

BAB I PENDAHULUAN

I.1 State of the Arts

Penelitian mengenai *ensemble supervised machine learning* pada institusi perbankan bertujuan membangun dan mengembangkan model *credit scoring*. Pendekatan ini tidak hanya bertujuan meningkatkan akurasi prediksi, tetapi juga untuk membantu perusahaan dalam mencapai efisiensi pengelolaan risiko kredit dengan meningkatkan *approval rate* dan menurunkan Tingkat NPL rate sesuai KPI Bank XYZ. Beberapa institusi perbankan masih menerapkan model *credit scoring* dengan pendekatan tradisional berbasis aturan (*rule based*) dan tanpa penerapan *machine learning*. Penelitian terdahulu yang berkaitan dengan hal tersebut adalah, Pertama “Analisis Klasifikasi Kredit Menggunakan Regresi Logistik Biner dan *Radial Basis Function Network* di Bank ‘X’ Cabang Kediri”, yang membandingkan metode klasifikasi dalam menganalisis kelayakan pemberian Kredit Tanpa Agunan (KTA), memberikan wawasan pembuatan model *credit scoring* tanpa *machine learning* dengan pendekatan *rule based* dan diharapkan untuk dapat dikembangkan serta ditinjau kembali dengan perkembangan teknologi mendatang yang relevan (Rosi Diaprina & Suhartono, 2014). Kedua, “*Credit Scoring System Using Machine Learning*”, yang memberikan tinjauan komprehensif mengenai sistem *credit scoring*, membandingkan metode tradisional dengan pendekatan *machine learning* dan hasil pendekatan *machine learning* memberikan peningkatan akurasi dalam penilaian kredit (Abhishek Kumar dkk., 2024). Ketiga, “*Sharpening the Accuracy of Credit Scoring Models with Machine Learning Algorithms*”, yang membandingkan efektivitas penggunaan model (*bagging, boosting, stacking*) dengan *decision tree* terhadap *ensemble classifier*, ditemukan bahwa *ensemble* dengan model *boosted (boosting)* memberikan akurasi, ROC-AUC tertinggi untuk dataset perbankan Australia dan Jerman dengan pola data *non linear, imbalance* dan kompleks (Consoli dkk., 2021). Keempat, “*Ensemble Learning Based Models and Deep Learning Model for Credit Prediction, Case Study: Taiwan, China*”, yang mengevaluasi beberapa model pembelajaran mesin untuk prediksi *credit default* (gagal bayar) menggunakan dataset dari Taiwan yaitu; *Logistic Regression* (LR), *Decision Tree* (DT), *Random Forest* (RF), *Extreme Gradient Boosting* (XGBoost), *Gradient Boosting Decision Trees* (GBDT) dan *Deep Neural Network* (DNN). Evaluasi kinerja model dilakukan menggunakan metode *cross-validation* dan hasil menunjukkan

bahwa model *ensemble* ini mampu menangani data besar, relasi *nonlinear* dan meningkatkan akurasi, serta XGBoost merupakan model yang paling efektif dalam akurasi dan stabilitas prediksi untuk sistem *credit scoring* berbasis data (Han, 2024). Kelima, “*Comparative analysis of boosting algorithms for predicting personal default*”, yang membandingkan algoritma *boosting* (XGBoost, AdaBoost, CatBoost & LightGBM) untuk memprediksi *personal default* menggunakan dataset dari Vietnam dengan hasil LightGBM merupakan performa model paling unggul dalam menangani dataset yang besar dan kompleks serta CatBoost untuk *credit scoring* memiliki stabilitas performa dalam berbagai skenario dataset (Nguyen & Ngo, 2025). Keterbaruan penelitian ini akan berfokus untuk membuat model *credit scoring* dengan membandingkan model-model yang sudah dijelaskan diatas diantaranya; *XGBoost*, *CatBoost*, *AdaBoost*, *LGBM*, *Random Forest* dan *Decision Tree* melalui pendekatan *ensemble machine learning* terhadap dataset pada Bank XYZ di Indonesia.

I.2 Latar Belakang

Perkembangan teknologi dan informasi pada era digital saat ini berdampak pesat, salah satunya dalam industri jasa keuangan. Percepatan digitalisasi dalam industri jasa keuangan di Indonesia telah memberikan bentuk baru pada institusi perbankan yang turut mendorong pertumbuhan bank digital (Badan Pusat Statistik Bank Indonesia, 2024). Berbeda dengan bank konvensional, bank digital menawarkan layanan perbankan secara menyeluruh melalui platform digital, tanpa interaksi fisik di kantor cabang. Inovasi ini memungkinkan masyarakat untuk mengakses layanan finansial secara cepat dan efisien melalui platform digital. Pinjaman telah terbukti menjadi salah satu bisnis utama sebagian besar bank (Chopra & Bhilare, 2018). Seperti yang ada pada bank digital, salah satu layanan utama yang ditawarkan oleh bank digital adalah pembiayaan konsumtif dalam bentuk Kredit Tanpa Agunan (KTA), yang dapat di akses melalui perangkat seluler dan identitas digital. Bank digital memanfaatkan teknologi untuk menyalurkan produk pinjaman secara online atau disebut dengan *Fintech lending/Peer-to-Peer Lending* (P2P Lending) (Otoritas Jasa Keuangan (OJK), 2018). P2P Lending diatur dan diawasi langsung oleh OJK melalui POJK No. 10/POJK.05/2022 tentang Layanan Pendanaan Bersama Berbasis Teknologi Informasi (Otoritas Jasa Keuangan, 2022).

Beberapa bank seperti Digibank by DBS dan Bank BTPN melalui BTPN Syariah telah secara aktif menyediakan layanan KTA berbasis aplikasi *mobile*, yang memungkinkan nasabah memperoleh pinjaman dalam waktu singkat hanya dengan verifikasi data digital, seperti e-KTP dan histori transaksi (Digibank by DBS, 2019), (BTPN Syariah, 2014). Seperti yang ada pada penelitian “Pemberian Kredit Tanpa Agunan (KTA) Instan Digibank Berdasarkan POJK Nomor 12/POJK.03/2018” yang menyatakan bahwa bank digital tidak menggunakan agunan dalam menyalurkan produk pinjamannya, dengan salah satu alasan proses cepat dan praktis (*Fully Digital*) (Rizal & Imaniyati, 2020). Pernyataan tersebut didukung pada Pasal 8 ayat (1) UU Perbankan mengenai bank dapat memberikan fasilitas pinjaman tanpa jaminan selama pihak bank memiliki keyakinan terhadap debitur untuk melunasi hutangnya (Badan Pembina Hukum Nasional, 1998) serta berlandaskan POJK Nomor 12/POJK.03/2018 tentang Layanan Perbankan Digital Oleh Bank Umum dihubungkan dengan prinsip kehati-hatian dan juga dihubungkan dengan manajemen risiko (Otoritas Jasa Keuangan (OJK), 2018). Transformasi ini menjadi penanda pergeseran paradigma dalam proses penilaian kelayakan kredit, dari pendekatan konvensional berbasis agunan ke pendekatan digital berbasis data. Namun demikian, Dalam mekanisme P2P *Lending*, investor atau bank tidak mengetahui stabilitas kondisi finansial dari calon debitur, kemudahan akses ini membawa tantangan baru, khususnya dalam aspek manajemen risiko kredit. Risiko utama dari layanan kredit adalah gagal bayar atau disebut *Non-Performing Loan* (NPL), sehingga lembaga keuangan digital dituntut untuk memiliki sistem penilaian kredit atau *credit scoring* yang tidak hanya akurat tetapi juga adaptif terhadap data digital, agar bisa mengurangi risiko NPL yang dapat merugikan bank (Mendrofa dkk., 2023).

Dalam praktiknya, beberapa institusi keuangan masih mengandalkan model konvensional seperti regresi logistik berbasis *rule based* atau base model, hal ini dilakukan karena melihat urgensi, lingkup dan kondisi dari perusahaan itu sendiri. Penelitian mengenai hal tersebut telah dilakukan sebelumnya, membandingkan tiga metode klasifikasi *k-Nearest Neighbor*, regresi logistik biner, dan pohon klasifikasi dalam menganalisis kelayakan pemberian Kredit Tanpa Agunan (KTA). Meskipun ketiga metode dianalisis, fokus pada regresi logistik biner memberikan wawasan tentang penggunaannya dalam analisis kredit tanpa melibatkan teknik *machine learning* dan penerapan *base model*, kemudian hasil penelitian diharapkan untuk dapat ditinjau kembali dengan perkembangan teknologi

mendatang yang relevan (Rosi Diaprina & Suhartono, 2014). Dalam penerapannya juga memiliki keterbatasan dalam menangkap kompleksitas hubungan nonlinier antar *variable* yang biasa terjadi pada pola transaksi maupun rekam jejak pembayaran.

Sebagai respons terhadap tantangan tersebut, penggunaan *machine learning* dalam membuat model *credit scoring* telah terbukti memberikan keunggulan signifikan dibandingkan pendekatan tradisional berbasis aturan (*rule based*). Dimana *machine learning* merupakan salah satu cabang kecerdasan *Artificial Intelligent* (AI) yang memungkinkan sistem komputer untuk belajar dan meningkatkan kinerjanya dari pengalaman tanpa diprogram secara eksplisit dengan menggunakan metode algoritma untuk proses belajarnya (Yusoff, 2024). Kemudian dapat menangkap kompleksitas hubungan nonlinier antar *variable* tidak hanya menggunakan metode tunggal, melainkan menggunakan pendekatan model dengan menggabungkan beberapa model tunggal atau disebut dengan *ensemble machine learning* yang dapat memberikan peningkatan hasil positif seperti akurasi prediksi dibandingkan metode individual atau klasifikasi tunggal (Perera & Premaratne, 2024). Hasil klasifikasi dalam model *credit scoring* berbentuk label yang biasa digunakan untuk memprediksi status pinjaman atau kredit dalam kategori NPL/*bad customer*/tidak layak dan Performing Loan (PL)/*good customer*/layak (Febriyanti & Rizky Izzalqurny, 2023).

Penerapan *ensemble machine learning* tidak hanya menggunakan klasifikasi tunggal melainkan menggabungkan beberapa model dengan menggunakan data berlabel yang dinamakan *ensemble supervised learning*. Pendekatan berbasis *machine learning* khususnya metode *ensemble supervised learning* seperti *Random Forest*, *Gradient Boosting*, dan *XGBoost*, menjadi semakin relevan. Algoritma-algoritma ini mampu menangani data dalam jumlah besar, mengakomodasi hubungan nonlinier, serta meningkatkan akurasi prediksi risiko kredit (Han, 2024). Beberapa penelitian sebelumnya telah menunjukkan bahwa penggunaan *ensemble machine learning* dalam *credit scoring* secara konsisten menghasilkan performa yang lebih baik dibandingkan dengan metode statistik tradisional (Li & Chen, 2020; Zhu dkk., 2024). Dalam penelitian berikut juga membandingkan kinerja lima metode *ensemble supervised learning* (*Random Forest*, *AdaBoost*, *XGBoost*, *LightGBM*, dan *Stacking*) dalam konteks *credit scoring*. Hasilnya menunjukkan bahwa model *ensemble supervised learning*, khususnya yang

menggunakan teknik *boosting*, secara konsisten mengungguli model individual seperti regresi logistik dalam hal akurasi dan AUC (Li & Chen, 2020).

Latar belakang tersebut selaras dengan studi kasus yang diangkat dalam penelitian ini, bertujuan untuk membangun dan mengevaluasi model *credit scoring* berbasis metode *ensemble supervised learning* untuk pinjaman multiguna maupun KTA pada bank digital. Dalam rangkaian teknik *machine learning* yang diadopsi untuk penelitian ini, sample data menggunakan catatan transaksi pinjaman dari Bank XYZ yang dikategorikan ke dalam dua dimensi kredit, yaitu NPL sebagai representasi nasabah bermasalah (*bad customer*) dan PL sebagai representasi nasabah baik (*good customer*). Dalam menyusun dan menyelesaikan proses penelitian ini secara sistematis, digunakan pendekatan CRISP-DM (*Cross-Industry Standard Process for Data Mining*) sebagai kerangka kerja utama yang terdiri dari enam tahapan, yakni: pemahaman bisnis (*business understanding*), pemahaman data (*data understanding*), persiapan data (*data preparation*), pemodelan (*modeling*), evaluasi (*evaluation*), dan penerapan (*deployment*). Dalam konteks penelitian ini, CRISP-DM digunakan untuk mengidentifikasi kebutuhan bisnis terkait prediksi risiko kredit, memahami karakteristik data digital yang tersedia, serta merancang dan membandingkan performa model *machine learning*, khususnya metode *ensemble supervised learning*, guna memperoleh model *credit scoring* yang paling optimal untuk mendukung pengambilan keputusan pada layanan bank digital.

Permasalahan utama yang menjadi dasar penelitian ini adalah belum tercapainya parameter performa risiko kredit yang ditetapkan oleh Bank XYZ untuk produk X. Berdasarkan data posisi akhir tahun 2023, tingkat NPL tercatat sebesar 4%, melebihi ambang batas yang ditetapkan perusahaan yaitu sebesar 3%. Sementara itu, nilai *approval rate* hanya mencapai 65%, berada di bawah target *Key Performance Indicator* (KPI) yang telah ditetapkan adalah sebesar 70%. Fakta ini mengindikasikan bahwa sistem *credit scoring* yang digunakan saat ini belum mampu secara efektif menyeimbangkan antara akurasi deteksi risiko gagal bayar dan potensi ekspansi bisnis melalui persetujuan kredit. Oleh karena itu, hasil dari penelitian ini diharapkan dapat memberikan kontribusi empiris dan praktis terhadap peningkatan *approval rate* dan menurunkan tingkat NPL berbasis teknologi, guna mendukung pencapaian parameter risiko yang dapat diterima dan ditargetkan oleh Bank XYZ serta dapat menghasilkan model yang aplikatif dalam konteks perbankan digital.

I.3 Rumusan Masalah

Dalam mengidentifikasi masalah-masalah terkait pembuatan model *credit scoring*, berdasarkan hasil dari pencarian literatur dan wawancara narasumber pada bagian latar belakang, penulis mengidentifikasi permasalahan yang diangkat pada penelitian ini adalah sebagai berikut :

1. Bagaimana membangun model *credit scoring* yang efektif menggunakan metode *ensemble supervised machine learning* untuk memprediksi risiko kredit pada layanan pinjaman digital di Bank XYZ?
2. Model *ensemble supervised learning* mana yang memberikan performa terbaik dalam memprediksi klasifikasi nasabah PL dan NPL berdasarkan data pinjaman digital? Faktor apa saja yang mempengaruhi?
3. Bagaimana perbandingan kinerja model *ensemble supervised learning* terhadap model pembelajaran Tunggal (*single supervised learning*) dalam hal akurasi, presisi, recall dan ROC-AUC dalam konteks *credit scoring*?
4. Apakah penerapan model *credit scoring* berbasis *ensemble supervised learning* dapat membantu menurunkan Tingkat NPL menjadi di bawah batas maksimum 3% dan meningkatkan *approval rate* mendekati target KPI sebesar 70% pada produk X di Bank XYZ dibandingkan pendekatan tradisional (*rule based*)?

Melalui penelitian ini, diharapkan tidak hanya membangun model *credit scoring* berbasis *ensemble supervised machine learning*, tetapi juga mengaikatnya secara langsung dengan permasalahan nyata di institusi keuangan digital, terutama dapat menjadi solusi alternatif untuk penanganan risiko kredit produk X di Bank XYZ.

I.4 Batasan Masalah

Penelitian ini memiliki beberapa batasan yang perlu diperjelas untuk memastikan ruang lingkup yang terarah dan terfokus. Adapun batasan masalah yang ada pada penelitian ini adalah sebagai berikut :

1. Data yang digunakan merupakan data historis transaksi pinjaman konsumtif (Produk X) dari Bank XYZ selama periode tertentu, dan tidak mencakup produk pinjaman lain seperti pinjaman modal usaha atau KPR.

2. Penelitian hanya berfokus pada model klasifikasi berbasis *supervised learning* dan tidak membahas metode *unsupervised* atau *reinforcement learning*.
3. Model yang dikembangkan hanya membandingkan beberapa algoritma *ensemble supervised learning* yaitu *Random Forest*, *AdaBoost*, *XGBoost*, *LightGBM* dan *CatBoost*.
4. Evaluasi model terbatas pada metrik performa klasifikasi dan keterkaitannya dengan indikator bisnis seperti NPL dan *approval rate*, tanpa membahas aspek regulasi, privasi data, atau interpretabilitas model secara mendalam.
5. Penerapan hasil model hanya bersifat simulatif dan belum mencakup implementasi langsung ke dalam sistem produksi Bank XYZ.

Dengan batasan-batasan ini, penelitian ini bertujuan untuk memberikan solusi yang terarah dalam pembuatan model model *credit scoring* berbasis metode *ensemble supervised machine learning* untuk pinjaman konsumtif maupun KTA pada bank digital khususnya Produk X pada Bank XYZ.

I.5 Lingkup Penelitian

Penelitian ini difokuskan pada pengembangan dan evaluasi model *credit scoring* berbasis *ensemble supervised machine learning* dalam konteks perbankan digital, dengan studi kasus pada produk pinjaman konsumtif (produk X) milik Bank XYZ. Adapun lingkup penelitian ini dijelaskan sebagai berikut:

1. Objek Penelitian

Penelitian ini berfokus pada pemodelan *credit scoring* untuk nasabah pengguna produk pinjaman konsumtif (produk X) di Bank XYZ. Produk ini merupakan jenis pinjaman tanpa agunan (KTA) yang ditawarkan secara digital.

2. Sumber dan Periode Data

Dataset yang digunakan merupakan data historis transaksi pinjaman multiguna produk X yang dihimpun dari sistem internal Bank XYZ, mencakup periode tahun 2022 – 2023, di mana melihat *performance window* ada pada posisi 31 Desember 2024 (karena tenor maksimum ada di 12 bulan & pinjaman sudah *mature*). Data mencakup informasi terkait aplikasi kredit, profil debitur, dan hasil evaluasi pinjaman.

3. Dimensi Risiko Kredit

Analisis risiko kredit dilakukan dengan mengelompokkan nasabah ke dalam dua kategori utama, yaitu:

1. *Performing Loan* (PL) adalah, nasabah yang melakukan pembayaran pinjaman sesuai ketentuan dan dikategorikan sebagai (*good customer*).
2. *Non-Performing Loan* (NPL) adalah, nasabah yang gagal bayar atau mengalami keterlambatan pembayaran signifikan dan dikategorikan sebagai (*bad customer*), sesuai definisi internal Bank XYZ.

4. Ruang Lingkup Model

Model yang dibangun terbatas pada penggunaan metode *ensemble supervised machine learning*, yaitu *AdaBoost*, *XGBoost*, dan *CatBoost*. Model-model ini dibandingkan dengan model baseline (misalnya *logistic regression*) untuk melihat peningkatan performa prediktif.

5. Metrik Evaluasi

Kinerja model dievaluasi menggunakan metrik klasifikasi yang umum digunakan dalam pengembangan sistem *credit scoring*, meliputi akurasi, *precision*, *recall*, *F1-score*, dan *Area Under the Curve* (AUC).

6. Tujuan Bisnis yang Diukur

Model yang dibangun ditujukan untuk membantu Bank XYZ mencapai dua target utama produk X:

- Menurunkan rasio NPL ke bawah batas maksimal 3%.
- Meningkatkan *approval rate* hingga mencapai minimal 70%.


7. Batasan Sistematis

Penelitian ini tidak mencakup aspek implementasi langsung ke dalam sistem operasional Bank XYZ, serta tidak membahas aspek hukum, regulasi, atau privasi data secara detail. Fokus penelitian hanya pada pengembangan model prediktif berbasis data historis Produk X tipe pinjaman konsumtif berbasis digital.

I.6 Kesenjangan Penelitian

Analisis kesenjangan merupakan proses penting dalam penelitian untuk mengidentifikasi perbedaan antara kondisi aktual dengan kondisi yang diharapkan. Tujuannya adalah untuk memahami kebutuhan yang belum terpenuhi serta menemukan area yang perlu diperbaiki dalam suatu organisasi. Dalam konteks ini, metode seperti *fishbone* diagram

dapat dimanfaatkan sebagai alat visual untuk menggambarkan dan mengevaluasi kesenjangan yang terjadi pada hasil penilaian risiko kredit Bank XYZ.



Gambar I-1 Fishbone hasil penilaian risiko kredit Bank XYZ

Kesenjangan yang teridentifikasi dalam *fishbone* pada penelitian ini adalah, penggunaan teknologi dalam proses penilaian kredit masih mengandalkan metode statistik tradisional yang bersifat linear dan kurang adaptif terhadap pola perilaku nasabah yang kompleks dan dinamis. Selain itu, belum adanya integrasi *machine learning* khususnya metode *ensemble* seperti *Random Forest*, *AdaBoost*, *CatBoost* atau *Gradient Boosting* yang terbukti unggul dalam menangani data kompleks untuk pembuatan model *credit scoring* (Li & Chen, 2020). Hal ini menjadi hambatan dalam meningkatkan performa model, terutama dalam menurunkan Tingkat kredit bermasalah (NPL) dan meningkatkan *approval rate*. Disisi lain, institusi juga belum memiliki kerangka kerja *Machine Learning Operations* (MLOps) yang memungkinkan pengelolaan dan pembaruan model secara berkala. Hal ini juga diperparah dengan keterbatasan Sumber Daya Manusia (SDM) yang kurang memenuhi secara kuantitas seperti *Data Scientist* yang berperan sekaligus menjadi MLOps, sehingga peran yang seharusnya dijalankan menjadi kurang optimal dan dapat menurunkan kualitas dan produk yang diharapkan. Meskipun *machine learning*, khususnya pendekatan *ensemble supervised learning*, terbukti mampu meningkatkan performa model *credit scoring*, institusi keuangan digital dalam penelitian ini masih menggunakan pendekatan tradisional (*rule based*) dan belum memanfaatkan teknologi tersebut. Kesenjangan inilah yang mendorong perlunya penelitian untuk membangun dan mengevaluasi model *credit scoring* berbasis *ensemble supervised learning* sebagai solusi untuk mengatasi keterbatasan pendekatan tradisional yang selama ini digunakan dan tidak hanya membangun serta mengevaluasi, tetapi juga mengaitkannya secara langsung dengan permasalahan nyata di institusi keuangan digital,

seperti pencapaian KPI risiko kredit (NPL) dan ekspansi bisnis (*approval rate*), dengan pendekatan yang terstruktur dan aplikatif.

I.7 Tujuan Penelitian

Tujuan penelitian ini didasari oleh identifikasi dari perumusan masalah yang telah dilakukan, sebagai berikut :

1. Membangun model *credit scoring* berbasis *ensemble supervised learning* guna memprediksi risiko kredit pada layanan pinjaman konsumtif (Produk X) di Bank XYZ.
2. Membandingkan performa beberapa algoritma *ensemble supervised learning* seperti *Random Forest*, *AdaBoost*, *LightGBM*, *XGBoost*, dan *CatBoost* dengan metode Tunggal yaitu *Decision Tree* dalam mengklasifikasikan nasabah *good customer* dan *bad customer*.
3. Mengevaluasi kinerja model yang dibangun dengan menggunakan metrik evaluasi seperti *precision*, *recall*, *F1-score*, dan *ROC-AUC*.
4. Mengkaji kontribusi model *credit scoring* terhadap penurunan tingkat NPL dan peningkatan *approval rate* sesuai dengan target *Key Performance Indicator* (KPI) produk X di Bank XYZ.

Adapun tujuan penelitian ini diharapkan dapat memberi manfaat atau kontribusi baik secara keilmuan maupun praktik dalam membua model *credit scoring* dengan *ensemble supervise learning* untuk institusi perbankan digital.

I.8 Manfaat Penelitian

Penelitian ini diharapkan dapat memberi manfaat atau kontribusi baik secara keilmuan maupun praktik. Secara keilmuan, penelitian ini diharapkan dapat berkontribusi dalam memberi alternatif model algoritma *credit scoring* terutama model algoritma yang menggunakan teknik *ensemble supervised learning*. Selain itu penelitian ini diharapkan dapat menambah *body of knowledge* dari sistem informasi khususnya domain pengembangan algoritma *machine learning* pada institusi keuangan digital. Kontribusi yang kedua adalah secara praktik dapat membantu institusi keuangan digital yaitu bank XYZ dalam meningkatkan *approval rate* untuk mengurangi tingkatan dari NPL. Hal ini didasari atas hasil pengukuran performa algoritma yang ada pada saat ini masih belum

optimal, masih dalam pendekatan tradisional (*rule based*) dan penggunaan algoritma yang masih sederhana, serta belum menerapkan pendekatan *machine learning* dalam proses *credit scoring* untuk menghasilkan *approval rate* dan tingkat NPL yang sesuai dengan target segmentasi Produk X. Dengan melakukan kajian secara ilmiah, maka rancangan model algoritma diharapkan dapat diterapkan pada sistem *credit scoring* bank XYZ.

I.9 Rasionalisasi Penelitian

Dalam era transformasi digital yang semakin pesat, institusi perbankan digital menghadapi tantangan yang semakin kompleks dalam mengelola risiko kredit, khususnya dalam proses pemberian pinjaman secara cepat dan tepat. Salah satu aspek krusial dalam manajemen risiko tersebut adalah sistem *credit scoring*, yaitu mekanisme evaluasi kelayakan kredit calon debitur berdasarkan data historis dan karakteristik perilaku finansial. Model *credit scoring* yang andal tidak hanya berperan dalam menjaga kualitas portofolio kredit, tetapi juga menjadi fondasi penting dalam mencapai keseimbangan antara ekspansi bisnis dan mitigasi risiko gagal bayar. Namun, pendekatan tradisional yang selama ini digunakan dalam membangun sistem *credit scoring*, seperti regresi logistik sederhana dan pendekatan tradisional (*rule based*) sering kali memiliki keterbatasan dalam menangkap hubungan non-linier, serta interaksi kompleks antar fitur dalam data nasabah. Hal ini berdampak pada keterbatasan akurasi model dalam mengklasifikasikan nasabah secara tepat, yang pada akhirnya dapat memengaruhi kinerja risiko kredit dan tingkat persetujuan pinjaman di institusi perbankan.

Seiring dengan kemajuan teknologi *machine learning*, metode *ensemble supervised learning* telah muncul sebagai pendekatan yang lebih adaptif dan kuat dalam membangun model prediktif, termasuk dalam konteks *credit scoring*. Teknik *ensemble* seperti *AdaBoost*, *XGBoost*, *CatBoost*, *LGBM*, *Random Forest* menggabungkan beberapa model dasar untuk menghasilkan prediksi yang lebih akurat dan stabil. Penggunaan metode ini diyakini mampu memberikan solusi yang lebih optimal dibandingkan model tunggal dalam mengklasifikasikan risiko kredit nasabah.

Penelitian ini dilatarbelakangi oleh permasalahan konkret yang terjadi di Bank XYZ, di mana tingkat NPL pada produk X per akhir tahun 2023 tercatat sebesar 4%, melebihi batas toleransi perusahaan sebesar 3%. Selain itu, tingkat *approval rate* hanya mencapai

65%, lebih rendah dari target KPI sebesar 70%. Fakta ini menunjukkan bahwa sistem *credit scoring* yang digunakan saat ini belum mampu menyeimbangkan secara efektif antara mitigasi risiko dan optimalisasi bisnis. Oleh karena itu, diperlukan model *credit scoring* yang lebih canggih dan adaptif terhadap dinamika data digital. Berdasarkan latar belakang tersebut, penelitian ini dirancang untuk membangun dan mengevaluasi model *credit scoring* dengan menggunakan pendekatan *ensemble supervised machine learning* pada institusi perbankan digital. Diharapkan, hasil dari penelitian ini tidak hanya memberikan kontribusi teoretis terhadap pengembangan ilmu di bidang *data science* dan *machine learning*, tetapi juga memberikan manfaat praktis dalam meningkatkan kualitas pengambilan keputusan kredit, efisiensi operasional, serta penguatan sistem manajemen risiko di era perbankan digital.

I.10 Pertanyaan Penelitian

Dalam mengidentifikasi permasalahan-permasalahan terkait pembuatan model *credit scoring*, berdasarkan hasil dari pencarian literatur dan wawancara narasumber pada bagian latar belakang, perumusan masalah maupun pada subbab sebelumnya penulis mengidentifikasi permasalahan yang diangkat pada penelitian ini. Hasil identifikasi permasalahan tersebut digunakan sebagai dasar dalam merumuskan masalah penelitian berupa *research question* atau pertanyaan penelitian. Dari permasalahan tersebut, peneliti telah merumuskan satu pertanyaan penelitian atau *research question* sebagai berikut :

1. Bagaimana kinerja model *credit scoring* berbasis *ensemble supervised learning* dibandingkan dengan model pembelajaran tunggal (*single supervised learning*) dalam memprediksi risiko kredit pada institusi perbankan digital?
2. Sejauh mana metode *ensemble supervised learning* mampu meningkatkan akurasi prediksi terhadap klasifikasi nasabah *good customer* (PL) dan *bad customer* (NPL) dalam konteks pinjaman konsumtif atau tanpa agunan (KTA)?
3. Model *ensemble supervised learning* mana yang paling optimal dalam membangun sistem *credit scoring* berdasarkan data transaksi pinjaman digital di Bank XYZ?
4. Apakah model *credit scoring* yang dibangun menggunakan *ensemble supervised learning* dapat membantu menurunkan tingkat NPL dan meningkatkan *approval rate* sesuai dengan target KPI Bank XYZ untuk produk X?

I.11 Signifikansi Penelitian

Penelitian ini memiliki signifikansi kuat dalam pengembangan teknologi untuk membuat model *credit scoring* pada produk X di Bank XYZ, dimana pada studi kasus yang diambil masih menerapkan pendekatan tradisional (*rule based*) sehingga hasil yang diharapkan institusi dalam lingkup tingkat NPL dan juga *approval rate* masih belum memenuhi target KPI Perusahaan. Mengembangkan model *credit scoring* dengan metode *ensemble supervised machine learning* menggunakan algoritma *AdaBoost*, *XGBoost*, *CatBoost*, *LGBM*, *Random Forest* dan *Decision Tree* diharapkan dapat menjadi solusi dari permasalahan tersebut dan juga penelitian ini diharapkan dapat memberikan kontribusi sebagai berikut :

A. Secara Teoretis / Keilmuan

- Menambah literatur ilmiah mengenai penerapan *ensemble supervised machine learning* dalam konteks *credit scoring* pada sektor perbankan digital, khususnya di Indonesia.
- Memberikan analisis perbandingan antar model *ensemble* dalam konteks data historical pinjaman digital.

B. Secara Praktis

- Menyediakan solusi alternatif berbasis teknologi dalam pengembangan sistem *credit scoring* yang lebih akurat, efisien, dan adaptif.


Membantu pihak manajemen risiko dan kredit di Bank XYZ dalam menurunkan tingkat NPL dan meningkatkan *approval rate* sesuai target KPI.

I.12 Tantangan Penelitian

Penelitian ini menghadapi sejumlah tantangan yang perlu diantisipasi sejak tahap perancangan hingga evaluasi model. Tantangan utama terletak pada kualitas dan karakteristik data historis pinjaman konsumtif yang digunakan, seperti adanya data yang tidak lengkap, *noise*, atau *outlier*, yang dapat memengaruhi performa model. Selain itu, meskipun teknik *ensemble supervised learning* diketahui unggul dalam meningkatkan ROC-ACU serta akurasi prediksi, model ini cenderung lebih kompleks dan sulit diinterpretasikan, sehingga dapat menyulitkan dalam konteks audit internal dan pertanggungjawaban keputusan kredit.

Tantangan lainnya adalah menyeimbangkan antara peningkatan akurasi model dengan pencapaian tujuan bisnis, yaitu penurunan rasio *Non-Performing Loan* (NPL) hingga di bawah batas 3% dan peningkatan *approval rate* diatas 70% untuk produk X. Pengembangan model yang terlalu ketat bisa menurunkan *approval rate*, sementara model yang terlalu longgar dapat meningkatkan risiko kredit. Selain itu, proses *tuning* model dan validasi performa membutuhkan pemilihan parameter dan metrik evaluasi yang tepat agar hasil yang diperoleh benar-benar optimal dan dapat diterapkan dalam konteks operasional bank digital. Seluruh tantangan ini menuntut pendekatan penelitian yang sistematis, pemahaman mendalam terhadap domain keuangan, serta pemanfaatan metodologi seperti CRISP-DM untuk memastikan proses berjalan terstruktur dan berbasis kebutuhan bisnis yang nyata.

I.13 Sistematika Penulisan



Gambar I-2 Sistematika Penulisan

Sistematika penulisan terbagi menjadi beberapa bab serta subbab yang dilampirkan pada Gambar 1-2 Sistematika Penulisan dibawah ini. Bab I menjelaskan *state of the art*, latar belakang penelitian, perumusan masalah, batasan, lingkup peneltiain, kesenjangan serta tujuan yang ingin dicapai. Bab II berisi tinjauan pustaka, membahas teori-teori dasar serta penelitian terdahulu yang menjadi landasan penelitian ini. Bab III berisikan rencana perancangan penelitian, konseptual model, sistematika penelitian dan sumber data penelitian. Kemudian Bab IV, menyajikan hasil penelitian, mulai dari preprocessing data hingga validasi model prediksi. Selanjutnya Bab V menganalisis dan mendiskusikan hasil penelitian, termasuk proses pengembangan model credit scoring berbasis ensemble supervised learning menggunakan algoritma *AdaBoost*, *XGBoost*, *CatBoost*, *LGBM*, *Random Forest* dan *Decision Tree* untuk penanganan risiko kredit Produk X pada Bank XYZ. Terakhir, Bab VI merangkum temuan utama penelitian dan memberikan saran untuk pengembangan lebih lanjut. Struktur ini dirancang untuk memastikan penelitian memiliki alur yang jelas, dari perumusan masalah hingga rekomendasi implementasi.