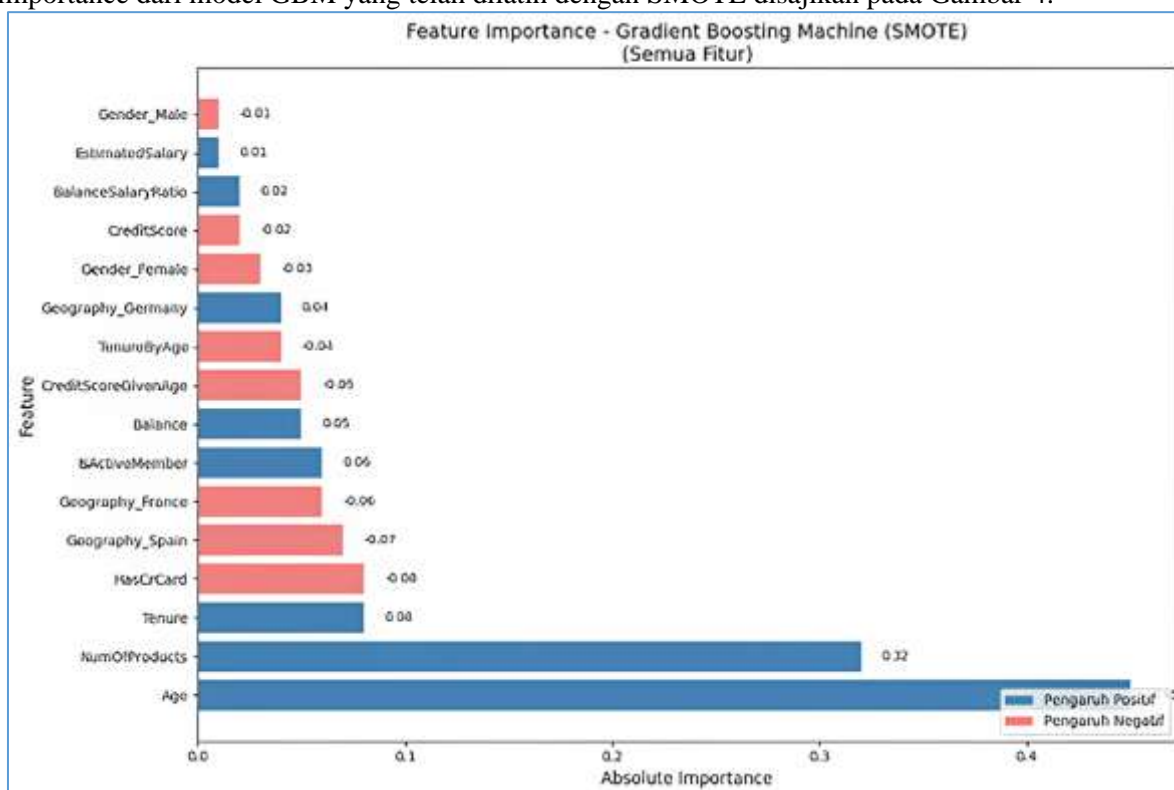
Tabel 4 Hasil Labeling Data

Actual Class	Predictred Non-Churn	Predicted Churn
Actual Non-Churn	1.405 (TN)	188 (FP)
Actual Churn	133 (FN)	274 (TP)

Dari total data uji, model berhasil mengklasifikasikan 1.405 nasabah *non-churn* dengan benar (true negatives) dan 274 nasabah *churn* dengan benar (true positives). Namun, terdapat 188 kesalahan prediksi di mana nasabah *non-churn* diprediksi sebagai *churn* (*false positives*), serta 133 kesalahan di mana nasabah *churn* tidak terdeteksi (*false negatives*). *Specificity* model mencapai 88.20%, yang menunjukkan kemampuan model dalam mengidentifikasi nasabah *non-churn* sangat baik. Sementara itu, sensitivitas (*recall*) sebesar 67.32% menunjukkan bahwa masih terdapat ruang peningkatan dalam mendeteksi nasabah *churn*. Secara keseluruhan, model GBM dengan SMOTE menunjukkan

kemampuan generalisasi yang cukup baik terhadap data baru. Kombinasi metrik yang dihasilkan mengindikasikan bahwa model ini dapat diandalkan sebagai dasar sistem pendukung keputusan untuk prediksi *churn* nasabah bank. Nilai *recall* yang cukup tinggi pada kelas *churn* menjadi perhatian utama karena dalam konteks bisnis, mendeteksi nasabah yang berisiko *churn* lebih prioritas dibandingkan ketepatan absolut prediksi, selama biaya intervensi retensi masih lebih rendah dibandingkan nilai nasabah yang dipertahankan.

Salah satu keunggulan model berbasis *ensemble* seperti *Gradient Boosting Machine* adalah kemampuannya untuk memberikan informasi mengenai tingkat kepentingan setiap fitur dalam proses prediksi. Analisis ini penting untuk memahami faktor-faktor apa yang paling dominan mempengaruhi keputusan model dalam mengklasifikasikan nasabah yang berpotensi *churn*. Visualisasi feature importance dari model GBM yang telah dilatih dengan SMOTE disajikan pada Gambar 4.



Gambar 4 Visualisasi korelasi data

Berdasarkan Gambar 4, mengilustrasikan kontribusi relatif setiap fitur terhadap keputusan klasifikasi model GBM. Hasil analisis menunjukkan dominasi dua fitur utama, yaitu *Age* (45%) dan *NumOfProducts* (32%), yang secara kumulatif menyumbang 77% dari total bobot prediksi model. Hal ini membuktikan bahwa faktor demografis usia dan kedalaman portofolio produk nasabah adalah prediktor kunci dalam perilaku *churn*.

Fitur *NumOfProducts* (Jumlah Produk) menempati peringkat kedua dengan importance 32%. Pengaruh positif fitur ini menunjukkan bahwa semakin banyak produk yang digunakan nasabah, semakin kecil kemungkinannya untuk *churn*. Hal ini dapat dijelaskan karena nasabah dengan banyak produk memiliki tingkat ketergantungan lebih tinggi terhadap bank serta biaya perpindahan yang lebih besar. Kedua fitur ini mendominasi total importance dengan kontribusi gabungan sebesar 77% , sementara 14 fitur lainnya hanya menyumbang 23% sisanya. Hal ini menegaskan bahwa usia dan jumlah produk adalah dua indikator paling kuat dalam memprediksi *churn*. Fitur lain dengan pengaruh positif yang cukup berarti adalah *Tenure* (0,08), *IsActiveMember* (0,06), dan *Balance* (0,05). Sementara itu, fitur dengan pengaruh negatif seperti *HasCrCard* (-0,08), *Geography_Spain* (-0,07), dan *Geography_France* (-0,06) menunjukkan korelasi negatif dengan *churn* meskipun pengaruhnya relatif kecil. Temuan ini memberikan wawasan berharga bagi institusi perbankan dalam merancang strategi retensi. Bank dapat memfokuskan intervensi pada nasabah dengan profil berisiko tinggi, yaitu

nasabah usia lanjut dengan jumlah produk terbatas, serta meningkatkan program *cross-selling* untuk menambah jumlah produk nasabah guna meningkatkan loyalitas.

Model *Gradient Boosting Machine* yang telah dilatih dan dievaluasi selanjutnya diimplementasikan ke dalam sistem pendukung keputusan berbasis web. Implementasi ini bertujuan untuk memudahkan pengguna non-teknis, seperti analis bisnis atau manajer bank, dalam memanfaatkan model prediksi *churn* secara interaktif dan *real-time*.

1) Arsitektur Sistem

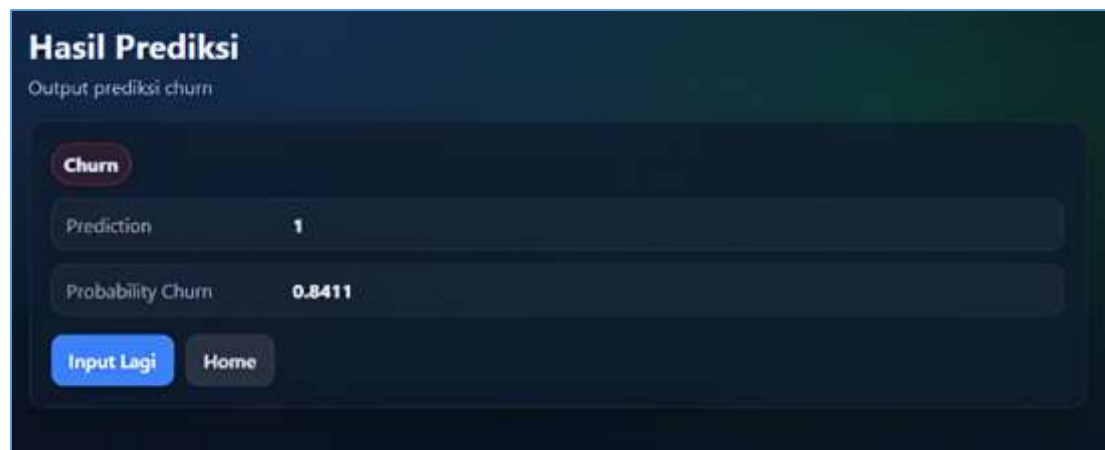
Sistem dikembangkan menggunakan Flask sebagai *backend framework* yang menghubungkan antarmuka pengguna dengan model *machine learning*. Model yang telah disimpan dalam format *joblib* dimuat ke dalam aplikasi untuk melakukan prediksi berdasarkan input yang diberikan pengguna. Bagian *frontend* dibangun dengan HTML dan CSS untuk menyediakan antarmuka yang sederhana dan mudah digunakan. Alur kerja sistem dimulai ketika pengguna memasukkan data nasabah melalui form input. Data tersebut kemudian dikirim ke server Flask, diproses agar sesuai dengan format yang diharapkan model (termasuk *encoding* fitur kategorikal), dan diteruskan ke model GBM untuk menghasilkan prediksi. Hasil prediksi berupa status *churn* beserta probabilitasnya dikembalikan dan ditampilkan kepada pengguna melalui halaman web.

2) Antarmuka Sistem

Salah satu keunggulan model berbasis *ensemble* seperti *Gradient Boosting Machine* adalah kemampuannya untuk memberikan informasi mengenai tingkat kepentingan setiap fitur dalam proses prediksi. Analisis ini penting untuk memahami faktor-faktor apa yang paling dominan mempengaruhi keputusan model dalam mengklasifikasikan nasabah yang berpotensi *churn*. Visualisasi *feature importance* dari model GBM yang telah dilatih dengan SMOTE disajikan pada Gambar 5.

Gambar 5 Antarmuka sistem

Pada Gambar 5 menyajikan antarmuka input sistem yang dirancang untuk menangkap data nasabah secara komprehensif. Fitur yang wajib diisi mencakup aspek demografis dan finansial seperti *Credit Score*, *Geography*, *Gender*, *Age*, *Balance*, *NumOfProducts*, *HasCrCard*, *IsActiveMember*, dan *Estimated Salary*. Fungsionalitas sistem terbagi menjadi dua opsi utama: tombol 'Predict' untuk mengeksekusi model klasifikasi dan tombol 'Home' untuk kembali ke menu sebelumnya.



Gambar 6 Antarmuka hasil prediksi

Setelah diproses, sistem menampilkan hasil pada Gambar 6 yang meliputi status Prediction (nilai 1 untuk *churn* dan 0 untuk *loyal*) serta Probability Churn. Sebagai contoh, pada Gambar 6 nasabah diprediksi *churn* (Prediction = 1) dengan probabilitas 84.11%, yang berarti model memiliki tingkat keyakinan 84.11%. Pengguna kemudian dapat memilih tombol "Input Lagi" untuk memasukkan data baru atau "Home" untuk kembali ke menu awal.

5 Kesimpulan

Penelitian ini berhasil mengembangkan sistem pendukung keputusan (DSS) berbasis web menggunakan Flask untuk memprediksi *churn* nasabah bank dengan algoritma *Gradient Boosting Machine* (GBM). Penerapan teknik SMOTE terbukti efektif mengatasi ketidakseimbangan data, meningkatkan jumlah sampel kelas minoritas dari 1.630 menjadi 6.370 sehingga model dapat belajar secara lebih adil. Model GBM yang dihasilkan mencapai *accuracy* sebesar 83.95% dan *recall* 67.32% pada kelas *churn*. Analisis *feature importance* menunjukkan bahwa Age (45%) dan *NumOfProducts* (32%) merupakan faktor paling menentukan dalam prediksi *churn*. Secara praktis, aplikasi ini memungkinkan pengguna non-teknis di industri perbankan untuk melakukan prediksi secara *real-time* guna merancang strategi retensi yang lebih proaktif dan berbasis data.

Referensi

- [1] P. P. Singh, F. I. Anik, R. Senapati, A. Sinha, N. Sakib, and E. Hossain, "Investigating Customer Churn in Banking: A Machine Learning Approach and Visualization App for Data Science and Management," *Data SCI. Manag.*, Vol. 7, No. 1, pp. 7–16, 2024, DOI: <https://doi.org/10.1016/j.dsm.2023.09.002>.
- [2] P. Boozary, S. Sheykhani, H. GhorbanTanhaei, and C. Magazzino, "Enhancing Customer Retention with Machine Learning: A Comparative Analysis of Ensemble Models for Accurate Churn Prediction," *Int. J. Inf. Manag. Data Insights*, Vol. 5, No. 1, p. 100331, 2025, DOI: <https://doi.org/10.1016/j.ijime.2025.100331>.
- [3] Y. K. Dwivedi et al., "Artificial Intelligence (AI): Multidisciplinary Perspectives on Emerging Challenges, Opportunities, and Agenda for Research, Practice and Policy," *Int. J. Inf. ManAge.*, Vol. 57, p. 101994, 2021, DOI: <https://doi.org/10.1016/j.ijinfomgt.2019.08.002>.
- [4] A. De Caigny, K. W. De Bock, and S. Verboven, "Hybrid Black-Box Classification for Customer Churn Prediction with Segmented Interpretability Analysis," *Decis. Support Syst.*, Vol. 181, p. 114217, 2024, DOI: <https://doi.org/10.1016/j.dss.2024.114217>.
- [5] S. S. Poudel, S. Pokharel, and M. Timilsina, "Explaining Customer Churn Prediction in Telecom Industry using Tabular Machine Learning Models," *Mach. Learn. with Appl.*, Vol. 17, p. 100567, 2024, DOI: <https://doi.org/10.1016/j.mlwa.2024.100567>.
- [6] R. A. de Lima Lemos, T. C. Silva, and B. M. Tabak, "Propension to Customer Churn in a Financial Institution: A Machine Learning Approach," *Neural Comput. Appl.*, Vol. 34, No. 14, pp. 11751–11768, 2022, DOI: 10.1007/s00521-022-07067-x.

- [7] K. Peng, Y. Peng, and W. Li, "Research on Customer Churn Prediction and Model Interpretability Analysis," *PLoS One*, Vol. 18, No. 12, pp. 1–26, 2023, DOI: 10.1371/journal.pone.0289724.
- [8] M. Imani, M. Joudaki, A. Beikmohammadi, and H. R. Arabnia, "Customer Churn Prediction: A Systematic Review of Recent Advances, Trends, and Challenges in Machine Learning and Deep Learning," *Mach. Learn. Knowl. Extr.*, Vol. 7, No. 3, 2025, DOI: 10.3390/make7030105.
- [9] P. P. Šimović, C. Y. T. Chen, and E. W. Sun, "Classifying the Variety of Customers' Online EngAgement for Churn Prediction with a Mixed-Penalty Logistic Regression," *Comput. Econ.*, Vol. 61, No. 1, pp. 451–485, 2023, DOI: 10.1007/s10614-022-10275-1.
- [10] R. Krishna, D. Jayanthi, D. S. Shylu Sam, K. Kavitha, N. K. Maurya, and T. Benil, "Application of Machine Learning Techniques for Churn Prediction in the Telecom Business," *Results Eng.*, Vol. 24, p. 103165, 2024, DOI: <https://doi.org/10.1016/j.rineng.2024.103165>.
- [11] T. Gattermann-Itschert and U. W. Thonemann, "Proactive Customer Retention Management in a Non-Contractual B2B Setting based on Churn Prediction with Random Forests," *Ind. Mark. Manag.*, Vol. 107, pp. 134–147, 2022, DOI: <https://doi.org/10.1016/j.indmarman.2022.09.023>.
- [12] I. AlShourbaji, N. Helian, Y. Sun, A. G. Hussien, L. Abualigah, and B. Elnaim, "An Efficient Churn Prediction Model using Gradient Boosting Machine and Metaheuristic Optimization," *Sci. Rep.*, Vol. 13, No. 1, p. 14441, 2023, DOI: 10.1038/s41598-023-41093-6.
- [13] Z. Liu, P. Jiang, K. W. De Bock, J. Wang, L. Zhang, and X. Niu, "Extreme Gradient Boosting Trees with Efficient Bayesian Optimization for Profit-Driven Customer Churn Prediction," *Technol. Forecast. Soc. Change*, Vol. 198, p. 122945, 2024, DOI: <https://doi.org/10.1016/j.techfore.2023.122945>.
- [14] I. H. Sugoza, C. Verberi, and S. Yasar, "Machine Learning Approaches to Credit Risk: Evaluating Turkish Participation and Conventional Banks," *Borsa Istanbul Rev.*, Vol. 25, No. 3, pp. 497–512, 2025, DOI: <https://doi.org/10.1016/j.bir.2025.02.001>.
- [15] S. K. Rajput *et al.*, "Forecasting Capacitor Banks for Improving Efficiency of Grid-Integrated PV Plants: A Machine Learning Approach," *Energy Reports*, Vol. 13, pp. 140–160, 2025, DOI: <https://doi.org/10.1016/j.egyr.2024.12.011>.
- [16] M. M. Mariani, I. Machado, V. Magrelli, and Y. K. Dwivedi, "Artificial Intelligence in Innovation Research: A Systematic Review, Conceptual Framework, and Future Research Directions," *Technovation*, Vol. 122, p. 102623, 2023, DOI: <https://doi.org/10.1016/j.technovation.2022.102623>.
- [17] M. I. Reis, J. N. C. Gonçalves, P. Cortez, M. S. Carvalho, and J. M. Fernandes, "A Context-Aware Decision Support System for Selecting Explainable Artificial Intelligence Methods in Business Organizations," *Comput. Ind.*, Vol. 165, p. 104233, 2025, DOI: <https://doi.org/10.1016/j.compind.2024.104233>.
- [18] J. K. Sana, M. S. Rahman, and M. S. Rahman, "Privacy-Preserving Customer Churn Prediction Model in the Context of Telecommunication Industry," *Eng. Appl. Artif. Intell.*, Vol. 162, p. 112514, 2025, DOI: <https://doi.org/10.1016/j.engappai.2025.112514>.
- [19] R. Zhou, Y. Cui, and B. Hu, "Research on MBTI Testing System based on the Combination of Flask Framework and ORM Technology," in *2023 IEEE 3rd International Conference on Data Science and Computer Application (ICDSCA)*, 2023, pp. 1582–1585. DOI: 10.1109/ICDSCA59871.2023.10393033.
- [20] M. EskandariNasab, S. M. Hamdi, and S. Filali Boubrahimi, "FlaPLeT: A Full-Stack Web Platform for End-to-End Time Series Data Processing and Machine Learning in Solar Flare Prediction," *SoftwareX*, Vol. 33, p. 102540, 2026, DOI: <https://doi.org/10.1016/j.softx.2026.102540>.