



**PREDIKSI DAN INTERPRETASI TINGKAT *CHURN* PELANGGAN
DI PT. BPR MAGGA JAYA UTAMA MENGGUNAKAN *EXTREME
GRADIENT BOOSTING* DAN *SHAP* UNTUK MENDUKUNG
PENGAMBILAN KEPUTUSAN**

SKRIPSI

Oleh:

PHIONG MARKUS

20211000002

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI**

UNIVERSITAS BUDDHI DHARMA

TANGERANG

2025



**PREDIKSI DAN INTERPRETASI TINGKAT *CHURN* PELANGGAN
DI PT. BPR MAGGA JAYA UTAMA MENGGUNAKAN *EXTREME
GRADIENT BOOSTING* DAN *SHAP* UNTUK MENDUKUNG
PENGAMBILAN KEPUTUSAN**

SKRIPSI

**Diajukan sebagai salah satu syarat untuk memperoleh Gelar Sarjana pada Program
Studi Teknik Informatika Fakultas Sains dan Teknologi
Universitas Buddhi Dharma
Jenjang Pendidikan Strata 1**

Oleh:

PHIONG MARKUS

20211000002

FAKULTAS SAINS DAN TEKNOLOGI

UNIVERSITAS BUDDHI DHARMA


TANGERANG

2025

LEMBAR PERSEMBAHAN

Dengan mengucap puji syukur kepada Tuhan Yang Maha Esa, SKRIPSI ini kopersambahkan untuk:

1. Keluarga besar Penulis yang telah senantiasa membantu dan memberi dukungan setiap saat.
2. Teman-teman Penulis baik itu teman kuliah seangkatan, adik kelas, kakak kelas pada Fakultas Teknik Informatika Universitas Budhi Dharma, maupun teman-teman dari fakultas dan Universitas Buddhi Dharma, maupun teman-teman dari fakultas dan universitas lain yang telah memberi banyak masukan, semangat dan arahan hingga akhirnya dapat terselesaikan Skripsi ini.
3. Rekan-rekan dari PT. BPR Magga Jaya Utama yang telah selalu memberikan dukungan dan semangat.



LEMBAR PERNYATAAN KEASLIAN SKRIPSI


Yang bertanda tangan di bawah ini.

NIM : 20211000002
Nama : Phiong Markus
Jenjang Studi : Strata 1
Program Studi : Teknik Informatika
Peminatan : *Data Science*

Dengan ini saya menyatakan bahwa:

1. Skripsi ini adalah asli dan belum pernah diajukan untuk mendapatkan gelar akademik Sarjana atau kelengkapan studi, baik di Universitas Buddhi Dharma maupun di Perguruan Tinggi lainnya.
2. Skripsi ini saya buat sendiri tanpa bantuan dari pihak lain, kecuali arahan dosen pembimbing.
3. Dalam Skripsi ini tidak terdapat karya atau pendapat yang telah ditulis atau dipublikasikan orang lain, kecuali secara tertulis dengan jelas dan dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan dicantumkan daftar Pustaka.
4. Dalam Skripsi ini tidak terdapat pemalsuan (kebohongan), seperti buku, artikel, jurnal, data sekunder, pengolahan data, dan pemalsuan tanda tangan dosen atau Ketua Program Studi Universitas Buddhi Dharma yang dibuktikan dengan keasliannya.
5. Lembar pernyataan ini saya buat dengan sesungguhnya, tanpa paksaan dan apabila dikemudian hari atau pada waktu lainnya terdapat penyimpangan dan ketidak beneran dalam pernyataan ini, saya bersedia menerima sanksi akademik berupa pencabutan gelar akademik yang telah saya peroleh karena Skripsi ini serta sanksi lainnya sesuai dengan peraturan dan norma yang berlaku.

Tangerang, 05-08-2025
Yang membuat pernyataan,



Phiong Markus
20211000002

LEMBAR PERSETUJUAN PUBLIKASI KARYA ILMIAH

Yang bertanda tangan di bawah ini.

NIM	: 20211000002
Nama	: Phiong Markus
Jenjang Studi	: Strata 1
Program Studi	: Teknik Informatika
Peminatan	: <i>Data Science</i>

Dengan ini menyetujui untuk memberikan ijin kepada pihak Universitas Buddhi Dharma, Hak Bebas Royalti Non – Eksklusif (*Non-exclusive Royalty-Free Right*) atas karya ilmiah kami yang berjudul “**Prediksi dan Interpretasi Tingkat Churn Pelanggan di PT. BPR Magga Jaya Utama Menggunakan *Extreme Gradient Boosting* dan *SHAP* Untuk Mendukung Pengambilan Keputusan**”.

Dengan Hak Bebas Royalti Non – Eksklusif ini pihak Universitas Buddhi Dharma berhak menyimpan, mengalih-media atau format-kan, mengelolanya dalam pangkalan data (*database*), mendistribusikannya, dan menampilkan atau mempublikasikannya di internet atau media lain untuk kepentingan akademis tanpa perlu meminta ijin dari saya selama tetap mencantumkan nama saya sebagai penulis pertama atau pencipta karya ilmiah tersebut.

Saya bersedia untuk menanggung secara pribadi, tanpa melibatkan pihak Universitas Buddhi Dharma, segala bentuk tuntutan hukum yang timbul atas pelanggaran Hak Cipta dalam karya ilmiah saya ini.

Demikian pernyataan ini saya buat dengan sebenarnya.

Tangerang, 05-08-2025
Yang membuat pernyataan,



Phiong Markus
20211000002

LEMBAR PENGESAHAN PEMBIMBING
PREDIKSI DAN INTERPRETASI TINGKAT *CHURN* PELANGGAN
DI PT. BPR MAGGA JAYA UTAMA MENGGUNAKAN *EXTREME*
***GRADIENT BOOSTING* DAN *SHAP* UNTUK Mendukung**
PENGAMBILAN KEPUTUSAN

Dibuat Oleh:

NIM : 20211000002

Nama : Phiong Markus

Telah disetujui untuk dipertahankan di hadapan Tim Penguji Ujian

Komprehensif

Program Studi Teknik Informatika

Peminatan *Data Science*

Tahun Akademik 2024/2025

Disahkan oleh,

Tangerang, 05-08-2025

Pembimbing,



(Indah Fenriana, S.Kom.,M.Kom)

NUPTK. 6538766667230262

LEMBAR PENGESAHAN SKRIPSI
PREDIKSI DAN INTERPRETASI TINGKAT *CHURN* PELANGGAN
DI PT. BPR MAGGA JAYA UTAMA MENGGUNAKAN *EXTREME*
***GRADIENT BOOSTING* DAN *SHAP* UNTUK Mendukung**
PENGAMBILAN KEPUTUSAN

Dibuat Oleh:

NIM : 20211000002

Nama : Phiong Markus

Telah disetujui untuk dipertahankan di hadapan Tim Penguji Ujian

Komprehensif

Program Studi Teknik Informatika

Peminatan *Data Science*

Tahun Akademik 2024/2025

Disahkan oleh,

Tangerang, 05-08-2025

Dekan,

Ketua Program Studi,



Dr Yakub, M.Kom.,M.M.

NUPTK. 1836747648130172




Hartana Wijaya, S.Kom., M.Kom

NUPTK. 3844759660131192

LEMBAR PENGESAHAN TIM PENGUJI

Nama : Phiong Markus
NIM : 20211000002
Fakultas : Sains dan Teknologi
Judul Skripsi : Prediksi dan Interpretasi Tingkat *Churn* Pelanggan di PT. BPR Magga Jaya
Utama Menggunakan *Extreme Gradient Boosting* dan *SHAP* Untuk
Mendukung Pengambilan Keputusan.

Dinyatakan LULUS setelah mempertahankan di depan Tim Penguji pada hari Selasa, 05-08-2025.

	Nama penguji :	Tanda Tangan :
Ketua Penguji :	Edy, ST., M.Kom NUPTK. 7560760661130203	
Penguji I :	Hartana Wijaya, M.Kom NUPTK. 3844759660131192	
Penguji II :	Indah Fenriana, S.Kom., M.Kom NUPTK. 6538766667230262	

Mengetahui,
Dekan Fakultas Sains dan Teknologi


Dr. Yakub, M.Kom., M.M.

NUPTK. 1836747648130172

KATA PENGANTAR

Dengan mengucapkan Puji Syukur kepada Tuhan Yang Maha Esa yang telah memberikan Rahmat dan karunia-Nya kepada penulis sehingga dapat menyusun dan menyelesaikan Skripsi ini dengan judul **Prediksi dan Interpretasi Tingkat Churn Pelanggan di PT. BPR Magga Jaya Utama Menggunakan *Extreme Gradient Boosting* dan SHAP Untuk Mendukung Pengambilan Keputusan**. Tujuan utama dari pembuatan Skripsi ini adalah sebagai salah satu syarat kelengkapan dalam program pendidikan Strata 1 Program Studi Teknik Informatika di Universitas Buddhi Dharma. Dalam penyusunan Skripsi ini penulis banyak menerima bantuan dan dorongan baik moril maupun materiil dari berbagai pihak, maka pada kesempatan ini penulis menyampaikan rasa terima kasih yang sebesar-besarnya kepada:

1. Ibu Dr. Limajatini, S.E., M.M., B.K.P. , sebagai Rektor Universitas Buddhi Dharma
2. Bapak Dr. Yakub, M.Kom., M.M. sebagai Dekan Fakultas Sains dan Teknologi
3. Bapak Hartana Wijaya, S.Kom., M.Kom. sebagai Ketua Program Studi Teknik Informatika
4. Ibu Indah Fenriana, S.Kom., M.Kom. sebagai pembimbing yang telah membantu dan memberikan dukungan serta harapan untuk menyelesaikan penulisan Skripsi ini.
5. Orang tua dan keluarga yang selalu memberikan dukungan baik moril dan materiil. Teman-teman yang selalu membantu dan memberikan semangat

Serta semua pihak yang terlalu banyak untuk disebutkan satu-persatu sehingga terwujudnya penulisan ini. Penulis menyadari bahwa penulisan Skripsi ini masih belum sempurna, untuk itu penulis mohon kritik dan saran yang bersifat membangun demi kesempurnaan penulisan di masa yang akan datang. Akhir kata semoga Skripsi ini dapat berguna bagi penulis khususnya dan bagi para pembaca yang berminat pada umumnya.

Tangerang, 05-08-2025

Penulis

Prediksi dan Interpretasi Tingkat Churn Pelanggan di PT. BPR Magga Jaya Utama Menggunakan Extreme Gradient Boosting dan SHAP Untuk Mendukung Pengambilan Keputusan

104 Halaman + xviii/ 10 Tabel / 24 Gambar / 4 Lampiran

ABSTRAK

Customer churn adalah penurunan persentase pelanggan dalam suatu industri yang terjadi dalam jangka waktu tertentu dan dapat memengaruhi pertumbuhan bisnis. Dalam industri perbankan, inovasi pada pelayanan, fasilitas, dan kepuasan nasabah menjadi kunci untuk mempertahankan loyalitas di tengah persaingan yang ketat. Salah satu permasalahan utama adalah berhentinya nasabah menggunakan layanan bank (*churn*). Penelitian ini bertujuan membangun sistem prediksi churn menggunakan algoritma *Extreme Gradient Boosting* (XGBoost) dan menginterpretasikan hasil prediksi dengan metode *Shapley Additive Explanations* (SHAP) guna mendukung pengambilan keputusan strategis di PT. BPR Magga Jaya Utama. Data penelitian terdiri dari 54.213 sampel nasabah dengan 13 atribut utama, diproses melalui tahapan pra-pemrosesan, penyeimbangan data menggunakan *SMOTE*, pelatihan model, dan evaluasi. Hasil penelitian menunjukkan bahwa model XGBoost mencapai akurasi 88%, dengan nilai *precision* 0,88, *recall* 0,88, dan *f1-score* 0,88. Interpretasi menggunakan SHAP berhasil mengidentifikasi kontribusi setiap fitur secara transparan terhadap prediksi churn. Sistem prediksi ini diimplementasikan pada platform berbasis *web*, memudahkan manajemen dalam melakukan analisis dan intervensi tepat sasaran. Dengan sistem ini, PT. BPR Magga Jaya Utama berpotensi meningkatkan retensi nasabah dan mengurangi tingkat *churn* secara signifikan.

Kata Kunci : *Churn, Machine Learning, Perbankan, SHAP, XGBoost*

ABSTRACT

Customer churn refers to the decline in the percentage of customers within an industry over a certain period, which can affect business growth. In the banking industry, innovations in services, facilities, and customer satisfaction are essential to maintaining loyalty in the face of intense competition. One of the main challenges is customer churn, where customers stop using banking services. This study aims to develop a churn prediction system using the Extreme Gradient Boosting (XGBoost) algorithm and to interpret the predictions with the Shapley Additive Explanations (SHAP) method to support strategic decision-making at PT. BPR Magga Jaya Utama. The dataset consists of 54,213 customer samples with 13 main attributes, processed through data preprocessing, balancing with SMOTE, model training, and performance evaluation. The results show that the XGBoost model achieved 88% accuracy, with precision of 0.88, recall of 0.88, and f1-score of 0.88. The SHAP method successfully identified the contribution of each feature to churn prediction in a transparent manner. The prediction system was implemented on a web-based platform, enabling management to conduct analysis and targeted interventions more effectively. With this system, PT. BPR Magga Jaya Utama has the potential to improve customer retention and significantly reduce churn rates.

Keyword : Churn, Banking, Machine Learning, SHAP, XGBoost

DAFTAR ISI

LEMBAR PERSEMBAHAN	i
LEMBAR PERNYATAAN KEASLIAN SKRIPSI.....	ii
LEMBAR PERSETUJUAN PUBLIKASI KARYA ILMIAH	iii
LEMBAR PENGESAHAN PEMBIMBING	iv
LEMBAR PENGESAHAN SKRIPSI	v
LEMBAR PENGESAHAN TIM PENGUJI	vi
KATA PENGANTAR.....	vii
ABSTRAK.....	viii
ABSTRACT	ix
DAFTAR ISI	x
DAFTAR TABEL	xv
DAFTAR GAMBAR.....	xvi
DAFTAR LAMPIRAN	xvii
BAB I PENDAHULUAN	1
1.1 Latar Belakang Masalah	1
1.2 Identifikasi Masalah.....	3
1.3 Ruang Lingkup Penelitian.....	4
1.4 Tujuan dan Manfaat Penelitian	4
1.4.1 Tujuan penelitian.....	4
1.4.2 Manfaat penelitian.....	5
1.5 Sistematika Penulisan	5
BAB II LANDASAN TEORI.....	8
2.1 Bank	8
2.2 <i>Machine Learning</i>	8
2.3 <i>Artificial Intelligence</i>	8
2.4 <i>Pyhton</i>	9

2.5	<i>Django</i>	9
2.6	<i>Customer Churn</i>	10
2.7	<i>Metode Extreme Gradient Boosting (XGBoost)</i>	10
2.8	<i>Synthetic Minority Oversampling Technique (SMOTE)</i>	13
2.9	<i>shapley additive explanations (SHAP)</i>	13
2.10	<i>Unified Modeling Language</i>	14
2.11	<i>Entity Relationship Diagram</i>	17
2.12	<i>Website</i>	18
2.13	<i>MYSQL</i>	18
2.14	<i>Blackbox Testing</i>	19
2.15	<i>Tinjauan Studi</i>	19
2.15.1	Penelitian dibuat oleh Qi Tang, Guoen Xia, Xianquan Zhang, Feng Long dengan judul " <i>A customer churn prediction model based on XGBoost and MLP</i> "	19
2.15.2	Penelitian dibuat oleh Suwarno, Ryo Kusnadi dengan judul " <i>Analisis Perbandingan SVM, XGBoost dan Neural Network pada Klasifikasi Ujaran Kebencian</i> ".	20
2.15.3	Penelitian dibuat oleh Jhiro Faran, Agung Triayudi dengan judul " <i>Analysis of the Effectiveness of Polynomial Fit SMOTE Mesh on Imbalance Dataset for Bank Customer Churn Prediction with XGBOOST and BAYESIAN OPTIMIZATION</i> "	20
2.15.4	Penelitian dibuat oleh Hiya Nalatissifa, Hilman Ferdinandus Pardede dengan judul " <i>Customer Decision Prediction Using Deep Neural Network on Telco Customer Churn Data</i> ".	21
2.15.5	Penelitian dibuat oleh Khaerul Anam, Ade Rizki Rinaldi, Fathurrohman dengan judul " <i>Komparasi Algoritma Machine Learning dalam Klasifikasi Loyalitas Nasabah Bank Berbasis Particle Swarm Optimization</i> "	21
2.15.6	Penelitian dibuat oleh Amir Mahmud Husein, Mawaddah Harahap, Piter Fernandito dengan judul " <i>Pendekatan Data Science untuk Menemukan Churn Pelanggan pada Sector Perbankan dengan Machine Learning</i> "	22

2.15.7	Penelitian dibuat oleh Miryam Clementine Aksama, Arum Wahyuniati dengan judul " <i>Prediksi Churn Nasabah Bank Menggunakan Klasifikasi Naïve Bayes dan ID3</i> ".	22
2.15.8	Penelitian dibuat oleh Mohammad Amirulhaq Iskandar, Ulinnuha Latifa dengan judul " <i>Website Prediksi Customer Churn Untuk Mempertahankan Pelanggan pada Perusahaan Telekomunikasi</i> ".	23
2.15.9	Penelitian dibuat oleh Praveen Lalwani, Manas Kumar Mishra, Jasroop Singh Chadha, dan Pratyush Sethi dengan judul " <i>Customer Churn Prediction System: A Machine Learning Approach</i> ".	23
2.15.10	Penelitian dibuat oleh B. Prabadevi, R. Shalini, dan B.R. Kavitha dengan judul " <i>Customer Churning Analysis Using Machine Learning Algorithms</i> ".	24
2.15.11	Penelitian dibuat oleh Pahul Preet Singh, Fahim Islam Anik, Rahul Senapati, Arnav Sinha, Nazmus Sakib, dan Eklas Hossain dengan judul " <i>Investigating Customer Churn in Banking: A Machine Learning Approach</i> ".	24
2.15.12	Penelitian dibuat oleh Pranshu Kumar Soni dan Leema Nelson dengan judul " <i>Profit-Driven Churn Prediction using Machine Learning Techniques in Banking Sector</i> ".	25
2.15.13	Penelitian dibuat oleh Pallabi Baruah dan Bhairab Sarma dengan judul " <i>Predictive Analysis on Churn Customers in Business Industries Using Supervised Machine Learning Algorithms and SMOTE</i> ".	25
2.15.14	Penelitian dibuat oleh Muhammad Maulana Sidiq dan Dyah Anggraini dengan judul " <i>Analysis and Classification of Customer Churn Using Machine Learning</i> ".	26
2.15.15	Penelitian dilakukan oleh Adlina Khairunnisa dengan judul " <i>Perbandingan Model Random Forest dan XGBoost untuk Prediksi Kejahatan Kesusilaan di Provinsi Jawa Barat</i> ".	26
BAB III METODOLOGI PENELITIAN		28
3.1	Tinjauan Umum Perusahaan	28
3.1.1	Sejarah singkat	28
3.1.2	Visi, Misi dan Tujuan	30


3.1.3	Struktur Organisasi.....	31
3.2	Identifikasi Kebutuhan.....	50
3.2.1	Identifikasi Kebutuhan Fungsional Sistem	51
3.3	Pembahasan Metode Yang Digunakan	52
3.4	Pembahasan Algoritma Yang Digunakan.....	56
3.5	Kerangka Pemikiran.....	71
3.6	Perancangan UML	73
3.6.1	<i>Activity Diagram</i>	74
3.7	Implementasi Antarmuka dan perancangan <i>Database</i>	75
3.7.1	Implementasi Antarmuka	75
3.7.2	Perancangan <i>Database</i> menggunakan.....	78
3.8	Jadwal Penelitian	79
BAB IV HASIL DAN PEMBAHASAN.....		81
4.1	Identifikasi Kebutuhan Non Fungsional Sistem	81
4.2	Tampilan Program dan Alat.....	82
4.2.1	Tampilan Halaman <i>Login</i>	82
4.2.2	Tampilan Halaman <i>Home</i>	82
4.2.3	Tampilan Halaman Tambah Data.....	83
4.2.4	Tampilan Halaman <i>Details</i>	84
4.2.5	Tampilan Halaman <i>Actions</i>	85
4.3	Penerapan Metode dan Algoritma	87
4.4	<i>Black Box Testing</i>	88
4.5	Evaluasi Model	89
4.6	<i>User Acceptance Testing (UAT)</i>	92
BAB V SIMPULAN DAN SARAN		95
5.1	Simpulan	95
5.2	Saran	96

DAFTAR PUSTAKA.....	98
LAMPIRAN	101



DAFTAR TABEL

Tabel 2.1 Notasi <i>Use Case</i>	15
Tabel 2.2 Notasi <i>Activity Diagram</i>	16
Tabel 3.1 Kebutuhan Pengguna	51
Tabel 3.2 Kebutuhan Fungsional	51
Tabel 3.3 <i>churn prediction</i>	65
Tabel 4.1 Hasil <i>Blackbox Testing</i>	88
Tabel 4.2 Hasil Evaluasi Model XGBoost	90
Tabel 4.3 Hasil <i>User Acceptance Testing</i>	93



DAFTAR GAMBAR

Gambar 3.1 Struktur Organisasi PT Magga Jaya Utama.....	31
Gambar 3.2 <i>Learning Curve</i>	59
Gambar 3.3 Diagram Pohon Keputusan (<i>yes</i>)	60
Gambar 3.4 Diagram Pohon Keputusan (<i>no,missing</i>)	61
Gambar 3.5 Grafik <i>Churn Prediction</i>	67
Gambar 3.6 <i>Summary SHAP</i>	68
Gambar 3.7 Laporan Klasifikasi.....	69
Gambar 3.8 Diagram Kerangka pemikiran.....	71
Gambar 3.9 <i>Use Case Diagram</i>	73
Gambar 3.10 <i>Activity Diagram Login</i>	74
Gambar 3.11 <i>Activity Diagram Prediksi Churn</i>	75
Gambar 3.12 Rancangan halaman <i>Home</i>	76
Gambar 3.13 Rancangan halaman <i>Details</i>	76
Gambar 3.14 Rancangan halaman <i>Actions</i>	77
Gambar 3.15 Rancangan halaman <i>Login</i>	77
Gambar 3.16 Perancangan <i>Database</i>	79
Gambar 3.17 <i>Gantt Chart</i>	80
Gambar 4.1 Halaman <i>Login</i>	82
Gambar 4.2 Halaman <i>Home</i>	83
Gambar 4.3 Halaman Tambah Data	84
Gambar 4.4 Halaman <i>Details</i>	85
Gambar 4.5 Halaman <i>Actions</i>	86
Gambar 4.6 <i>Confusion Matrix</i>	91
Gambar 4.7 Kurva <i>ROC Curve – One-vs-Rest</i>	92

DAFTAR LAMPIRAN

Lampiran 1 <i>Requirement Elicitation</i>	101
Lampiran 2 Surat Permohonan Penelitian	102
Lampiran 3 Kartu Bimbingan.....	103
Lampiran 4 Daftar Riwayat Hidup	104



BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Bank adalah Lembaga pengelolaan keuangan yang dimana menghimpun dana masyarakat dan mendistribusikan dana yang dikelola dalam bentuk pinjaman untuk keperluan ekonomi nasabah. Layanan keuangan yang diberikan bank kepada nasabah baik individu, perusahaan, dan institusi yaitu dalam bentuk simpanan atau tabungan, kredit, deposito, aplikasi perbankan, dan layanan lainnya. Dalam *industry* perbankan, mempertahankan pelanggan menjadi salah satu tantangan utama di tengah persaingan yang semakin ketat. Pelanggan yang berhenti menggunakan layanan bank, baik dalam bentuk kredit, tabungan, maupun produk perbankan lainnya, sering kali dipicu oleh berbagai faktor seperti ketidakpuasan layanan, penawaran yang lebih menarik dari kompetitor, hingga perubahan kebutuhan finansial pelanggan.

Kemajuan teknologi yang memudahkan nasabah lebih mudah untuk berpindah layanan, *system* layanan perbankan bisa menjadi faktor kehilangannya pelanggan tanpa memiliki fitur yang lengkap serta waktu yang dibutuhkan dalam proses transaksi antar bank maupun sesama bank dilakukan secara *real – time* dan cepat (Husein & Harahap, 2021). Pendekatan yang efektif dalam menangani permasalahan *churn* adalah dengan menggunakan teknologi prediksi berbasis data, di mana bank dapat mengidentifikasi pelanggan yang berpotensi berhenti, sebelum mereka benar-benar melakukan *churn*.

Keberhasilan suatu bisnis adalah mampu mendapatkan nasabah baru dan mempertahankan nasabah lama untuk menjadi loyalitas terhadap bank (Singh et al., 2024). Dengan membuat suatu layanan khusus untuk pelanggan lama serta memberikan *strategy* bisnis terbaru untuk nasabah baru, menjadikan pemantauan keefektifan suatu

strategy loyalitas yang diterapkan kepada seluruh nasabah bank. Sebagai hasilnya, muncul banyak peluang pemasaran baru akibat perkembangan dalam interaksi antara pelanggan dan perusahaan. Di samping itu, sebagian besar strategi Marketing fokus pada mempertahankan pelanggan (Soni & Nelson, 2023).

Sistem prediksi tingkat *churn* memungkinkan bank mengantisipasi lebih cepat dengan memanfaatkan data historis pelanggan, seperti riwayat transaksi, interaksi, serta pola perilaku lainnya, untuk mendeteksi tanda-tanda *churn* (Nalatissifa & Pardede, 2021). Dengan teknologi seperti *machine learning*, khususnya metode seperti *Extreme Gradient Boosting* (XGBoost), bank dapat memprediksi pelanggan yang berpotensi *churn* secara lebih akurat. Metode XGBoost merupakan implementasi canggih dari metode *gradient boosting* berbasis *decision tree*. Mampu menghasilkan model yang dapat diandalkan dalam masalah klasifikasi dan regresi (Liang, 2021). Penerapan sistem pengelolaan data kategorikal dan numerical, serta XGBoost menerapkan metode *ensemble learning*, yaitu dengan menggabungkan prediksi dari beberapa model untuk menghasilkan keputusan prediksi yang lebih akurat (Faran & Triayudi, 2024).

Dalam konteks ini, pendekatan *Shapley Additive Explanations* (SHAP) menjadi sangat penting sebagai teknik interpretasi model *machine learning* yang bersifat *blackbox* atau sulit dipahami secara langsung (Syamkalla et al., 2024). SHAP berlandaskan pada konsep nilai *Shapley* dari teori permainan kooperatif, yang secara matematis menghitung kontribusi adil dari setiap fitur input terhadap hasil prediksi model. Dengan memberikan nilai kontribusi (*shapley value*) pada setiap fitur, SHAP mampu menunjukkan seberapa besar pengaruh fitur tersebut dalam menentukan *output* model, baik pada tingkat prediksi individual maupun secara keseluruhan (Baruah & Sarma, 2024). Pendekatan ini sangat krusial dalam aplikasi bisnis seperti sistem prediksi *churn* di sektor perbankan, di mana transparansi dan kepercayaan terhadap hasil model menjadi aspek yang sangat penting.

Dengan SHAP, para *management* dan pengambil keputusan dapat memahami alasan di balik prediksi yang dihasilkan oleh model *machine learning*, sehingga interpretasi menjadi lebih akurat dan hasil interpretasi menjadi lebih tepat, sehingga proses pengambilan keputusan dapat dilakukan secara lebih akurat dan bertanggung jawab. Dengan informasi prediksi yang tepat, PT. BPR Magga Jaya Utama dapat membuat strategi untuk mempertahankan kepuasan nasabah dan menargetkan pelanggan yang memiliki potensi *churn* tinggi sebelum mereka benar-benar berpindah ke kompetitor.

Penelitian ini menjadi penting karena di era digitalisasi ini, pengelolaan hubungan pelanggan menjadi kunci yang penting dan efisien dalam keberhasilan perusahaan perbankan. Dengan menerapkan analisis *churn* yang didukung teknologi canggih, diharapkan PT. BPR Magga Jaya Utama dapat meningkatkan loyalitas pelanggan dan mengurangi tingkat *churn* secara signifikan.

1.2 Identifikasi Masalah

Permasalahan yang didapatkan dari indentifikasi yaitu:

- a) Tidak dapat memprediksi jumlah nasabah yang berpotensi *churn*.
- b) Belum terdapat teknologi yang mendukung dalam melakukan prediksi.
- c) Tidak dapat memberikan solusi yang tepat kepada nasabah dalam upaya mempertahankan pelanggan.

1.3 Ruang Lingkup Penelitian

Mengacu pada latar belakang tersebut, rumusan penelitian ini dirumuskan sebagai berikut:

- a) Bagaimana kinerja *Extreme Gradient Boosting* dalam memprediksi tingkat *churn* dan *Shapley Additive Explanations* dalam pengambilan keputusan pelanggan di PT Magga Jaya Utama.
- b) Seberapa akurat model prediksi *churn* yang dapat dihasilkan dalam mengidentifikasi nasabah yang berpotensi berhenti menggunakan layanan perbankan di PT Magga Jaya Utama.
- c) Data internal yang diperoleh dari perusahaan PT. BPR Magga Jaya Utama dimana diambil sampling yang digunakan yaitu tahun 2022 sampai dengan 2024 yang digunakan sebagai kinerja *Extreme Gradient Boosting* dalam memprediksi tingkat *churn*.
- d) Dataset terdiri dari 54.213 sampel dari 13 atribut terdiri dari nomor rekening, nama, alamat, jenis kelamin, pendapatan, saldo tabungan, lokasi usaha, rata-rata transaksi, status perkawinan, masa bekerja, sumber dana, plafond, dan kolektibilitas.

1.4 Tujuan dan Manfaat Penelitian

1.4.1 Tujuan penelitian

- a) Mengevaluasi tingkat keakuratan dan ketepatan waktu dalam tindakan pencegahan yang tepat kepada nasabah sebelum nasabah melakukan proses pemberhentian layanan perbankan.

- b) Mengidentifikasi potensi yang mempengaruhi *churn* pada pelanggan di PT. BPR Magga Jaya Utama
- c) Membangun model prediksi *churn* menggunakan metode *Extreme Gradient Boosting* untuk mengidentifikasi pelanggan yang berpotensi berhenti menggunakan layanan perbankan.

1.4.2 Manfaat penelitian

- a) Mengoptimalkan Tindakan preventif untuk meningkatkan kepercayaan dan loyalitas nasabah, sehingga dapat dilakukan penanganan yang tepat waktu untuk meminimalisir kehilangan nasabah.
- b) Meningkatkan relasi bank dengan nasabah dalam hal wawasan perilaku dan preferensi nasabah yang lebih terarah dan efektif.
- c) Penerapan untuk mendeteksi nasabah yang berpotensi *churn* dalam pengelolaan nasabah untuk mempertahankan nasabah dari persaingan di industri perbankan.

1.5 Sistematika Penulisan

Struktur penulisan disusun dalam bentuk beberapa Bab dan Sub bab untuk dapat dipahami dengan baik dan mengikuti kaidah penulisan ilmiah yang berlaku, berikut penjelasan secara singkat setiap bab dari karya ilmiah ini.

BAB I PENDAHULUAN

Penjelasan awal menjelaskan tentang topik gambaran umum yang dibahas dalam penelitian ini. Bagian ini diawali dengan latar belakang masalah dan memaparkan fenomena yang melatar belakangi sehingga memerlukan kajian ini. Selanjutnya disajikan rumusan masalah, yaitu pertanyaan pokok pada penelitian ini yang menjadi focus untuk dijawab.

Tujuan penelitian yaitu menggambarkan hasil yang ingin diperoleh melalui pelaksanaan penelitian ini, serta menjelaskan batasan masalah dan memperjelas ruang lingkup penelitian agar tidak melampaui ruang lingkup yang diperlukan. Utilitas Penelitian menyajikan manfaat teoretis dan praktis dari hasil penelitian baik bagi pengembangan ilmu pengetahuan maupun pemangku kepentingan. Bab ini diakhiri dengan penjelasan sistematika penulisan yang menjelaskan struktur penulisan disertasi secara keseluruhan.

BAB II LANDASAN TEORI

Teori dasar yang mendukung penelitian yang memiliki relevansi dengan fokus kajian penelitian ini, yang dijadikan pembahasan kontribusi penelitian ini terhadap bidang ilmu terkait dan ruang yang ingin dipenuhi oleh penelitian ini. Bab ini menyajikan kerangka berpikir, yaitu alur logika yang merangkum hubungan antar variabel yang diteliti berdasarkan teori yang telah diulas, sehingga memandu arah penelitian.

BAB III METODOLOGI PENELITIAN

Bab ini menjelaskan profil umum perusahaan yang menjadi objek penelitian, termasuk sejarah singkat, visi, misi, tujuan, dan struktur organisasi. Selanjutnya diuraikan identifikasi kebutuhan sistem, baik kebutuhan umum maupun kebutuhan fungsional. Bab ini juga membahas metode penelitian yang digunakan, algoritma yang dipilih beserta alasan penggunaannya, serta kerangka pemikiran penelitian. Bagian perancangan sistem mencakup pembuatan UML, *activity diagram*, rancangan antarmuka, dan perancangan *database*. Selain itu, dijelaskan pula implementasi sistem yang meliputi implementasi antarmuka dan implementasi *database*. Bab ini diakhiri dengan penyajian jadwal penelitian dalam bentuk tabel atau diagram Gantt.

BAB IV HASIL DAN PEMBAHASAN

Bab ini menjelaskan proses implementasi rancangan menjadi sistem yang dapat berjalan, meliputi implementasi antarmuka, penerapan basis data, dan integrasi sistem secara keseluruhan. Disajikan juga hasil pengujian sistem untuk memastikan kesesuaian dengan kebutuhan yang telah diidentifikasi sebelumnya.

BAB V SIMPULAN DAN SARAN

Bagian terakhir menampilkan hasil penelitian dan kesimpulan, serta rekomendasi untuk penelitian tambahan dan perancangan model yang lebih akurat.



BAB II

LANDASAN TEORI

2.1 Bank

Menurut UU No. 7 Tahun 1992 yang kemudian diperbarui dengan UU No. 10 Tahun 1998, bank konvensional didefinisikan sebagai suatu badan usaha yang menghimpun dana dari masyarakat melalui penyaluran kredit maupun bentuk-bentuk lainnya untuk meningkatkan kesejahteraan banyak orang. Di sisi lain, bank digital adalah pilihan layanan keuangan berbasis teknologi digital atau tanpa kertas. Nasabah mendapatkan berbagai kemudahan dalam melakukan kegiatan ekonomi, bisnis, serta mengakses gaya hidup yang telah menyesuaikan dengan perkembangan teknologi. Oleh karena itu, penerapan transformasi teknologi informasi dalam sistem perbankan menjadi keharusan dan merupakan salah satu kekuatan utama perusahaan.

2.2 Machine Learning

Machine Learning adalah studi tentang algoritma untuk memahami dan berfikir untuk melakukan tugas - tugas tertentu yang biasanya dilakukan oleh manusia dapat dilakukan secara otomatis. Mempelajari pada data yang dimiliki untuk melaksanakan kegiatan umum yang dilakukan dan menarik kesimpulan baru dan tepat berdasarkan pola-pola yang telah diamati sebelumnya (Amirulhaq Iskandar et al., 2023).

2.3 Artificial Intelligence

Artificial Intelligence (AI) adalah cabang ilmu komputer yang berfokus pada pembuatan sistem dan mesin yang mampu melakukan tugas yang biasanya membutuhkan kecerdasan manusia. Proses ini melibatkan penerapan model matematis dan algoritma guna

memungkinkan sistem komputer mempelajari data, mengidentifikasi pola, serta menghasilkan keputusan secara cerdas (Eriana et al., 2023).

Beberapa konsep penting dalam lingkup kecerdasan buatan termasuk pembelajaran mesin, jaringan saraf (jaringan saraf tiruan), pemrosesan bahasa alami dan banyak lagi. Kecerdasan buatan sangat berdampak pada banyak bidang, termasuk pengobatan, pengenalan suara, pengenalan wajah, dan mobil otonom (Eriana et al., 2023).

2.4 *Python*

Python adalah pemrograman dengan bahasa yang bersifat interpretatif, *responsive* terhadap pengguna, dan berorientasi objek. Bahasa ini mengintegrasikan modul, penanganan pengecualian, pengetikan dinamis, jenis data tingkat tinggi yang dinamis, serta dukungan untuk *class*. Selain pemrograman berorientasi objek, *Python* juga mendukung paradigma pemrograman lain, seperti prosedural dan fungsional. (Python Software Foundation, 2023). *Python* memiliki beragam *library machine learning* open source yang sangat luas, termasuk, namun tidak terbatas pada, beberapa berikut: *Pandas*, yang memberikan kemampuan untuk menangani dataset besar dengan menyediakan alat untuk membaca, menulis, membersihkan, dan mengubah data; *Numpy (Numerical Python)*, yang menawarkan kemampuan komputasi *array* yang kuat untuk menangani perhitungan matematis besar menggunakan *array* multi-dimensi, serta mengatasi masalah kecepatan perhitungan; dan *Scipy*, yang digunakan untuk komputasi ilmiah dan teknis, memanfaatkan *array* multi-dimensi dari *Numpy* untuk mendukung perhitungan yang lebih kompleks (Silaparasetty, 2020a).

2.5 *Django*

Django merupakan kerangka kerja *website* tingkat lanjut berbasis *Python* yang dirancang untuk mempermudah pembangunan aplikasi *website* secara cepat, aman, dan

terorganisir. *Framework* ini menerapkan pola arsitektur *Model*, *View*, dan *Template* (MVT). (D Saputra, 2022). Django memungkinkan proses perancangan *website* menjadi lebih efisien serta terorganisir selaras dengan struktur data yang sudah ditetapkan (Irwan et al., 2022).

2.6 *Customer Churn*

Churn suatu istilah yang menggambarkan berhentinya nasabah menggunakan produk atau layanan pada suatu perusahaan dan memutuskan berpindah layanan ke perusahaan lainnya. *Churn* merupakan masalah penting karena dapat berdampak besar pada perusahaan karena dapat menunjukkan tingkat kepuasan pelanggan, kualitas dan efektivitas layanan pelanggan, dan kekuatan persaingan dalam pasar (Miryam Clementine & Arum, 2022).

Nasabah bank memiliki kriteria pemilihan bank yang disukai, maka bank harus mampu mengevaluasi layanan yang diberikan. Menambah nasabah baru menjadi opsi untuk menaikkan *Casa* (*Current Account Savings Account*) bank namun akan memakan lebih banyak biaya sedangkan mempertahankan nasabah yang sudah ada lebih efisien secara biaya (Miryam Clementine & Arum, 2022).

2.7 Metode *Extreme Gradient Boosting* (XGBoost)

Suatu metode pembelajaran mesin yang skalabel dan terdistribusi pada *Gradient - Boosted Decision Tree* (GBDT) yang menawarkan *boosting* an pohon secara parallel. Dimana setiap pohon mencoba untuk memperbaiki kesalahan untuk mendapatkan regresi, klasifikasi, dan perangkingan masalah (Alotaibi & Haq, 2024) Berikut rumus XGBoost.

$$L^t = \sum_{i=1}^m l\left(y_i, \text{pred}_i^{(t-1)} + f_t(x_i)\right) + \Omega(f_t)$$

Dimana:

L^t = total fungsi kehilangan pada iterasi ke-t.

$\text{pred}_i^{(t-1)}$ = prediksi dari iterasi sebelumnya (iterasi ke-t -1).

$f_t(x_i)$ = nilai residu atau kesalahan yang belum dijelaskan dari iterasi-t.

$\Omega(f_t)$ = regulasi, yang mengendalikan kompleksitas model untuk mencegah *overfitting*.

Adapun istilah Regulasi:

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda ||w||^2$$

Dimana:

$\Omega(f)$ = regulasi model.

T = jumlah daun dalam pohon pada iterasi ke-t.

γ = parameter yang mengontrol jumlah daun, mencegah pohon menjadi terlalu besar.

λ = parameter yang mengontrol regulasi pada bobot, mencegah bobot menjadi terlalu besar dan menghindari *overfitting*.

Adapun Taylor Orde kedua untuk fungsi kehilangan:

$$L^t \approx \sum_{i=1}^m \left(g_i f_i(x_i) + \frac{1}{2} h_i f_t^2(x_i) \right) + \Omega(f_t)$$

$L^t \approx$ = pendekatan fungsi kehilangan pada iterasi ke-t menggunakan deret taylor.

g_i = turunan pertama (*gradien*) dari fungsi kehilangan pada prediksi sebelumnya, yang menunjukkan arah perbaikan.

h_i = turunan kedua (*hessian*) dari fungsi kehilangan, memberikan informasi lebih untuk optimisasi yang lebih akurat.

Adapun bobot optimal daun:

$$w_j^* = - \frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda}$$

w_j^* = bobot optimal untuk daun j, memberikan kontribusi terbaik dalam mengurangi kesalahan.

I_j = himpunan data yang masuk ke dalam daun j.

$\sum_{i \in I_j} g_i$ = jumlah gradien pertama dari data dalam daun j, yang menunjukkan seberapa banyak kesalahan yang harus diperbaiki.

$\sum_{i \in I_j} h_i + \lambda$ = regularisasi yang mempertimbangkan kompleksitas pohon dan bobot untuk mencegah *overfitting*.

Dan terakhir Gain untuk *Split* Kandidat:

$$L_{split} = \frac{1}{2} \left(\frac{(\sum_{i \in I_L} g_i)^2}{\sum_{i \in I_L} h_i + \lambda} + \frac{(\sum_{i \in I_R} g_i)^2}{\sum_{i \in I_R} h_i + \lambda} - \frac{(\sum_{i \in I} g_i)^2}{\sum_{i \in I} h_i + \lambda} \right) - \lambda$$

L_{split} = nilai gain untuk *split*, menunjukkan seberapa baik split tersebut dalam mengurangi kesalahan.

I_L dan I_R = subset data yang masuk ke masing – masing cabang (kiri dan kanan) setelah split.

$\sum_{i \in I_L} g_i$ dan $\sum_{i \in I_R} g_i$ = jumlah gradien dari data yang masuk ke cabang kiri dan kanan.

$\sum_{i \in I_L} h_i + \lambda$ dan $\sum_{i \in I_R} h_i + \lambda$ = regularisasi untuk setiap cabang untuk mencegah model menjadi terlalu kompleks.

2.8 *Synthetic Minority Oversampling Technique (SMOTE)*

Klasifikasi terkait data biner sering menghadapi masalah dataset yang tidak seimbang. Secara umum ditemukan dalam aplikasi bisnis praktis seperti deteksi, penyaringan, dan prediksi. Untuk mengatasi masalah tersebut, salah satu metode yang banyak diterapkan secara luas adalah *Synthetic Minority Oversampling Technique* dikembangkan secara khusus untuk mengatasi permasalahan ketidakseimbangan pada dataset dengan menghasilkan sampel sintesis untuk kelas minoritas. Teknik ini dikembangkan untuk mengatasi tantangan yang terkait dengan dataset tidak seimbang (Wu et al., 2022).

Penyempurnaan parameter dapat meningkatkan performa model secara keseluruhan, tetapi juga secara efektif meminimalkan risiko *overfitting*, proses ini membantu model menjadi lebih andal untuk melakukan generalisasi pada pola data baru (Baruah & Sarma, 2024).

2.9 *shapley additive explanations (SHAP)*

Shapley additive explanations adalah metode yang digunakan untuk menghitung kontribusi disetiap fitur untuk menginterpretasikan terhadap *output* model mesin (Khairunnisa, 2023). Tujuan utama SHAP adalah memberikan penjelasan terhadap hasil prediksi dengan menentukan seberapa besar peran masing-masing fitur dalam memengaruhi nilai prediksi (Syamkalla et al., 2024). Nilai *Shapley* merupakan metode dari teori permainan yang digunakan untuk mengukur kontribusi masing-masing pemain secara adil terhadap total hasil yang diperoleh, dengan tujuan utama menentukan besarnya kontribusi setiap pemain terhadap pencapaian bersama (Khairunnisa, 2023). Berikut perhitungan metode *Shapley additive explanations*:

$$f(x) = \phi_0 + \sum_{i=1}^M \phi_i$$

$f(x)$ adalah *output* prediksi model untuk instance x_1

ϕ_0 adalah nilai dasar (*baseline*), yaitu prediksi rata-rata model jika tidak ada fitur yang digunakan (sering kali merupakan rata-rata prediksi seluruh data)

ϕ_i adalah nilai kontribusi fitur ke- i

M adalah jumlah total fitur




2.10 *Unified Modeling Language*

Unified Modeling Language adalah seperangkat simbol grafis yang didasarkan pada satu meta-model untuk mendukung penjabaran dan perancangan sistem perangkat lunak, terutama yang memanfaatkan pemrograman berorientasi objek (Tjandra et al., 2024). UML direpresentasikan melalui berbagai bentuk diagram, yaitu:

a. *Use Case Diagram*

Use Case Diagram berfungsi untuk memperlihatkan sistem dari sudut pandang pengguna (*user*), dengan fokus menekankan pada kemampuan yang terdapat dalam sistem, Tidak menitikberatkan pada alur atau runtutan aksi. Diagram ini menggambarkan hubungan antara pengguna dan sistem (Tjandra et al., 2024).

Tabel 2.1 Notasi Use Case


Simbol	Nama	Keterangan
	Aktor	Menggambarkan fungsi seseorang, sistem lainnya, atau perangkat saat berinteraksi dengan skenario penggunaan.
	<i>Use case</i>	Abstraksi serta hubungan antara sistem dan pelaku
	<i>Association</i>	hubungan atau koneksi antara dua atau lebih kelas
	Generalisasi	Merepresentasikan pewarisan peran aktor yang memungkinkan partisipasi dalam satu atau lebih <i>use case</i>
	<i>Include</i>	Merepresentasikan bahwa <i>use case</i> yang lebih spesifik mewarisi seluruh perilaku dari <i>use case</i> induknya
	<i>Extend</i>	Menggambarkan bahwa suatu <i>use case</i> menyediakan fungsi tambahan bagi <i>use case</i> lain ketika kondisi tertentu dipenuhi



b. Activity Diagram

Diagram aktivitas atau *Activity Diagram* berfungsi sebagai memvisualisasikan rangkaian cara kerja dalam suatu sistem. Diagram ini menunjukkan bagaimana orang, objek, atau sistem berinteraksi dalam

berbagai skenario, serta memperlihatkan langkah-langkah kegiatan, proses pengambilan keputusan, dan alur pengendalian dalam proses tersebut (Fadilla, 2023).

Tabel 2.2 Notasi Activity Diagram

No	Notasi	Nama	Keterangan
1		<i>Activity</i>	Menggambarkan suatu aktivitas atau tindakan dalam alur bisnis
2		<i>Action</i>	Merepresentasikan suatu tindakan atau kegiatan yang dilakukan dalam suatu aktivitas
3		<i>Initial Node</i>	Menggambarkan titik permulaan dari suatu aktivitas atau rangkaian proses
4		<i>Activity Final Node</i>	Menggambarkan titik penyelesaian dari suatu aktivitas atau proses
5		<i>Fork Node</i>	Menggambarkan titik keputusan yang mengarah pada percabangan aktivitas dalam proses

6		<i>Decision</i>	Menggambarkan titik pengambilan keputusan dalam jalannya suatu proses
7		<i>Transition</i>	Merepresentasikan jalannya proses bisnis dari satu aktivitas ke aktivitas lainnya
8		<i>Swimlane</i>	Menggambarkan entitas atau peran dalam organisasi yang berpartisipasi dalam pelaksanaan proses bisnis

2.11 *Entity Relationship Diagram*

Entity Relationship Diagram (ERD) adalah model data yang dipakai untuk menjelaskan keterkaitan antar data dalam basis data dengan cara yang logis kepada pengguna. ERD didasari pada pandangan bahwa dunia nyata terdiri dari objek-objek dasar. Pemakaian ERD cukup sederhana untuk dipahami, bahkan bagi orang-orang yang tidak berpengalaman. Untuk perancang atau analis sistem, ERD sangat membantu dalam memodelkan sistem yang akan diubah menjadi basis data. Model ini mendukung dalam menganalisis dan merancang basis data dengan memperlihatkan jenis data yang dibutuhkan serta hubungan antar data di dalamnya. ERD juga dilengkapi dengan simbol-simbol yang merepresentasikan proses data dalam pengembangannya (Tjandra et al., 2024).

2.12 Website

Website adalah platform digital yang memungkinkan akses informasi dan konten dari berbagai lokasi secara luas. Di era digital *modern*, *website* berperan sebagai media komunikasi yang signifikan untuk menyebarkan informasi, mendukung perkembangan bisnis, dan menjalin interaksi dengan *audiens* di seluruh dunia. Melalui *website*, individu maupun organisasi dapat menyampaikan pesan atau menyediakan layanan yang dapat dijangkau oleh pengguna secara global (Syabania & Rosmawarni, 2021).

Website merupakan sekumpulan serangkaian halaman yang bertujuan untuk menyajikan informasi dalam bentuk teks, gambar statis maupun bergerak, animasi, *audio*, atau kombinasi dari berbagai elemen tersebut. Setiap halaman memiliki sifat statis atau dinamis dan terhubung membentuk sebuah sistem yang terintegrasi, di mana setiap halaman dihubungkan melalui jaringan halaman-halaman lainnya. Menurut Bakti, seperti yang dikutip dalam penelitian (Riko Rivanthio, 2020).

2.13 MYSQL

MySQL adalah server basis data yang bertugas untuk mengelola struktur serta pengoperasian database, yang merupakan susunan data yang dirancang untuk mempermudah penyimpanan dan pengambilan informasi (Anggraini et al., 2020). Sebagai sistem manajemen *database* relasional, *MySQL* digunakan untuk menyimpan, mengelola, dan mengakses data dari berbagai aplikasi berbasis web. *MySQL* juga memungkinkan integrasi dengan script PHP melalui perintah *query* SQL, yang mendukung operasi seperti pengambilan, penambahan, pengubahan, dan penghapusan data dalam *database* (Syabania & Rosmawarni, 2021).

2.14 *Blackbox Testing*

Blackbox testing adalah metode yang berfokus pada pengujian perangkat lunak dalam aspek fungsional dari sistem. Metode ini menguji fungsionalitas berdasarkan spesifikasi yang telah ditentukan tanpa memeriksa pemrograman sistem didalamnya (Prawira & Wulandari, 2022).

Dalam penerapannya, pengujian dilakukan dengan memberikan input data secara acak untuk mengevaluasi apakah sistem dapat memberikan respons yang valid. Apabila pemrosesan sistem dilakukan dan terdapat respons tidak valid, maka sistem akan menolaknya dan tidak menyimpannya ke dalam *database*. Sebaliknya, jika terdapat pemrosesan data yang dimasukkan valid, data tersebut akan diproses dan disimpan dalam sistem (Nur Ichsanudin et al., 2022).

2.15 Tinjauan Studi

2.15.1 Penelitian dibuat oleh Qi Tang, Guoen Xia, Xianquan Zhang, Feng Long dengan judul "*A customer churn prediction model based on XGBoost and MLP*".

Penelitian ini bertujuan meningkatkan kinerja prediksi *churn* pelanggan dengan menggabungkan algoritma XGBoost dan *Multi-layer Perceptron* (MLP). Dataset yang digunakan terdiri dari fitur numerik yang diproses melalui XGBoost untuk menghasilkan *leaf numbers*, kemudian diolah oleh MLP. Metode evaluasi menggunakan validasi silang dan perbandingan dengan model lainnya. Hasil dari penelitian ini menunjukkan bahwa kerangka kerja gabungan memiliki performa prediksi yang lebih baik dibandingkan model tradisional. Kesimpulannya, pendekatan ini efektif untuk meningkatkan kinerja prediksi *churn* pelanggan.

2.15.2 Penelitian dibuat oleh Suwarno, Ryo Kusnadi dengan judul "Analisis Perbandingan SVM, XGBoost dan *Neural Network* pada Klasifikasi Ujaran Kebencian".

Penelitian ini bertujuan untuk mengevaluasi tingkat akurasi dari tiga algoritma klasifikasi, yaitu SVM, XGBoost, dan *Neural Network*, dalam mendeteksi ujaran kebencian. Dataset yang dianalisis berasal dari kumpulan *tweet* berbahasa Indonesia yang mengandung ujaran kebencian. Proses evaluasi dilakukan menggunakan sejumlah metrik, antara lain akurasi, *precision*, *recall*, dan *F1-score*. Berdasarkan hasil pengujian, algoritma SVM mencatatkan akurasi tertinggi sebesar 83,2%, menunjukkan performa yang lebih baik dibandingkan dua algoritma lainnya. Oleh karena itu, SVM dinilai layak untuk dijadikan pilihan dalam tugas klasifikasi ujaran kebencian.

2.15.3 Penelitian dibuat oleh Jhiro Faran, Agung Triayudi dengan judul "*Analysis of the Effectiveness of Polynomial Fit SMOTE Mesh on Imbalance Dataset for Bank Customer Churn Prediction with XGBOOST and BAYESIAN OPTIMIZATION*".

Penelitian ini bertujuan meningkatkan akurasi prediksi *churn* pada dataset tidak seimbang dengan menggunakan *Polynomial Fit SMOTE Mesh* (PFSM) dan *Bayesian Optimization*. Dataset yang digunakan terdiri dari 10.000 data nasabah bank dengan 14 fitur, di mana hanya 20% pelanggan yang mengalami *churn*. Evaluasi dilakukan menggunakan indikator akurasi, *precision*, *recall*, dan *F-score*. Hasil eksperimen menunjukkan bahwa model dengan PFSM dan *Bayesian Optimization* mencapai akurasi 86.1%. Kesimpulannya, pendekatan ini efektif untuk meningkatkan prediksi pada data tidak seimbang.

2.15.4 Penelitian dibuat oleh Hiya Nalatissifa, Hilman Ferdinandus Pardede dengan judul "*Customer Decision Prediction Using Deep Neural Network on Telco Customer Churn Data*".

Penelitian ini mengusulkan arsitektur baru berbasis *Deep Neural Network* (DNN) untuk prediksi *churn* pelanggan di sektor telekomunikasi. Dataset yang digunakan terdiri dari 7.403 record data pelanggan telekomunikasi. Evaluasi dilakukan dengan membandingkan akurasi prediksi DNN dengan algoritma KNN, *Random Forest* (RF), dan *Decision Tree* (DT). Hasil menunjukkan bahwa DNN dengan tuning hyperparameter menghasilkan akurasi tertinggi sebesar 83.09%. Kesimpulannya, model DNN terbukti lebih unggul dibandingkan algoritma lainnya untuk prediksi *churn* pelanggan telekomunikasi.

2.15.5 Penelitian dibuat oleh Khaerul Anam, Ade Rizki Rinaldi, Fathurrohman dengan judul "*Komparasi Algoritma Machine Learning dalam Klasifikasi Loyalitas Nasabah Bank Berbasis Particle Swarm Optimization*".

Penelitian memiliki tujuan untuk membandingkan algoritma *Random Forest*, *Decision Tree*, serta *Neural Network* untuk klasifikasi loyalitas nasabah bank. Dataset yang digunakan berasal dari nasabah bank XYZ yang diambil melalui Kaggle. Metode evaluasi mencakup akurasi, *precision*, *recall*, dan AUC. Hasil yang didapatkan bahwa *Random Forest* mendapatkan akurasi tertinggi sebesar 86.34%. Kesimpulannya, algoritma *Random Forest* paling efektif untuk klasifikasi loyalitas nasabah bank.

2.15.6 Penelitian dibuat oleh Amir Mahmud Husein, Mawaddah Harahap, Piter Fernandito dengan judul "Pendekatan *Data Science* untuk Menemukan *Churn* Pelanggan pada Sector Perbankan dengan *Machine Learning*".

Penelitian ini menganalisis *churn* pelanggan dengan menggunakan model berbasis *machine learning*. Dataset yang digunakan melibatkan data pelanggan bank dengan metode rekayasa fitur untuk meningkatkan kinerja prediksi. Metode evaluasi mencakup perbandingan akurasi model antara beberapa algoritma. Berdasarkan hasil pengujian, algoritma *Random Forest* memperoleh akurasi tertinggi sebesar 86%. Kesimpulannya, algoritma *Random Forest* merupakan algoritma yang efektif dalam memprediksi *churn* pada industri perbankan.

2.15.7 Penelitian dibuat oleh Miryam Clementine Aksama, Arum Wahyuniati dengan judul "Prediksi *Churn* Nasabah Bank Menggunakan Klasifikasi Naïve Bayes dan ID3".

Penelitian ini menjelaskan perbandingan algoritma Naïve Bayes dengan ID3 untuk prediksi *churn* nasabah bank. Dataset yang digunakan berjumlah 10.000 data nasabah, dibagi menjadi 60:40 untuk data training dan testing. Metode evaluasi dilakukan dengan membandingkan akurasi antara kedua algoritma. *Naïve Bayes* tercatat memiliki akurasi yang lebih tinggi dibandingkan algoritma lainnya menurut hasil penelitian (85.17%) dibandingkan ID3 (79.17%). Kesimpulannya, algoritma Naïve Bayes lebih unggul dalam prediksi *churn* dibandingkan ID3.

2.15.8 Penelitian dibuat oleh Mohammad Amirulhaq Iskandar, Ulinnuha Latifa dengan judul "*Website Prediksi Customer Churn Untuk Mempertahankan Pelanggan pada Perusahaan Telekomunikasi*".

Tujuan dari penelitian ini adalah membangun model prediksi *churn* pelanggan dengan memanfaatkan algoritma KNN yang telah diimplementasikan dalam sebuah *website*. Dataset yang digunakan adalah Telco *Customer Churn* dengan total 6.950 data. Metode evaluasi berdasarkan akurasi prediksi model yang mencapai 81%. Hasil menunjukkan bahwa model ini dapat diimplementasikan untuk memprediksi *churn* dan mempertahankan pelanggan. Kesimpulannya, model KNN dalam bentuk *website* dapat membantu perusahaan telekomunikasi mengelola pelanggan.

2.15.9 Penelitian dibuat oleh Praveen Lalwani, Manas Kumar Mishra, Jasroop Singh Chadha, dan Pratyush Sethi dengan judul "*Customer Churn Prediction System: A Machine Learning Approach*".

Penelitian ini menggunakan pendekatan *machine learning* dengan berbagai algoritma, termasuk *logistic regression*, SVM, dan *Random Forest*. Dataset diproses dengan pre-processing dan feature selection menggunakan *Gravitational Search Algorithm* (GSA). Hasil evaluasi menunjukkan bahwa algoritma *boosting* seperti AdaBoost dan XGBoost memberikan akurasi tertinggi masing-masing 81,71% dan 80,8%. AUC tertinggi 84% juga diraih oleh kedua algoritma tersebut, menunjukkan keefektifan metode *ensemble learning* dalam prediksi *churn*.

2.15.10 Penelitian dibuat oleh B. Prabadevi, R. Shalini, dan B.R. Kavitha dengan judul "*Customer Churning Analysis Using Machine Learning Algorithms*".

Penelitian ini menganalisis algoritma *machine learning* yang digunakan untuk prediksi *churn* pelanggan dan menentukan algoritma terbaik di antaranya. Dataset yang digunakan mencakup data pelanggan selama sembilan bulan sebelum *churn*. Beberapa algoritma yang diuji meliputi *Stochastic Gradient Booster*, *Random Forest*, *Logistic Regression*, dan KNN. Hasil penelitian menunjukkan bahwa *Stochastic Gradient Booster* mencapai akurasi tertinggi sebesar 83.9%, diikuti oleh *Logistic Regression* (82.9%), *Random Forest* (82.6%), dan KNN (78.1%). Kesimpulannya, *Stochastic Gradient Booster* adalah algoritma paling efektif untuk prediksi *churn* pelanggan.

2.15.11 Penelitian dibuat oleh Pahul Preet Singh, Fahim Islam Anik, Rahul Senapati, Arnav Sinha, Nazmus Sakib, dan Eklas Hossain dengan judul "*Investigating Customer Churn in Banking: A Machine Learning Approach*".

Penelitian ini mengeksplorasi penggunaan algoritma *machine learning* untuk memahami dan memprediksi attrisi pelanggan di sektor perbankan. Dataset yang digunakan terdiri dari 10.000 data nasabah, termasuk informasi seperti skor kredit, usia, dan saldo. Model seperti XGBoost dan *Random Forest* digunakan dalam proses evaluasi. Hasil penelitian menunjukkan bahwa XGBoost memberikan akurasi terbaik dalam memprediksi pelanggan yang berisiko tinggi meninggalkan bank. Kesimpulannya, XGBoost adalah model yang efektif untuk prediksi *churn* pelanggan di sektor perbankan.

2.15.12 Penelitian dibuat oleh Pranshu Kumar Soni dan Leema Nelson dengan judul "Profit-Driven Churn Prediction using Machine Learning Techniques in Banking Sector".

Penelitian ini berfokus pada pengembangan model prediksi *churn* berbasis profit melalui penerapan algoritma *machine learning*. Menggunakan Dataset nasabah bank dari Kaggle. Metode evaluasi mencakup algoritma seperti *Artificial Neural Network* (ANN), *Support Vector Machine* (SVM), dan *Random Forest*. Hasil menunjukkan bahwa ANN memiliki akurasi tertinggi sebesar 97%, diikuti oleh *Random Forest* (86%) dan SVM (82.3%). Kesimpulannya, ANN adalah algoritma terbaik untuk pengembangan model prediksi *churn* berbasis profit.

2.15.13 Penelitian dibuat oleh Pallabi Baruah dan Bhairab Sarma dengan judul "Predictive Analysis on Churn Customers in Business Industries Using Supervised Machine Learning Algorithms and SMOTE"

Penelitian ini mengusulkan model prediksi *churn* berbasis *hybrid* XGBoost dengan SMOTE untuk mengatasi ketidakseimbangan data. Dataset berisi informasi 10.000 pelanggan dari berbagai lokasi geografis. Algoritma seperti *Random Forest*, *Gradient Boosting*, dan SVM digunakan sebagai pembanding, dengan model *hybrid* mencapai akurasi tertinggi sebesar 96%. Penelitian ini memberikan solusi untuk meningkatkan loyalitas pelanggan dan mengurangi *churn* di industri berbasis layanan.

2.15.14 Penelitian dibuat oleh Muhammad Maulana Sidiq dan Dyah Anggraini dengan judul "Analysis and Classification of Customer Churn Using Machine Learning".

Penelitian ini mengklasifikasikan *churn* pelanggan menggunakan berbagai model *machine learning*. Dataset yang digunakan adalah IBM Telco dataset dengan data dari 7043 pelanggan. Beberapa algoritma yang diuji meliputi XGBoost, *Random Forest*, dan *Logistic Regression*, serta menggunakan metode SMOTE untuk mengatasi ketidakseimbangan data. Hasil penelitian menunjukkan bahwa XGBoost memberikan akurasi terbaik sebesar 82.94%, sementara penggunaan SMOTE cenderung menurunkan akurasi. Kesimpulannya, XGBoost adalah model terbaik untuk klasifikasi *churn* pelanggan pada dataset ini.

2.15.15 Penelitian dilakukan oleh Adlina Khairunnisa dengan judul "Perbandingan Model Random Forest dan XGBoost untuk Prediksi Kejahatan Kesusilaan di Provinsi Jawa Barat".

Penelitian ini bertujuan mengembangkan model klasifikasi untuk mendeteksi adanya kejahatan kesusilaan di desa/kelurahan Provinsi Jawa Barat menggunakan pendekatan *machine learning*. Data yang digunakan berasal dari PODES 2018 dan menunjukkan ketidakseimbangan kelas yang signifikan. Cara menangani data yang tidak seimbang seperti *undersampling*, *oversampling*, dan SMOTE digunakan sebelum proses pemodelan. Dua algoritma yang dibandingkan adalah Random Forest dan XGBoost. Evaluasi model dilakukan menggunakan *balanced accuracy*, sensitivitas, dan spesifisitas. Hasil menunjukkan bahwa model XGBoost dengan teknik SMOTE menghasilkan *balanced accuracy* tertinggi sebesar 71,30%. Analisis SHAP menunjukkan bahwa faktor seperti pengedaran narkoba, pencurian, penipuan,

penganiayaan, perjudian, jumlah penginapan, dan jarak ke pub atau diskotik merupakan indikator penting dalam klasifikasi kejahatan kesusilaan. Kesimpulannya, XGBoost dengan SMOTE merupakan model terbaik untuk prediksi kejahatan kesusilaan di wilayah tersebut.



BAB III

METODOLOGI PENELITIAN

3.1 Tinjauan Umum Perusahaan

3.1.1 Sejarah singkat

PT. BPR Magga Jaya Utama, yang dikenal dengan nama BANK MAJU, merupakan lembaga keuangan yang didirikan berdasarkan Akta Notaris Pendy Tanzil, S.H., Nomor 5 tanggal 18 Januari 2006. Pendirian ini memperoleh pengesahan melalui Surat Keputusan Menteri Kehakiman dan Hak Asasi Manusia Republik Indonesia Nomor C-07084 HT.01.01 tanggal 10 Maret 2006. Selain itu, pendirian Bank Perkreditan Rakyat (BPR) ini juga telah mendapatkan persetujuan dari Bank Indonesia pada tanggal 13 Januari 2006 dengan nomor surat 8/22/DPBPR/PLBPR. Legalitas dan persetujuan tersebut menjadi dasar operasional BANK MAJU dalam memberikan layanan jasa keuangan kepada masyarakat.

Pada tahun 2006, PT. Bank Perekonomian Rakyat Magga Jaya Utama (BANK MAJU) mencatatkan total aset sebesar Rp4,373 miliar. Seiring perkembangan perusahaan, nilai aset tersebut mengalami peningkatan signifikan hingga mencapai Rp370,925 miliar pada tahun 2023. Sebagai bagian dari upaya transformasi dan pembaruan citra perusahaan, BANK MAJU memperkenalkan logo baru pada bulan Mei 2015. Selanjutnya, pada tanggal 20 September 2023, dilakukan perubahan nama perusahaan berdasarkan Undang-Undang Nomor 4 Tahun 2023 tentang Pengembangan dan Penguatan Sektor Keuangan (UU PPSK), dari yang sebelumnya bernama PT. Bank Perkreditan Rakyat Magga Jaya Utama menjadi PT. Bank Perekonomian Rakyat Magga Jaya Utama. Dengan mengusung moto

"*Together We Grow*", BANK MAJU menunjukkan komitmennya untuk tumbuh dan berkembang bersama para nasabah, serta menciptakan kemajuan secara berkelanjutan.

Nilai-nilai perusahaan merupakan fondasi penting dalam membangun budaya organisasi yang kuat yang selalu bertumbuh dan berdaya saing. PT. BPR Magga Jaya Utama mengedepankan prinsip *teamwork* yang bertujuan untuk mendorong pertumbuhan pribadi dan profesional melalui pengoptimalan kinerja individu maupun tim. Selain itu, nilai *respect* diterapkan dengan memberikan penghargaan kepada orang lain, berupaya memahami satu sama lain, bertanggung jawab, serta membangun rasa saling percaya. Selanjutnya, budaya *nobility and learner culture* menjadi bagian integral dalam menciptakan karakter yang berorientasi pada pembelajaran berkelanjutan dan memiliki hati yang mulia. Dalam hal pengambilan keputusan, perusahaan mengimplementasikan nilai *consensus* melalui prinsip *Genchi Genbutsu*, yaitu pendekatan langsung ke sumber fakta untuk memastikan keputusan yang diambil berdasarkan data yang akurat, membangun konsensus, serta mencapai tujuan secara efektif dan efisien. Prinsip *innovation* juga menjadi fokus utama melalui upaya perbaikan berkelanjutan terhadap operasional bisnis, yang bertujuan untuk mendorong inovasi dan evolusi. Terakhir, nilai *challenge* mendorong perusahaan untuk membangun visi jangka panjang dan menghadapi tantangan dengan keberanian serta kreativitas dalam rangka mewujudkan berbagai impian dan target yang telah ditetapkan. Nilai-nilai tersebut menjadi pilar utama dalam mendukung pencapaian tujuan strategis perusahaan.

3.1.2 Visi, Misi dan Tujuan

a) Visi

Menjadi Bank Perekonomian Rakyat terkemuka di wilayah Jabodetabek melalui pembangunan hubungan yang harmonis dan berlandaskan kepercayaan dengan nasabah.

b) Misi


Mendorong pertumbuhan dan pengembangan usaha kecil menengah (UKM) dengan menyediakan layanan keuangan yang andal, inovatif, serta menciptakan hubungan saling menguntungkan antar *stakeholder*.

c) Tujuan

Memperluas akses layanan keuangan untuk seluruh nasabah dan usaha menengah kecil (UKM) yang terus bertumbuh dan berkembang bersama. Untuk mencapai tujuan tersebut, perusahaan melaksanakan berbagai layanan dan jasa usaha sebagai berikut:

1. Menghimpun dana masyarakat dalam bentuk simpanan, yang mencakup produk – produk keuangan seperti tabungan, deposito, dan jenis produk keuangan serupa lainnya.
2. Menyalurkan dana yang telah dihimpun kepada masyarakat atau pelaku usaha dalam bentuk kredit, guna mendukung pertumbuhan ekonomi dan pembangunan.

3.1.3 Struktur Organisasi



Gambar 3.1 Struktur Organisasi PT Magga Jaya Utama
(Sumber: PT BPR Magga Jaya Utama, 2025)

Struktur ini menggambarkan hubungan hierarki, tugas, tanggung jawab, dan alur koordinasi dengan unit kerja lainnya. Setiap unit dalam struktur organisasi memiliki peran, tugas, dan tanggung jawab yang jelas. Adapun uraian tugas dan wewenang masing-masing bagian dijabarkan sebagai berikut:

a. Dewan Komisaris

Melakukan monitoring secara menyeluruh terhadap seluruh kegiatan operasional perbankan dilaksanakan di bawah pengelolaan dan pengawasan Direksi, serta mendampingi Direksi dalam menjalin relasi dengan pihak *eksternal*. Evaluasi kinerja Direksi dilakukan untuk memastikan kesesuaian dengan anggaran dasar, rencana kerja perusahaan, dan peraturan perusahaan maupun pemerintah yang berlaku. Memberikan masukan kepada Direksi dalam mencari solusi atas berbagai permasalahan operasional yang dihadapi oleh bank, hasil dari proses pengawasan operasional dilaporkan secara berkala kepada Bank Indonesia. Tugas lainnya mencakup pelaksanaan rapat evaluasi bersama Direksi, mewakili Direksi apabila keduanya berhalangan hadir, serta memimpin Rapat Umum Pemegang Saham dalam kondisi ketidakhadiran Direksi.

b. Direktur Utama

Direktur Utama memiliki tanggung jawab utama dalam menetapkan peraturan internal perusahaan, merancang serta menetapkan sistem operasional, dan merumuskan strategi untuk mencapai visi dan misi perusahaan. Selain itu, Direktur Utama juga

bertugas dalam menetapkan strategi guna menjaga tingkat kesehatan Bank agar tetap berada pada kondisi yang wajar dan sehat. Juga bertanggung jawab merumuskan kebijakan operasional disertai dengan distribusi tanggung jawab yang terstruktur dan terdefinisi dengan baik, mengembangkan produk layanan perbankan, serta meningkatkan kemampuan SDM. Selain itu, Direktur Utama mengevaluasi pelaksanaan operasional, peraturan, dan kinerja staf, mengendalikan anggaran dan upaya peningkatan volume usaha, mengatasi masalah operasional, serta menjalin hubungan dengan pihak ketiga untuk pengembangan usaha Bank. Dalam hal wewenang, Direktur Utama bertindak mewakili perusahaan sesuai anggaran dasar, menetapkan arah kebijakan operasional, memberikan opini terkait komite kredit, merekrut dan memberhentikan karyawan, serta menentukan sistem kompensasi bagi karyawan.

c. **Direktur Yang Membawahi Kepatuhan**

Direktur Kepatuhan bertugas merumuskan kebijakan strategis guna mendorong terbentuknya budaya kepatuhan, serta menyusun sistem dan prosedur operasional sebagai pedoman internal bagi kegiatan perbankan. Direktur Kepatuhan memastikan bahwa seluruh kebijakan, sistem, dan aktivitas usaha Bank dijalankan sesuai dengan ketentuan yang ditetapkan oleh Otoritas Jasa Keuangan dan peraturan perundang-undangan yang berlaku, meminimalkan risiko kepatuhan, dan mencegah penyimpangan dalam kebijakan atau keputusan Direksi. Selain itu, Direktur Kepatuhan memiliki tugas terkait fungsi

kepatuhan dan hak serta kewajiban sebagaimana telah ditentukan dalam Undang-Undang Perseroan Terbatas, termasuk tugas yang berkaitan dengan pengawasan terhadap risiko kepatuhan. Dalam hal wewenang, Direktur Kepatuhan mewakili perusahaan sesuai anggaran dasar, menetapkan arah kebijakan operasional, memberikan opini terkait komite kredit, serta merekrut, memberhentikan, dan menetapkan sistem kompensasi bagi karyawan.

d. Direktur Bisnis

Direktur bisnis bertugas sebagai koordinator sekaligus Ketua Komite Kredit, dengan tanggung jawab utama dalam mengendalikan kegiatan pendanaan (*funding*) dan penyaluran kredit (*lending*), menatausahakan serta mengkoordinir kegiatan operasional internal Bank, memantau likuiditas, dan mempersiapkan pemenuhan kewajiban perusahaan terhadap pihak ketiga serta memastikan bahwa seluruh kewajiban tersebut dilaksanakan secara tepat waktu dan sesuai ketentuan. Selain itu, Direktur juga melakukan distribusi tugas kepada staf dan karyawan, serta memantau pelaksanaan operasional guna menjamin efisiensi dan efektivitas kinerja organisasi. Secara kolektif, Direktur merancang peraturan yang berkaitan dengan alur kredit dan menetapkan sistem prosedur operasional bank dalam hal perkreditan, strategi pencapaian visi, misi, serta tingkat kesehatan Bank yang wajar dan sehat. Direktur juga menjalin relasi dengan nasabah untuk pembiayaan serta perkembangan usaha, mengendalikan anggaran dan upaya peningkatan volume usaha, serta

mengatasi masalah operasional. Dalam wewenanganya, Direktur mewakili perusahaan sesuai anggaran dasar, menetapkan kebijakan operasional, memberikan persetujuan kredit, merekrut dan memberhentikan karyawan, serta menentukan sistem kompensasi.

e. *General Manager Kredit*

General Manager Kredit berfokus pada pengelolaan laba Bank yang berada di bawah wewenanganya, mengawasi seluruh kegiatan yang dibawah dan moral pegawai, serta menentukan sanksi, promosi, pendidikan, dan pelatihan sesuai ketentuan. Tugas lainnya meliputi memeriksa dan menandatangani dokumen sesuai prosedur, mengusulkan perbaikan sistem operasional dan pengembangan produk, serta membangun citra positif perusahaan. Pemimpin juga membina kerja sama antarunit kerja, memastikan kepatuhan perusahaan terhadap peraturan, mengelola aspek hukum dalam pengembangan dan kerja sama, serta mengkaji perikatan hukum secara berkala. Selain itu, mereka menyusun agenda rapat, konsep surat keputusan, menindaklanjuti temuan pemeriksaan, dan melaksanakan tugas lain dari Direksi. Dalam wewenanganya, pemimpin mengadakan rapat koordinasi rutin dan memberikan teguran atau mengusulkan sanksi kepada bawahan sesuai dengan aturan perusahaan.

f. Kepala Bagian Pengembangan Jaringan Kantor dan PPUM

Kepala Bagian Pengembangan Jaringan Kantor dan PPUM bertugas bertanggung jawab kepada *Manager*, mengusulkan rencana kerja dan anggaran, serta mengembangkan jaringan kantor dengan meningkatkan pelayanan. Tugas lainnya meliputi mengurus perizinan pembukaan kantor, pelaksanaan *event*, dan kegiatan, membangun komunitas melalui pelatihan usaha maju, menyelenggarakan *event* untuk pengembangan nasabah, dan mengelola dokumentasi serta data penting. Kepala Bagian juga berperan dalam melakukan inovasi produk dan layanan untuk mendukung bisnis baru, memfasilitasi komunikasi antara Bank dan nasabah melalui aplikasi dan media sosial, serta menangani temuan hasil pemeriksaan. Dalam wewenangya, Kepala Bagian memberikan pertimbangan dan rekomendasi kepada *Manager* dan Direksi.

g. Staff PPUM

Staff PPUM bertugas membantu Kepala Bagian Jaringan Kantor dan PPUM dalam mengusulkan rencana kerja dan anggaran, mengurus perizinan pelaksanaan *event* dan kegiatan, serta membangun komunitas melalui pelatihan usaha maju. Selain itu, *staff* PPUM menyelenggarakan *event* untuk pengembangan nasabah, mengelola dokumentasi dan data penting, serta melakukan inovasi produk dan layanan untuk mendukung bisnis baru. Staff juga bertanggung jawab memfasilitasi komunikasi melalui aplikasi dan media sosial seperti *web*, *Facebook*, dan *Instagram*, serta

melaksanakan perintah lain dari Kepala Bagian. Dalam wewenanganya, *staff* mendukung Kepala Bagian dalam memberikan pertimbangan dan rekomendasi kepada *Manager* dan Direksi

h. Kepala Bagian Remedial

Kepala Bagian Remedial bertugas membantu Direksi dalam menangani penyelesaian kredit bermasalah, mengusulkan rencana kerja dan anggaran pencapaian target, serta mengawasi tugas karyawan di bawahnya dengan prinsip kehati-hatian. Kepala Bagian melakukan pemetaan tunggakan kredit, merancang strategi penagihan yang efektif, dan mengusulkan tindakan penyelamatan kredit melalui restrukturisasi, penjadwalan ulang, atau rekondisi bagi debitur berkarakter baik. Selain itu, mereka mengusulkan kredit hapus buku, pengelolaan aset hasil sitaan (AYDA), serta penyelesaian kredit bermasalah akibat buruknya karakter debitur. Tugas lainnya mencakup monitoring tingkat kesehatan Bank, seperti kualitas aset produktif (KAP) dan rasio kredit bermasalah (NPL), serta memastikan kegiatan penyelesaian kredit sesuai dengan peraturan. Kepala Bagian juga menyediakan laporan lengkap kepada Direksi, menangani temuan pemeriksaan, dan berkoordinasi dengan pihak eksternal untuk penyelesaian kredit bermasalah. Dalam wewenanganya, Kepala Bagian memberikan pertimbangan dan rekomendasi kepada Direksi terkait aspek preventif, detektif, dan korektif dalam penyelesaian kredit bermasalah.

i. *Staff Remedial*

Staff Remedial bertugas mendukung Kepala Bagian Remedial dalam melaksanakan tugas penyelesaian kredit bermasalah sesuai arahan Direksi. Tugas mereka meliputi membantu pengusulan rencana kerja dan anggaran, memberikan laporan dan masukan terkait strategi penyelamatan kredit melalui restrukturisasi, penjadwalan ulang, atau rekondisi, serta mengusulkan penyelesaian untuk kredit bermasalah akibat buruknya karakter debitur. Mereka juga bertanggung jawab atas monitoring pengelolaan AYDA, kredit hapus buku, dan tingkat NPL, melakukan pembinaan serta pendekatan kepada nasabah, dan memastikan pelaksanaan penyelesaian kredit sesuai peraturan yang berlaku. Selain itu, mereka menyediakan laporan yang relevan untuk Direksi, menangani temuan pemeriksaan, membantu koordinasi dengan pihak eksternal seperti pengacara dan balai lelang. Dalam wewenangnya, *staff* mendukung Kepala Bagian memberikan rekomendasi kepada Direksi dalam aspek preventif, detektif, dan korektif dalam penyelesaian kredit bermasalah.

j. Kepala Bagian Kepatuhan

Kepala Bagian Kepatuhan bertanggung jawab memastikan seluruh rangkaian kerja BPR sesuai dengan peraturan Otoritas Jasa Keuangan (OJK) dan perundang-undangan yang relevan melalui pemantauan, sosialisasi, pelatihan, serta penyesuaian kebijakan dan prosedur internal. Tugas utama meliputi konsultasi kepatuhan, pengelolaan risiko kepatuhan, evaluasi sistem kerja, serta pelaporan

kepada Direksi terkait pelaksanaan dan pelanggaran kepatuhan. Selain itu, kepala bagian ini merumuskan strategi untuk menciptakan budaya kepatuhan, memberikan rekomendasi terkait produk dan aktivitas bank, dan bekerja sama dengan unit kerja lainnya untuk mendukung penerapan manajemen risiko. Dalam menjalankan tugas, kepala bagian ini memiliki wewenang memberikan pertimbangan, rekomendasi, dan evaluasi atas pelaksanaan kerja, memastikan seluruh kegiatan BPR berjalan sesuai dengan ketentuan peraturan OJK dan standar *internal* yang ditetapkan.

k. *Staff* Bagian Kepatuhan

Staff Bagian Kepatuhan bertugas melakukan pemeriksaan kepatuhan pegawai BPR terhadap peraturan Otoritas Jasa Keuangan (OJK) dan perundang-undangan terkait melalui pemantauan, sosialisasi, pelatihan, serta evaluasi prosedur kepatuhan di seluruh unit kerja. Tugas utama mencakup identifikasi, pengukuran, monitoring, dan pengendalian risiko sesuai dengan ketentuan, mendukung pengkinian pedoman kerja, serta merumuskan strategi untuk menciptakan budaya kepatuhan di BPR. Selain itu, staff ini melaporkan pelaksanaan fungsi kepatuhan, memberikan rekomendasi dan evaluasi atas kebijakan serta sistem kerja, serta berkoordinasi dengan unit kerja Manajemen Risiko. Dalam wewenangnya, staff mendukung Kepala Bagian Kepatuhan dalam memberikan pertimbangan dan rekomendasi kepada Direktur Kepatuhan untuk

memastikan kesesuaian seluruh pekerjaan bank selaras dengan regulasi OJK dan ketentuan hukum yang berlaku.

l. Kepala Bagian Audit Internal

Kepala Bagian Audit *Internal* bertanggung jawab membantu Direksi dalam melaksanakan tugas pengawasan dan pengendalian internal bank melalui penyusunan rencana kerja, anggaran, dan *Standard Operating Procedure* internal yang sesuai dengan peraturan otoritas dan strategi bank. Tugas meliputi penyusunan rencana audit, kontrol fungsi pengendalian *intern*, pemeriksaan kesesuaian aktivitas usaha dengan peraturan, peningkatan budaya risiko, serta penyediaan laporan lengkap dan akurat untuk pengambilan keputusan oleh Direksi. Selain itu, Kepala Bagian Audit *Internal* bertugas membantu perbaikan temuan pemeriksaan dan memastikan semua kegiatan mendukung tujuan strategis bank. Dalam pelaksanaan tugasnya, Kepala Bagian Audit Internal memiliki wewenang memberikan pertimbangan dan rekomendasi kepada Direktur Utama.

m. *Staff Audit Internal*

Staff Audit Internal bertugas mendukung Kepala Bagian Audit *Internal* dalam melaksanakan tanggung jawabnya, termasuk membantu penyusunan rencana kerja, anggaran, strategi, kebijakan, dan pedoman pengendalian intern yang sesuai dengan peraturan otoritas dan strategi bank. *Staff Audit Internal* juga berperan dalam mempersiapkan rencana pemeriksaan, melakukan audit untuk

memastikan kepatuhan terhadap peraturan, meningkatkan efektivitas budaya risiko, serta menyusun laporan pemeriksaan yang lengkap dan akurat untuk pengambilan keputusan oleh Direksi. *Staff* juga memiliki wewenang membantu Kepala Bagian dalam memberikan rekomendasi kepada Direktur Utama terkait tugas bidang audit *intern*.

n. Kepala Bagian Marketing

Kepala Bagian Marketing bertugas membantu Direksi dalam menjalankan tanggung jawabnya, termasuk menyusun rencana kerja, anggaran, dan laporan tahunan bagian marketing, serta merumuskan dan mengembangkan sistem dan prosedur bersama PE Kepatuhan. Mereka menyusun strategi pengumpulan dana, mengembangkan pemasaran melalui media sosial dan internet, mengawasi serta mendorong kinerja *account officer* untuk mencapai target, dan melaporkan pencapaian kepada manajemen. Selain itu, Kepala Bagian Marketing memberikan solusi pengembangan produk dan saluran pemasaran, menilai kinerja bawahan, serta membantu Direksi dalam menetapkan bunga produk, menerapkan prinsip GCG, dan menjaga rahasia bank. Dalam hal wewenang, mereka dapat membuat surat persetujuan kredit, menolak proses kredit yang tidak layak, memberikan rekomendasi suku bunga khusus, mengadakan rapat koordinasi, memberikan teguran atau sanksi kepada bawahan, dan menentukan *Base Lending Rate* bersama Direksi.

o. Koordinator *Mikro Team*

Koordinator *Mikro Team* bertugas melakukan promosi produk – produk perbankan dengan media sosial untuk mengoptimalkan pencapaian target penghimpunan dana melalui pendekatan yang tepat guna, mengawasi serta mendorong kinerja seluruh *Account Officer* untuk mencapai target pertumbuhan, dan melaporkan pencapaian mereka secara mingguan kepada Kepala Bagian Marketing. Selain itu, mereka menilai prestasi kerja bawahan serta menjaga kerahasiaan bank dan data nasabah. Dalam wewenangnya, Koordinator *Mikro Team* dapat membuat surat persetujuan kredit untuk debitur, menginformasikan kepada nasabah terhadap kredit yang tidak layak, dan mengadakan rapat koordinasi rutin dengan koordinator, marketing, dan *Account Officer*.

p. Kepala Bagian Kredit

Kepala Bagian Kredit bertugas membantu Direksi dalam melaksanakan tanggung jawab di bidang kredit, menyusun perencanaan pelaksanaan kegiatan, anggaran, serta laporan tahunan kredit, dan melakukan inovasi untuk meningkatkan kecepatan proses kredit. Mereka bertanggung jawab menjaga nasabah kredit tetap lancar, mengelola penyelesaian kredit bermasalah, memberikan usulan restrukturisasi kredit, dan melakukan pembinaan nasabah. Selain itu, mereka menyusun, melaksanakan, dan melaporkan realisasi pencapaian kredit, memperbaiki temuan audit, dan memberikan pertimbangan kepada Direksi terkait keputusan kredit,

bunga, denda, serta provisi. Dalam melaksanakan tugasnya, mereka menjaga kerahasiaan data nasabah dan menerapkan prinsip APU-PPT, perlindungan konsumen, serta GCG.

Dalam wewenangnya, Kepala Bagian Kredit dapat memberikan rekomendasi kepada Direksi mengenai keputusan kredit, putusan AYDA, pemberian keringanan tunggakan bunga, serta suku bunga khusus untuk nasabah potensial. Mereka juga memiliki hak untuk menolak proses kredit yang tidak sesuai prosedur dan mengadakan rapat koordinasi rutin dengan stafnya

q. Administrasi Kredit

Staff Administrasi Kredit bertugas untuk mendukung Kepala Bagian Kredit dalam melaksanakan tanggung jawab administrasi kredit dengan cara yang efisien dan efektif. Tugas utamanya meliputi penyusunan dan pengusulan Rencana Kerja dan Anggaran, koordinasi dengan staf untuk memastikan pengadministrasian permohonan kredit dilakukan dengan rapi dan sesuai prosedur, serta melakukan pemeriksaan terhadap kelengkapan dan kelayakan usaha calon debitur. Selain itu, staff ini juga bertanggung jawab untuk memantau tunggakan kredit, mengelola dokumen dan laporan terkait perkreditan, serta memastikan kepatuhan terhadap peraturan yang berlaku. *Staff* Administrasi Kredit juga melakukan koordinasi terkait pemeriksaan Daftar Hitam (BI-SID) dan memonitor kelengkapan dokumen jaminan, asuransi, serta kredit yang jatuh tempo. Dalam hal pengelolaan risiko, staff ini berwenang memberikan pertimbangan

kepada Kepala Bagian Kredit, serta mengasuransikan jaminan debitur dan menyimpan dokumen analisis kredit secara aman. Tugas tambahan mencakup penyelesaian temuan hasil pemeriksaan dari Otoritas Jasa Keuangan dan divisi terkait serta menyiapkan jadwal angsuran debitur.

r. Legal

Staff Legal memiliki tugas untuk mendukung Kepala Bagian Kredit dalam melaksanakan tanggung jawab hukum yang berkaitan dengan pengelolaan kredit. Tugas utama *Staff* Legal meliputi pengusulan Rencana Kerja dan Anggaran, koordinasi dengan staf terkait untuk memastikan pengadministrasian permohonan kredit berjalan sesuai dengan ketentuan, serta memastikan data debitur dan jaminan telah lengkap dan sah sesuai ketentuan yang ditetapkan oleh komite kredit. Selain itu, *Staff* Legal bertanggung jawab terhadap pembuatan perjanjian kredit dan pengikatan jaminan, baik secara notariil maupun di bawah tangan, serta menjaga keamanan dan kelengkapan dokumen terkait. *Staff* ini juga memeriksa keabsahan dokumen jaminan, mengatur pengikatan dengan notaris, dan menyiapkan surat roya saat kredit lunas. Dalam hal pengelolaan risiko hukum, *Staff* Legal memiliki kewenangan untuk menolak pelaksanaan akad kredit atau pencairan dana apabila dokumen debitur tidak lengkap atau mengandung cacat administratif, menerima dokumen jaminan asli, serta melaksanakan penyitaan jaminan berdasarkan persetujuan komite kredit. Jika terjadi masalah dengan

debitur, *Staff Legal* berhak memprosesnya hingga pengadilan, serta menjual jaminan yang diambil alih bank dengan persetujuan Direksi. Semua dokumen terkait pengelolaan kredit dan jaminan harus dikelola dengan rapi dan disimpan dalam lemari besi untuk memastikan keamanannya. *Staff Legal* juga wajib menyediakan laporan secara rinci kepada Kepala Bagian Kredit serta menyelesaikan temuan hasil pemeriksaan dari Otoritas Jasa Keuangan atau Audit *Internal*.

s. Analisa Kredit

Staff Analisa Kredit bertugas mendukung Kepala Bagian Kredit dalam melaksanakan tanggung jawab analisis kredit dengan cara yang akurat dan efisien. Tugas utamanya meliputi pengusulan Perencanaan kerja dan alokasi anggaran disertai dengan pelaporan progres realisasi program kerja, evaluasi model analisa kredit yang dilakukan secara berkala, dan pengecekan SID calon debitur. *Staff* ini melakukan analisis terhadap permohonan kredit yang telah lengkap dan disertai dengan hasil survei, menggunakan model dan prosedur standar yang ditetapkan oleh Bank. Laporan hasil analisis kredit harus sesuai dengan standar yang ditentukan dan dapat dipertanggungjawabkan, termasuk memberikan rekomendasi apakah kredit diterima atau ditolak, serta mencakup informasi mengenai plafond, jangka waktu, suku bunga, pendapatan bank, serta positif dan negatif covenant yang perlu diterapkan. Selain itu, staff ini bertanggung jawab untuk memastikan bahwa laporan analisa kredit

diselesaikan tepat waktu dan sesuai dengan standar yang ditentukan. *Staff Analisa Kredit* juga melaksanakan analisis untuk kredit yang akan direstrukturisasi atau dihapus buku, serta meminta informasi tambahan yang diperlukan dengan menjaga kerahasiaan bank dan debitur. Semua analisa harus sesuai dengan ketentuan perundang-undangan yang telah disahkan dan peraturan internal bank. Selain itu, staff ini juga wajib menyelesaikan temuan hasil pemeriksaan oleh otoritas pengawasan atau audit internal. Dalam hal ini, *Staff Analisa Kredit* memiliki wewenang untuk memberikan pertimbangan dan rekomendasi kepada Kepala Bagian Kredit terkait keputusan kredit.

t. Akunting

Staff Akunting bertanggung jawab untuk mengelola dan mengawasi kegiatan akuntansi di bank, dengan tugas utama menyusun rancangan anggaran dan memastikan realisasinya sesuai, mengawasi pencatatan dan penyajian data keuangan, serta melakukan analisis tren keuangan. Mereka juga bertugas menyusun dan melaksanakan laporan bulanan terkait bidang akuntansi dan menyajikan laporan keuangan yang valid dan disampaikan secara tepat waktu. Selain itu, staf terkait memiliki tanggung jawab dalam mengoordinasikan seluruh aspek perpajakan, serta melakukan perencanaan dan pengendalian terhadap arus kas bank, khususnya pengelolaan piutang dan hutang, untuk memastikan ketersediaan dana operasional. *Staff Akunting* juga merencanakan dan mengoordinasikan penyusunan anggaran, serta mengembangkan

sistem dan prosedur keuangan untuk mengurangi risiko. Mereka berperan dalam memberikan masukan keuangan untuk mendukung keputusan bisnis pimpinan bank, termasuk analisa investasi dan ekspansi. Tugas lainnya mencakup pembinaan operasional cabang, pengawasan jurnal operasional harian, rekonsiliasi rekening, dan pengarsipan transaksi. *Staff* ini juga bertanggung jawab untuk memelihara dan memeriksa kelengkapan bukti transaksi. Selain itu, mereka wajib menindaklanjuti temuan hasil pemeriksaan dan melaksanakan tugas lain yang diperintahkan oleh Direksi.

Dalam hal wewenang, *Staff* Akunting berhak memberikan rekomendasi kepada Kepala Bagian Operasional terkait tugas akunting, operasional, dan kontrol risiko. Memiliki otoritas untuk menolak pencatatan transaksi dengan dokumen pendukung yang tidak valid, serta bertanggung jawab melaporkan atau mengonfirmasi transaksi yang menunjukkan indikasi ketidakwajaran atau ketidakabsahan langsung kepada Direksi sebelum melakukan pembukuan.

u. Kurir

Staff Kurir bertugas untuk mendukung Kepala Bagian Operasional dalam melaksanakan tanggung jawab logistik dan operasional sehari-hari dengan cara yang efisien dan penuh tanggung jawab. Tugas utamanya meliputi pengantaran atau pengambilan surat, dokumen, dan barang dengan tepat waktu, serta menjaga kerahasiaan informasi yang terkandung dalam surat atau dokumen yang

dikirimkan. Selain itu, *staff* ini juga membantu manajemen dan karyawan dalam pengelolaan kebutuhan logistik, termasuk persediaan barang cetak dan alat tulis, serta memastikan kedisiplinan pegawai terkait etos kerja dan absensi. *Staff* Kurir bertanggung jawab menjaga inventaris bank, mengecek stok barang yang ada, dan menjaga hubungan baik dengan nasabah. Selain itu, serta mengurus dokumen administrasi terkait asuransi dan surat-surat perizinan yang berkaitan dengan inventaris dan aktiva tetap seperti STNK dan dokumen domisili. Tugas tambahan termasuk melaksanakan berbagai perintah dari Koordinator *Back Office* sesuai dengan kebutuhan operasional. Dalam hal wewenang, *Staff* Kurir berhak memberikan masukan kepada Koordinator *Back Office* terkait tugas dan fungsinya untuk meningkatkan kelancaran operasional dan logistik.

v. Satuan Pengamanan (SATPAM)

Staff Satuan Pengamanan (Satpam) bertugas untuk menjaga dan mengamankan lingkungan sekitar kantor bank dengan cara yang efektif dan efisien, serta memperhatikan prinsip kehati-hatian. Tugas utamanya meliputi pengawasan dan pengamanan rutin terhadap area bank, memastikan tidak ada pihak yang tidak berkepentingan berada di dalam lingkungan bank, baik selama jam operasional maupun setelah jam operasional, termasuk pada hari libur. Satpam juga bertanggung jawab untuk menerapkan budaya kerja yang ramah dan membiasakan diri memberi salam dan sapa kepada karyawan, tamu, dan nasabah yang ditemui, serta bekerja sesuai dengan jadwal shift

dan penugasan yang telah ditentukan oleh Koordinator *Back Office*. Di dalam Banking Hall, satpam melaksanakan tugas pengamanan dan pelayanan berdasarkan prosedur dan regulasi yang telah ditentukan oleh institusi perbankan, menjaga keharmonisan kerja dengan sesama satpam, dan menjaga citra positif bank dalam setiap interaksi dengan karyawan, tamu, dan masyarakat. Selain itu, Satpam juga bertugas untuk menegakkan kedisiplinan pegawai terkait etos kerja, budaya kerja, dan absensi, serta menjaga kerahasiaan bank dan memastikan tata tertib yang berlaku di perusahaan ditegakkan. Satpam juga melaksanakan tugas tambahan yang diperintahkan oleh Koordinator *Back Office*.

Dalam hal wewenang, Satpam memiliki hak untuk memberikan masukan kepada Koordinator *Back Office* terkait tugas dan fungsinya, serta memutuskan untuk memberikan otorisasi atau menolak akses terhadap individu maupun barang ke dalam area operasional kantor sesuai dengan prosedur keamanan yang berlaku. Selain itu, Satpam juga berwenang untuk mencegah permasalahan yang berkaitan dengan keamanan karyawan dan perusahaan.

w. Umum & *Cleaning Service*

Staff Umum & Cleaning Service bertugas untuk mendukung Kepala Bagian Operasional dalam melaksanakan tanggung jawab terkait kebersihan dan kebutuhan umum di kantor bank. Tugas utama mereka meliputi pembersihan area *Banking Hall*, toilet, meja, kursi, lantai, dan bagian lain di lingkungan kantor baik sebelum maupun

setelah jam operasional. Selain itu, *staff* ini juga bertanggung jawab untuk mempersiapkan kebutuhan air minum bagi manajemen dan karyawan, serta memastikan kebutuhan makanan dan minuman mencukupi seluruh kantor sesuai dengan instruksi dari Koordinator *Back Office*. Kehadiran Staf Umum dan *Cleaning Service* diatur agar dimulai satu jam sebelum operasional bank dimulai, serta berakhir setelah seluruh pegawai dan manajemen selesai beraktivitas dan meninggalkan kantor. Mereka juga membantu manajemen dan karyawan terkait konsumsi dan kebutuhan lainnya, serta melaksanakan kedisiplinan pegawai terkait etos kerja, budaya kerja, dan absensi. Selain itu, mereka turut menjaga inventaris bank dan melaksanakan tugas tambahan lainnya yang diperintahkan oleh Koordinator *Back Office*. Dalam hal wewenang, *staff* ini berhak memberikan masukan kepada Koordinator *Back Office* terkait tugas dan fungsinya untuk meningkatkan efektivitas dan efisiensi operasional bank

3.2 Identifikasi Kebutuhan

Dalam tahap ini, identifikasi kebutuhan dilakukan untuk memahami dan mendefinisikan kebutuhan fungsional dan non-fungsional dengan tujuan memastikan bahwa solusi yang dirancang disesuaikan dengan kepentingan dan ditujukan untuk memenuhi target yang telah direncanakan sebelumnya. Proses identifikasi kebutuhan mencakup beberapa langkah sebagai berikut:

3.2.1 Identifikasi Kebutuhan Fungsional Sistem

Kebutuhan fungsional adalah deskripsi mengenai kebutuhan utama untuk menjalankan fungsi yang harus dilakukan oleh sistem, seperti fitur – fitur yang memungkinkan menjalankan tugas tertentu atau memenuhi layanan persyaratan operasional. Pada Tabel 3.1 menunjukkan persyaratan kebutuhan Pengguna dan tabel 3.2 kebutuhan fungsional sistem yang diharapkan pada penelitian ini, yaitu:

Tabel 3.1 Kebutuhan Pengguna

No	User Sistem
KP.1	Merancang sistem aplikasi yang mengidentifikasi pola perilaku dan karakteristik pelanggan yang berisiko <i>churn</i> .
KP.2	Membuat aplikasi yang mampu menyediakan wawasan berbasis data untuk mendukung strategi bisnis dan keputusan manajerial.
KP.3	Membuat <i>website</i> analisis dapat digunakan untuk memahami kebutuhan dan harapan pelanggan, yang dapat membantu meningkatkan kualitas layanan.

Tabel 3.2 Kebutuhan Fungsional

No	Kebutuhan Fungsional	No kebutuhan Pengguna
KF.1	Aplikasi berbasis <i>Website</i>	KP.3
KF.2	Menambahkan <i>database</i> nasabah	KP.2
KF.3	Menampilkan data rekening nasabah	KP.1
KF.4	Mencari data nasabah	KP.2
KF.5	Melakukan prediksi tingkat <i>churn</i> nasabah	KP.1
KF.6	Menampilkan grafik hasil prediksi <i>churn</i> nasabah	KP.3
KF.7	Memberikan risiko tingkatan <i>churn</i> pelanggan	KP.2
KF.8	Memberikan rekomendasi langganan yang sesuai kepada nasabah	KP.2

3.3 Pembahasan Metode Yang Digunakan

XGBoost adalah pendekatan algoritma dalam machine learning yang menggabungkan beberapa model lemah melalui teknik boosting untuk menggabungkan pohon keputusan untuk menghasilkan akurasi prediksi yang lebih baik. Proses ini dilakukan dengan membangun serangkaian model lemah menjadi satu model kuat melalui pendekatan *gradient boosting*. Proses ini dilakukan secara iteratif, di mana setiap model baru bertujuan untuk memperbaiki kesalahan (*error*) pada model yang telah mengolah data sebelumnya. Setiap model dibangun dengan menggunakan residual *error* dari model sebelumnya sebagai target variabel, sehingga model-model baru fokus pada pengurangan *error* yang belum terselesaikan. Selain itu, XGBoost menerapkan teknik regularisasi, seperti L1 dan L2 *regularization*, untuk mencegah *overfitting*, yang dapat menurunkan performa model pada data pengujian. Regularisasi ini memberikan bobot yang berbeda pada setiap fitur, bergantung pada signifikansinya terhadap variabel target, sehingga membantu model dalam menjaga keseimbangan antara bias dan varians serta meningkatkan generalisasi.

Dalam penelitian ini, proses metode sistem diawali pada *Data Collection*, *Data Cleaning*, *Feature Engineering*, *Data Splitting*, *Handling Imbalanced*, *Model Training*, dan *Model Evaluation*. Adapun penjelasan setiap bagian tersebut yaitu:

1. *Data collection*

Dataset untuk penelitian berbentuk file CSV bernama *db_nasabahh.csv*, yang berisi informasi tentang nasabah serta transaksi yang telah dilakukan. Data ini terdiri dari berbagai kolom dengan data kategorikal dan numerik yang menunjukkan informasi tentang berbagai atribut nasabah, seperti pendapatan, saldo tabungan, status perkawinan, dan lokasi bisnis. Kualitas dan keragaman data yang diperoleh akan memengaruhi hasil dan akurasi model pembelajaran.

mesin, pengumpulan data merupakan tahap awal yang krusial dalam proses analisis ini. Pemanfaatan data dalam studi ini dilakukan secara selektif dan tidak hanya mencakup fitur yang relevan untuk analisis, tetapi juga fitur yang dapat digunakan dalam proses pemodelan untuk menemukan pola atau prediksi *churn* nasabah.

2. *Data Cleaning*

Membersihkan data karena data yang diperoleh dari sumber luar sering memiliki masalah seperti nilai yang *missing*, Data yang tidak memenuhi kriteria validitas, dan ketidakkonsistenan dalam format data. Ini karena data didapatkan data dari sumber luar cenderung memiliki kelemahan dalam hal kelengkapan dan akurasi. Dalam penelitian ini, median digunakan untuk mengisi kolom numerik yang memiliki nilai yang hilang karena median lebih tahan terhadap pengaruh *outlier* dibandingkan dengan *mean*. Selain itu, kolom yang memiliki nilai yang tidak valid, seperti kolom transaksi yang mengandung teks atau rentang transaksi, diperbaiki dengan mengubah formatnya menjadi format numerik yang lebih konsisten dan lebih mudah diproses. Untuk mengurangi kompleksitas dataset, kolom seperti nomor rekening, nama nasabah, dan alamat dihapus.

3. *Feature Engineering*

Feature engineering, yaitu proses menentukan fitur yang tepat untuk model pembelajaran mesin. Dengan menggunakan *One-Hot Encoding*, variabel kategorikal dalam penelitian ini, seperti jenis kelamin, status perkawinan, lokasi bisnis, dan sumber dana, diubah menjadi format numerik. Metode ini menggabungkan setiap kategori yang ada dalam kolom menjadi kolom baru dengan nilai 0 atau 1. Nilai ini menunjukkan bahwa kategori tersebut ada. Karena sebagian besar algoritma pembelajaran mesin hanya dapat memproses

data numerik, proses ini sangat penting. Dengan menggunakan encoding satu panas, informasi variabel kategori dapat digunakan untuk analisis tanpa kehilangan maknanya. Selain itu, langkah ini memungkinkan model untuk secara efektif memanfaatkan semua fitur yang ada dalam dataset.

4. *Data Splitting*

Setelah melalui tahap pembersihan data dan transformasi fitur ke dalam format numerik, data kemudian dibagi menjadi dua subset, yaitu data pelatihan dan data pengujian. Proses ini bertujuan untuk memastikan bahwa model pembelajaran mesin dapat dilatih menggunakan data yang tidak mengandung bias serta diuji menggunakan data yang belum pernah dikenali sebelumnya oleh model. Pada penelitian ini, pembagian data dilakukan dengan proporsi 80% untuk pelatihan dan 20% untuk pengujian. Pemisahan ini dilakukan secara acak guna menghasilkan distribusi data yang andal dan representatif. Pembagian data yang tepat sangat krusial untuk menghindari permasalahan *overfitting*, yaitu kondisi di mana model terlalu menyesuaikan diri dengan data pelatihan sehingga gagal melakukan generalisasi secara optimal terhadap data baru.

5. *Handling Imbalanced*

Ketidakseimbangan kelas, di mana jumlah sampel yang diambil dari satu kelas jauh lebih besar daripada yang diambil dari kelas lainnya. Variabel target yang berfungsi sebagai indikator untuk memprediksi kemungkinan *churn* pada nasabah (KOLEKTIBILITAS) memiliki distribusi yang tidak seimbang data nasabah menunjukkan adanya ketimpangan kelas, dengan proporsi nasabah yang tidak *churn* jauh lebih tinggi dibandingkan yang *churn*. Untuk mengatasi masalah ini, teknik SMOTE teknik pengambilan sampel sintetis minoritas menghasilkan data sintetis untuk kelas minoritas yang merupakan bagian dari

klien yang mengalami penurunan. Dengan memberi model kesempatan yang lebih besar untuk mempelajari pola dari kelas minoritas, teknik ini meningkatkan akurasi model. Model dapat melatih untuk memprediksi kedua kelas dengan lebih baik dan lebih akurat setelah data diseimbangkan.

6. Model Training

Model yang digunakan adalah XGBoost, sebuah algoritma yang sering digunakan untuk masalah klasifikasi dan berbasis teknik *boosting*. XGBoost adalah model kelompok yang menggunakan banyak pohon keputusan untuk membuat prediksi yang lebih akurat dan kuat. Model dilatih pada set pelajaran yang telah diproses dengan XGBoost. XGBoost dapat menangani data yang tidak seimbang, mengurangi *overfitting*, dan bekerja dengan baik pada data yang besar dan kompleks. Mengoptimalkan hyperparameter untuk kinerja terbaik adalah cara pelatihan dilakukan.

7. Model Evaluation

Evaluasi model untuk mengetahui sejauh mana model dapat dengan akurat memprediksi *churn* nasabah. Evaluasi dilakukan dengan menggunakan laporan klasifikasi dan matrix kekacauan. Laporan klasifikasi memberikan metrik kinerja utama, seperti skor *precision*, skor *recall*, dan F1, yang digunakan untuk menilai kualitas prediksi model pada setiap kelas. Skor *precision* mengukur ketepatan model dalam memprediksi kelas positif, sedangkan skor *recall* mengukur kemampuan model untuk menemukan kelas positif. *F1-Score* digunakan untuk menilai akurasi model secara menyeluruh dengan mempertimbangkan *trade-off* antara *precision* dan *recall*, sehingga menghasilkan penilaian yang lebih adil dalam kasus klasifikasi biner, matriks kekacauan digunakan untuk menunjukkan berapa banyak perkiraan yang salah

dan benar untuk masing-masing kelas. Hasil evaluasi ini menunjukkan seberapa baik model memprediksi *churn* nasabah.

3.4 Pembahasan Algoritma Yang Digunakan

Berikut penjelasan tentang cara kerja sistem:

1. Inisialisasi Model

XGBoost dimulai dengan membuat sebuah model sederhana, dimana menginisialisasi model dengan parameter dasar yaitu:


```
xgb_model = XGBClassifier(  
    random_state=42, use_label_encoder=False,  
    eval_metric='mlogloss', reg_alpha=0.5, reg_lambda=1.0, max_depth=6,  
    n_estimators=200, learning_rate=0.1)
```

random state digunakan mengontrol pengacakan data pada sistem sebelum dilakukan pemisahan, *use_label_encoder* berfungsi mengkodekan label untuk klasifikasi, dan *eval_metric* digunakan untuk menetapkan *metric* evaluasi yang digunakan untuk memantau performa model selama proses *training*. Sistem secara otomatis menginisialisasi model dengan pohon keputusan pertama berdasarkan parameter ini. Berikut hasil perhitungannya:

[0]	validation_0-mlogloss:1.33178	validation_1-mlogloss:1.33574
[1]	validation_0-mlogloss:1.16944	validation_1-mlogloss:1.17988
[2]	validation_0-mlogloss:1.04766	validation_1-mlogloss:1.06588
[3]	validation_0-mlogloss:0.95872	validation_1-mlogloss:0.98058
[4]	validation_0-mlogloss:0.88568	validation_1-mlogloss:0.91106
[5]	validation_0-mlogloss:0.83036	validation_1-mlogloss:0.85969
[6]	validation_0-mlogloss:0.77833	validation_1-mlogloss:0.81117
[7]	validation_0-mlogloss:0.73711	validation_1-mlogloss:0.77335
[8]	validation_0-mlogloss:0.70074	validation_1-mlogloss:0.74066

[9]	validation_0-mlogloss:0.66254	validation_1-mlogloss:0.70609
[10]	validation_0-mlogloss:0.63791	validation_1-mlogloss:0.68317
[11]	validation_0-mlogloss:0.61687	validation_1-mlogloss:0.66319
[12]	validation_0-mlogloss:0.59996	validation_1-mlogloss:0.64878
[13]	validation_0-mlogloss:0.58079	validation_1-mlogloss:0.63131
[14]	validation_0-mlogloss:0.56263	validation_1-mlogloss:0.61471
[15]	validation_0-mlogloss:0.54540	validation_1-mlogloss:0.59769
[16]	validation_0-mlogloss:0.53056	validation_1-mlogloss:0.58419
[17]	validation_0-mlogloss:0.51480	validation_1-mlogloss:0.56909
[18]	validation_0-mlogloss:0.49789	validation_1-mlogloss:0.55333
[19]	validation_0-mlogloss:0.48266	validation_1-mlogloss:0.53918
[20]	validation_0-mlogloss:0.47076	validation_1-mlogloss:0.52910
[21]	validation_0-mlogloss:0.45943	validation_1-mlogloss:0.51914
[22]	validation_0-mlogloss:0.44873	validation_1-mlogloss:0.50934
[23]	validation_0-mlogloss:0.43705	validation_1-mlogloss:0.49896
[24]	validation_0-mlogloss:0.42366	validation_1-mlogloss:0.48730
[25]	validation_0-mlogloss:0.41559	validation_1-mlogloss:0.47985
[26]	validation_0-mlogloss:0.40388	validation_1-mlogloss:0.46918
[27]	validation_0-mlogloss:0.39467	validation_1-mlogloss:0.46047
[28]	validation_0-mlogloss:0.38662	validation_1-mlogloss:0.45252
[29]	validation_0-mlogloss:0.37961	validation_1-mlogloss:0.44649
[30]	validation_0-mlogloss:0.36997	validation_1-mlogloss:0.43783
[31]	validation_0-mlogloss:0.36445	validation_1-mlogloss:0.43222
[32]	validation_0-mlogloss:0.35785	validation_1-mlogloss:0.42674
[33]	validation_0-mlogloss:0.35065	validation_1-mlogloss:0.42039
[34]	validation_0-mlogloss:0.34287	validation_1-mlogloss:0.41369
[35]	validation_0-mlogloss:0.33457	validation_1-mlogloss:0.40668
[36]	validation_0-mlogloss:0.32892	validation_1-mlogloss:0.40168
[37]	validation_0-mlogloss:0.32481	validation_1-mlogloss:0.39846
[38]	validation_0-mlogloss:0.32031	validation_1-mlogloss:0.39418
[39]	validation_0-mlogloss:0.31106	validation_1-mlogloss:0.38645
[40]	validation_0-mlogloss:0.30392	validation_1-mlogloss:0.37953
[41]	validation_0-mlogloss:0.29887	validation_1-mlogloss:0.37571
[42]	validation_0-mlogloss:0.29165	validation_1-mlogloss:0.36896
[43]	validation_0-mlogloss:0.28668	validation_1-mlogloss:0.36507
[44]	validation_0-mlogloss:0.28105	validation_1-mlogloss:0.36010
[45]	validation_0-mlogloss:0.27542	validation_1-mlogloss:0.35616
[46]	validation_0-mlogloss:0.26995	validation_1-mlogloss:0.35151
[47]	validation_0-mlogloss:0.26648	validation_1-mlogloss:0.34871
[48]	validation_0-mlogloss:0.26103	validation_1-mlogloss:0.34413
[49]	validation_0-mlogloss:0.25468	validation_1-mlogloss:0.33836
[50]	validation_0-mlogloss:0.24814	validation_1-mlogloss:0.33285
[51]	validation_0-mlogloss:0.24252	validation_1-mlogloss:0.32827
[52]	validation_0-mlogloss:0.23869	validation_1-mlogloss:0.32524
[53]	validation_0-mlogloss:0.23512	validation_1-mlogloss:0.32279
[54]	validation_0-mlogloss:0.23193	validation_1-mlogloss:0.32140
[55]	validation_0-mlogloss:0.22917	validation_1-mlogloss:0.31891
[56]	validation_0-mlogloss:0.22481	validation_1-mlogloss:0.31498
[57]	validation_0-mlogloss:0.21937	validation_1-mlogloss:0.31097
[58]	validation_0-mlogloss:0.21513	validation_1-mlogloss:0.30829

[59]	validation_0-mlogloss:0.20978	validation_1-mlogloss:0.30369
[60]	validation_0-mlogloss:0.20588	validation_1-mlogloss:0.30064
[61]	validation_0-mlogloss:0.20314	validation_1-mlogloss:0.29844
[62]	validation_0-mlogloss:0.19980	validation_1-mlogloss:0.29606
[63]	validation_0-mlogloss:0.19825	validation_1-mlogloss:0.29514
[64]	validation_0-mlogloss:0.19458	validation_1-mlogloss:0.29224
[65]	validation_0-mlogloss:0.19213	validation_1-mlogloss:0.29038
[66]	validation_0-mlogloss:0.18917	validation_1-mlogloss:0.28844
[67]	validation_0-mlogloss:0.18778	validation_1-mlogloss:0.28733
[68]	validation_0-mlogloss:0.18543	validation_1-mlogloss:0.28530
[69]	validation_0-mlogloss:0.18348	validation_1-mlogloss:0.28390
[70]	validation_0-mlogloss:0.18098	validation_1-mlogloss:0.28159
[71]	validation_0-mlogloss:0.17810	validation_1-mlogloss:0.27887
[72]	validation_0-mlogloss:0.17532	validation_1-mlogloss:0.27771
[73]	validation_0-mlogloss:0.17256	validation_1-mlogloss:0.27527
[74]	validation_0-mlogloss:0.16991	validation_1-mlogloss:0.27370
[75]	validation_0-mlogloss:0.16788	validation_1-mlogloss:0.27303
[76]	validation_0-mlogloss:0.16618	validation_1-mlogloss:0.27171
[77]	validation_0-mlogloss:0.16400	validation_1-mlogloss:0.27042
[78]	validation_0-mlogloss:0.16229	validation_1-mlogloss:0.26934
[79]	validation_0-mlogloss:0.16067	validation_1-mlogloss:0.26855
[80]	validation_0-mlogloss:0.15877	validation_1-mlogloss:0.26672
[81]	validation_0-mlogloss:0.15695	validation_1-mlogloss:0.26536
[82]	validation_0-mlogloss:0.15468	validation_1-mlogloss:0.26391
[83]	validation_0-mlogloss:0.15319	validation_1-mlogloss:0.26333
[84]	validation_0-mlogloss:0.15130	validation_1-mlogloss:0.26240
[85]	validation_0-mlogloss:0.14952	validation_1-mlogloss:0.26084
[86]	validation_0-mlogloss:0.14757	validation_1-mlogloss:0.25956
[87]	validation_0-mlogloss:0.14542	validation_1-mlogloss:0.25805
[88]	validation_0-mlogloss:0.14277	validation_1-mlogloss:0.25570
[89]	validation_0-mlogloss:0.14060	validation_1-mlogloss:0.25434
[90]	validation_0-mlogloss:0.13878	validation_1-mlogloss:0.25267
[91]	validation_0-mlogloss:0.13696	validation_1-mlogloss:0.25111
[92]	validation_0-mlogloss:0.13421	validation_1-mlogloss:0.24919
[93]	validation_0-mlogloss:0.13247	validation_1-mlogloss:0.24786
[94]	validation_0-mlogloss:0.13057	validation_1-mlogloss:0.24714
[95]	validation_0-mlogloss:0.12883	validation_1-mlogloss:0.24617
[96]	validation_0-mlogloss:0.12705	validation_1-mlogloss:0.24460
[97]	validation_0-mlogloss:0.12597	validation_1-mlogloss:0.24356
[98]	validation_0-mlogloss:0.12428	validation_1-mlogloss:0.24273
[99]	validation_0-mlogloss:0.12308	validation_1-mlogloss:0.24175




Gambar 3.2 Learning Curve
(sumber: Google Collab, 2025)

2. Perhitungan *Gradient*


Gradient error dihitung, yang merupakan selisih antara prediksi dan nilai yang sebenarnya. *Gradient* ini digunakan untuk mengetahui arah koreksi yang diperlukan pada model berikutnya. Secara matematis, *gradient error* untuk sebuah fungsi *loss* L adalah turunan pertama dari fungsi *loss* terhadap prediksi model ($\hat{y}$).

3. Membuat Pohon Keputusan Baru

Dibangun dengan tujuan untuk mengurangi kesalahan yang dihasilkan oleh model sebelumnya. Model keputusan baru ini difokuskan untuk memperbaiki residual yang dihitung di langkah sebelumnya dengan lebih baik.



Gambar 3.3 Diagram Pohon Keputusan (yes)



Gambar 3.4 Diagram Pohon Keputusan (no,missing)

Pohon keputusan yang dihasilkan oleh model XGBoost menunjukkan proses pemilihan fitur berdasarkan kontribusi terbesar terhadap prediksi, dengan fitur seperti Plafond, Saldo_Tabungan, dan Sumber_Dana_Hasil_usaha digunakan sebagai pembagi utama. Node akar memulai pembagian data dengan *threshold* tertentu, diikuti oleh cabang-cabang yang membagi data lebih lanjut berdasarkan nilai fitur untuk meminimalkan kesalahan prediksi. Garis biru dan merah mengindikasikan jalur kondisi *True* dan *False*, sementara nilai akhir pada leaf node merepresentasikan kontribusi prediksi dari pohon ini. Pohon keputusan ini merupakan bagian dari ensemble model XGBoost, di mana kontribusi setiap pohon digabungkan secara iteratif untuk memperbaiki akurasi prediksi, menghasilkan model yang robust dalam menangani data kompleks dan variabel yang saling berpengaruh.

4. Penambahan Model Iteratif

Proses ini akan dilakukan secara diulang dengan setiap pohon keputusan baru berusaha memperbaiki kesalahan model sebelumnya. Setiap pohon ditambahkan secara bertahap dalam *boosting* untuk menghasilkan model yang lebih baik.

5. Regularisasi

Untuk menghindari *overfitting* yang mungkin terjadi akibat model yang terlalu kompleks, XGBoost menerapkan regularisasi. Regularisasi L1 dan L2 digunakan untuk membatasi ukuran dan kompleksitas pohon keputusan, dengan menambahkan penalti pada bobot pohon yang besar. Regularisasi L1 dan L2 masing-masing ditentukan oleh parameter *reg_alpha* (L1) dan *reg_lambda* (L2),

yang dimasukkan dalam proses optimasi pohon. Regularisasi L1 (*Lasso*) dan L2 (*Ridge*).

6. Prediksi Akhir

Setelah dilakukan sejumlah iterasi, XGBoost menghasilkan prediksi akhir dengan menggabungkan hasil dari semua pohon keputusan. Prediksi ini merupakan rata-rata tertimbang dari setiap pohon, yang memberikan bobot pada pohon yang lebih baik dalam mengoreksi kesalahan. Hasil dari prediksi akhir dengan metode XGboost dijelaskan dalam tabel, setiap baris mewakili nasabah dan hasil prediksi terdapat pada kolom Kolektibilitas, berikut sintaks dan tabel hasil prediksi:

```
# Encoding target agar sesuai dengan format XGBoost
y_encoded = y - y.min()
# Oversampling menggunakan SMOTE
smote = SMOTE(random_state=42)
X_resampled, y_resampled = smote.fit_resample(X, y_encoded)
# Membagi data menjadi training dan testing set
X_train, X_test, y_train, y_test = train_test_split(X_resampled, y_resampled,
test_size=0.2, random_state=42)

# STEP 5: Train Model
# Melatih model XGBoost dengan class weights
xgb_model=XGBClassifier(random_state=42,use_label_encoder=False,eval_m
etric='mlogloss',reg_alpha=0.5,reg_lambda=1.0,max_depth=6,n_estimators=20
0,learning_rate=0.1 )
xgb_model.fit(X_train, y_train)

# Membuat prediksi
y_pred = xgb_model.predict(X_test)

#Prediksi untuk seluruh data yang telah diresampling (X_resampled)
y_resampled_pred = xgb_model.predict(X_resampled)

# Menambahkan kolom prediksi KOLEKTIBILITAS pada data asli yang telah
di-resampling
data_cleaned['Prediksi_KOLEKTIBILITAS'] = pd.Series(y_resampled_pred)

# Kategorikan pelanggan berdasarkan nilai KOLEKTIBILITAS yang diprediksi
```


```
# Anggap pelanggan dengan prediksi KOLEKTIBILITAS = 0 sebagai churn,  
selainnya non-churn  
data_cleaned['Churn']=data_cleaned['Prediksi_KOLEKTIBILITAS'].apply(lam  
bda x: 'Churn' if x == 0 else 'Non-Churn')  
  
# Menampilkan beberapa baris data untuk memastikan perubahan  
print(data_cleaned[['Prediksi_KOLEKTIBILITAS','Churn']].head())  
data_cleaned.to_csv('/content/drive/MyDrive/y_pred.csv', index=False)
```



Tabel 3.3 churn prediction

PENDAPAT AN	SALDO_TA BUNGAN	RATA_RAT A_TRANSA KSI	MASA_BEK ERJA	PLAFOND	KOLEKTI BILITAS	JENIS_KELA MIN_PERE MPUAN	JENIS_KELA MIN_TIDAK TERDAFTAR	LOKASI_US AHA_Lokas i Jauh	LOKASI_US AHA_Lokas i Tidak Diketahui	STATUS_PE RKAWINAN JANDA/D UDA	STATUS_PE RKAWINAN MENIKAH	STATUS_PE RKAWINAN TIDAK TERDAFTAR	SUMBER_D ANA_HASIL USAHA	SUMBER_D ANA_KOMI SI	SUMBER_D ANA_Lainn ya	SUMBER_DANA TIDAK TERDAFTAR	Prediksi KOLEKTI BILITAS	Churn
3500000	103083.5	0	0	17000000	1	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	TRUE	0	Churn
3000000	0	37500000	3	17000000	1	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	FALSE	0	Churn
2000000	216328.5	25000000	2	2000000	1	TRUE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	FALSE	0	Churn
4000000	2689548	75000000	30	4000000	2	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	FALSE	0	Churn
3500000	103083.5	0	5	17000000	1	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	TRUE	0	Churn
2000000	0	25000000	6	10000000	1	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
3500000	103083.5	0	5	2385000	5	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	TRUE	4	Non-Churn
2000000	6869310	25000000	3	5000000	2	TRUE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	FALSE	1	Non-Churn
5000000	17831775	75000000	4	5000000	2	TRUE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
2000000	1009606	25000000	30	5000000	2	TRUE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	FALSE	1	Non-Churn
1650000	85400	25000000	7	4000000	2	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	1	Non-Churn
3000000	76485.85	37500000	3	2000000	1	FALSE	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	0	Churn
3500000	103083.5	0	5	19000000	1	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	TRUE	0	Churn
41000000	357143	1E+08	4	14000000	1	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	0	Churn
3000000	56403.12	37500000	5	62000000	1	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	FALSE	0	Churn
2E+08	103083.5	1E+08	10	13000000	1	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	FALSE	0	Churn
9327740	0	1E+08	7	8000000	1	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
6809880	5630324	75000000	3	8000000	1	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
10000000	103083.5	1E+08	14	5000000	1	TRUE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
3000000	103083.5	37500000	3	5000000	2	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
5000000	0	75000000	15	5000000	1	TRUE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	FALSE	0	Churn
5000000	1351108	75000000	24	5000000	2	TRUE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	FALSE	1	Non-Churn
1E+09	0	1E+08	10	7000000	2	FALSE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	FALSE	1	Non-Churn
2000000	52615.82	25000000	0	50000000	1	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	0	Churn
5074667	0	75000000	10	7000000	1	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
2000000	226896.4	25000000	3	8000000	1	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	0	Churn
2000000	0	25000000	3	60000000	1	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	0	Churn
2000000	219067.4	25000000	3	5000000	1	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	0	Churn
2000000	1014526	25000000	3	10000000	1	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	0	Churn
3000000	1385510	37500000	14	5000000	1	TRUE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	FALSE	1	Non-Churn
27500000	281453.9	1E+08	1	10000000	1	TRUE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
32000000	19171963	1E+08	11	14000000	1	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
1000000	65625.92	25000000	0	25000000	1	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
2000000	54607.98	25000000	2	1000000	2	TRUE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	FALSE	1	Non-Churn
4200000	400682.5	75000000	1	2000000	5	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	4	Non-Churn
4200000	51895.29	75000000	1	20000000	3	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	2	Non-Churn
4000000	0	37500000	11	9.75E+08	1	TRUE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
20000000	103083.5	1E+08	15	3510000	2	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	FALSE	1	Non-Churn
4000000	0	37500000	16	10000000	1	FALSE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
3000000	6480	37500000	0	8000000	1	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
3000000	349098.1	37500000	6	8000000	2	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
2000000	364364.6	25000000	15	6000000	2	FALSE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
20000000	103083.5	1E+08	0	1.2E+08	2	TRUE	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	0	Churn
2.5E+08	1533620	1E+08	11	1.5E+08	1	FALSE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	FALSE	0	Churn
3500000	34406171	0	5	3.35E+08	2	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	TRUE	1	Non-Churn
3000000	103083.5	37500000	0	7000000	1	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
4000000	70774.2	37500000	3	7000000	1	TRUE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	0	Churn
3000000	253961.6	37500000	4	5000000	1	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	FALSE	0	Churn
2000000	1828648	25000000	2	7000000	1	TRUE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn

3000000	9313946	37500000	4	15000000	2	TRUE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	1	Non-Churn
5000000	5050251	75000000	2	5000000	1	FALSE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
3000000	465364.6	37500000	12	1800000	2	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	FALSE	1	Non-Churn
20000000	16497414	1E+08	25	2000000	1	TRUE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
5000000	9307402	75000000	8	3000000	5	TRUE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	FALSE	4	Non-Churn
2000000	103083.5	25000000	6	5000000	1	TRUE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	FALSE	1	Non-Churn
10000000	2.15E+08	1E+08	8	4000000	1	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
8000000	1.16E+08	75000000	6	3.5E+08	1	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
30000000	111809.5	1E+08	1	1E+08	1	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	0	Churn
1200000	0	25000000	2	3E+08	1	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
3500000	103083.5	0	5	27060823	3	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	0	Churn
3500000	103083.5	0	5	2.5E+08	1	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	0	Churn
4954000	1096346	75000000	3	24000000	1	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
4954000	9996	75000000	3	5E+08	1	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
66666667	18058.9	1E+08	7	12000000	1	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	FALSE	0	Churn
3500000	460243.8	0	5	2250000	5	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	TRUE	4	Non-Churn
1.42E+08	103083.5	1E+08	10	1.5E+08	2	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	1	Non-Churn
50000000	1154390	1E+08	1	10000000	1	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
10000000	505931.4	1E+08	2	3000000	1	FALSE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
40000000	439642.6	1E+08	3	10000000	1	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	0	Churn
10000000	24586450	1E+08	0	25000000	1	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	0	Churn
5000000	67180.24	75000000	25	10000000	1	FALSE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
5000000	58196.5	75000000	0	10000000	1	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
5000000	117311.3	75000000	3	9000000	1	FALSE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
2000000	68124.59	25000000	2	2.5E+08	1	FALSE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
3000000	68556.81	37500000	9	11000000	1	FALSE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
10000000	1502710	1E+08	20	12000000	1	FALSE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
2000000	68296.84	25000000	2	8000000	1	FALSE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
3000000	67180.24	37500000	0	8000000	1	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
2000000	68124.59	25000000	1	2.35E+08	1	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
3000000	67180.24	37500000	2	2.65E+08	1	FALSE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
3000000	58196.5	37500000	0	10000000	1	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
3000000	76304.76	37500000	0	10000000	3	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	2	Non-Churn
5000000	37262.16	75000000	1	6000000	1	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
3000000	68114.23	37500000	3	2500000	1	FALSE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
5070000	997732.5	75000000	8	10000000	2	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
5070000	0	75000000	8	18000000	3	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
3500000	7591137	0	5	6E+08	1	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	TRUE	0	Churn
4000000	30005.1	37500000	14	4E+08	1	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
4000000	1365	37500000	14	6E+08	1	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
60000000	823042.1	1E+08	25	1000000	1	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	FALSE	0	Churn
4800000	0	37500000	0	15000000	1	TRUE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	FALSE	0	Churn
5000000	103958.5	75000000	3	5000000	1	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	0	Churn
5000000	0	75000000	3	3500000	1	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	0	Churn
4517736	0	75000000	3	3500000	1	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
2000000	0	25000000	10	1.7E+08	1	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	FALSE	0	Churn
3600000	53808.42	37500000	2	10000000	1	FALSE	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	2	Non-Churn
3500000	103083.5	0	5	10000000	2	FALSE	TRUE	FALSE	TRUE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	TRUE	0	Churn
10000000	0	1E+08	2	7000000	1	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	0	Churn
10000000	1830864	1E+08	2	7000000	2	FALSE	FALSE	FALSE	FALSE	TRUE	FALSE	FALSE	FALSE	FALSE	FALSE	FALSE	1	Non-Churn




Gambar 3.5 Grafik Churn Prediction

(sumber: Google Collab, 2025)

Gambar 3.5 Distribusi *Churn* vs *Non-Churn* pada Data Asli memperlihatkan adanya ketidakseimbangan distribusi kelas (*class imbalance*) pada data sebelum dilakukan proses oversampling menggunakan metode SMOTE. Jumlah nasabah dengan status *Churn* jauh lebih besar dibandingkan dengan jumlah nasabah berstatus *Non-Churn*. Kondisi ini berpotensi menimbulkan bias pada model, di mana model cenderung memprediksi kelas mayoritas (*Churn*) dan mengabaikan kelas minoritas (*Non-Churn*). Oleh karena itu, dilakukan proses penyeimbangan data menggunakan SMOTE untuk menghasilkan distribusi kelas yang lebih proporsional. Dengan demikian, model dapat mempelajari karakteristik kedua kelas secara optimal dan meningkatkan kemampuan generalisasi pada data baru.

7. Interpretasi Model dengan SHAP

Setelah model dilatih, dilakukan interpretasi menggunakan pendekatan SHAP (*SHapley Additive exPlanations*) untuk menganalisis kontribusi relatif setiap fitur terhadap hasil prediksi model. SHAP menghasilkan nilai untuk setiap fitur yang menunjukkan seberapa besar fitur tersebut mempengaruhi prediksi untuk setiap kelas. Nilai ini sangat penting dalam memberikan kejelasan dan transparansi terhadap keputusan model.



Gambar 3.6 Summary SHAP

(sumber : Google Collab, 2025)

8. Evaluasi Model

Model dievaluasi menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score* untuk mengukur seberapa baik performa model dalam memprediksi *churn* nasabah. Evaluasi ini bertujuan memberikan gambaran menyeluruh mengenai kemampuan model dalam membedakan nasabah yang *churn* dan tidak *churn*, sehingga hasilnya sebagai acuan dalam mendukung pengambilan keputusan bisnis yang lebih terarah dan tepat sasaran. Implementasi langkah-langkah ini menggunakan objek *XGBClassifier* dari pustaka XGBoost, di mana model dilatih pada data pelatihan dengan metode *fit()* dan menghasilkan prediksi pada data uji menggunakan *predict()*. Evaluasi performa model kemudian ditampilkan melalui laporan klasifikasi yang dihasilkan oleh *classification_report()*, dengan sintaks berikut:

```
report = classification_report(y_test, y_pred, target_names=[str(cls) for cls in
y_encoded.unique()]) print("XGBoost Classification Report:") print(report)
```


	precision	recall	f1-score	support
0	0.76	0.87	0.81	666
1	0.84	0.68	0.75	682
2	0.93	0.88	0.91	677
3	0.99	0.99	0.99	647
4	0.88	0.98	0.93	642
accuracy			0.88	3314
macro avg	0.88	0.88	0.88	3314
weighted avg	0.88	0.88	0.88	3314

Gambar 3.7 Laporan Klasifikasi


(sumber: Google Collab, 2025)

9. Rekomendasi nerdasarkan fitur penting

Penelitian ini tidak hanya berhenti pada klasifikasi, tetapi juga menghasilkan rekomendasi personalisasi berdasarkan fitur yang paling mempengaruhi prediksi setiap nasabah. Untuk setiap prediksi yang dibuat model, diambil tiga fitur SHAP dengan pengaruh tertinggi. Berdasarkan fitur-fitur tersebut, sistem menghasilkan saran seperti peningkatan saldo tabungan, penawaran promo transaksi, atau edukasi jangka panjang. Hal ini memberikan nilai tambah pada aplikasi prediksi dengan menciptakan tindakan yang bisa dilakukan bank terhadap nasabah.




3.5 Kerangka Pemikiran




Gambar 3.8 Diagram Kerangka pemikiran

Gambar 3.8 menampilkan alur kerja sistem prediksi *customer churn* berbasis web yang diusulkan untuk PT. BPR Magga Jaya Utama. Sistem ini dirancang untuk mengelola basis data nasabah sekaligus memprediksi tingkat *churn* secara otomatis guna mendukung proses pengambilan keputusan manajerial. Proses dimulai dari pengumpulan data nasabah

(*data collection*), pembersihan data (*data cleaning*), rekayasa fitur (*feature engineering*), pemisahan data (*data splitting*), penanganan ketidakseimbangan data (*handling imbalanced data*), pelatihan model (*model training*), dan evaluasi model (*model evaluation*) yang diimplementasikan menggunakan *Python* dan *Django*. Model pembelajaran mesin yang digunakan adalah *Extreme Gradient Boosting* (XGBoost), sedangkan interpretasi hasil prediksi dilakukan dengan metode *Shapley Additive Explanations* (SHAP). Hasil analisis kemudian divisualisasikan dalam bentuk grafik tingkat *churn* seluruh nasabah, serta disajikan rekomendasi bagi setiap nasabah untuk memudahkan intervensi yang tepat sasaran.



3.6 Perancangan UML




Gambar 3.9 Use Case Diagram

Pada gambar 3.8 menggambarkan interaksi antara aktor “ Kepala Bagian Operasional ” dengan sistem untuk melakukan prediksi *churn* pada data *customer* dan melakukan analisis terkait data *customer*. Aktor “ Kepala Bagian Operasional ” memiliki akses dan menjalankan fungsi sistem mencakup fungsi utama seperti login. Selain itu aktor dapat mengakses ke halaman utama (*Home*) untuk fungsi seperti *upload*, *read*, dan *search* data *customer*. Terdapat pula Menu *details* menampilkan data *customer* secara lengkap dibandingkan dengan menu halaman utama (*Home*) fitur manajemen *details* pelanggan, termasuk pembaruan dan penghapusan data *customer*. Selain itu, sistem menyediakan

tindakan khusus (*Actions*) yaitu prediksi *churn* (*Churn Prediction*) untuk melakukan prediksi *churn customer* menggunakan metode XGBoost dan SHAP pada data *customer* dan hasil prediksi yang telah dilakukan di visualisasikan dalam bentuk grafik dan diagram (*Visualization Chart & Graphs*).

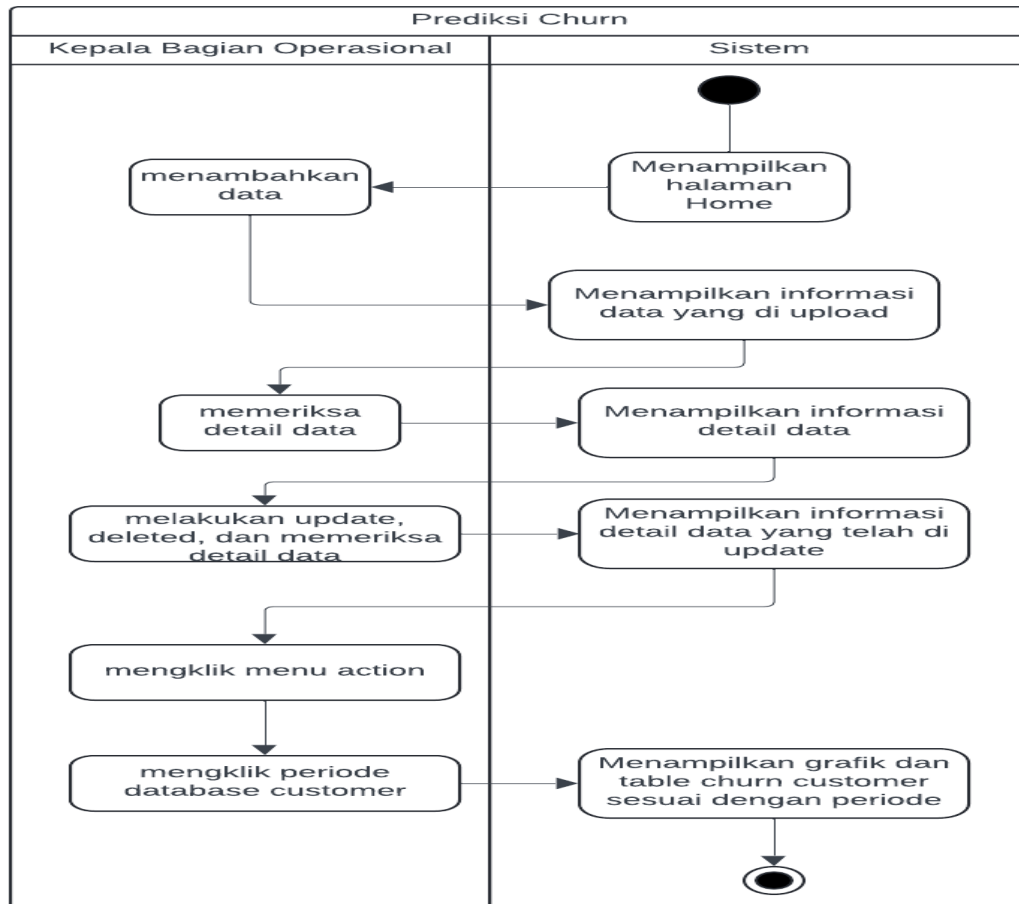
3.6.1 Activity Diagram

a. Login



Gambar 3.10 Activity Diagram Login

b. Prediksi *Churn Customers*



Gambar 3.11 Activity Diagram Prediksi Churn


3.7 Implementasi Antarmuka dan perancangan Database

3.7.1 Implementasi Antarmuka

Untuk menerjemahkan desain antarmuka pengguna yang telah dirancang dalam bentuk desain sebelum pembuatan aplikasi. Seluruh bagian menu dan tampilan dirancang sesuai dengan fungsi aplikasi atau sistem yang sedang dibangun. Implementasi ini mencakup penggunaan menu *Home*, tombol input data, tombol *search*, menu *details*, tombol aksi, tombol *update*, dan sebagainya yang digunakan untuk menerjemahkan desain visual dan interaktif menjadi bagian dari aplikasi yang dapat diakses dan digunakan


oleh pengguna akhir. Berikut implementasi antarmuka pada aplikasi yang dirancang:

a. Halaman *Home*




Gambar 3.12 Rancangan halaman *Home*

b. Halaman *Details*



Gambar 3.13 Rancangan halaman *Details*

c. Halaman *Actions*



Gambar 3.14 Rancangan halaman *Actions*

d. Halaman *Login*




Gambar 3.15 Rancangan halaman *Login*

3.7.2 Perancangan *Database* menggunakan

Entity Relationship Diagram (ERD) adalah alat visual yang berfungsi untuk menggambarkan struktur dan keterkaitan antar entitas dalam basis data relasional, serta menjelaskan alur pembentukan, penyimpanan, dan pemanfaatan data dalam sebuah sistem, sehingga membantu dalam merancang basis data yang efisien dan terstruktur. Komponen utama ERD meliputi entitas, atribut, dan relasi, Setiap entitas dalam ERD mewakili suatu objek atau konsep yang relevan dengan sistem, atribut digunakan untuk menjelaskan ciri-ciri dari entitas tersebut, dan relasi mengilustrasikan hubungan fungsional antar entitas yang saling berinteraksi. Dengan memanfaatkan ERD, pengembang dapat lebih mudah memahami kebutuhan data suatu organisasi serta interaksinya, Dengan demikian, sistem yang dikembangkan memiliki tingkat konsistensi yang lebih tinggi, mudah dipelihara, dan sesuai dengan tujuan organisasi. Berikut perancangan *database* menggunakan ERD pada sistem prediksi

churn yaitu sebagai berikut:



Gambar 3.16 Perancangan Database

3.8 Jadwal Penelitian

Untuk memastikan kelancaran pelaksanaan penelitian dan pencapaian tujuan yang telah ditetapkan, disusunlah jadwal penelitian dalam bentuk *Gantt Chart*. Jadwal ini menggambarkan tahapan kegiatan penelitian secara sistematis mulai dari perencanaan hingga penyusunan laporan akhir. Setiap aktivitas dirancang berdasarkan estimasi waktu yang realistis, sehingga dapat menjadi pedoman dalam pengelolaan waktu selama proses penelitian berlangsung.



Gambar 3.17 Gantt Chart

