

BAB I

PENDAHULUAN

1.1 Latar Belakang

Penyaluran kredit perbankan tetap menjadi sumber utama pendanaan bagi sektor riil, tetapi keputusan kredit yang keliru akan langsung tercermin pada kualitas aset dan kebutuhan pencadangan. Peralihan ke PSAK 71 memperketat kebutuhan pengukuran risiko karena cadangan kerugian penurunan nilai dihitung berbasis *Expected Credit Loss* (ECL) yang memisahkan ECL 12 bulan dan lifetime, serta memasukkan informasi *forward looking* untuk menangkap perubahan kualitas kredit lebih dini (Rahayu, 2021).

Dalam kerangka ECL, *Probability of Default* (PD) bukan sekadar angka model, melainkan input yang harus konsisten dengan profil risiko debitur dan dinamika ekonomi. Studi determinan PD pada perbankan menunjukkan PD dipengaruhi oleh profil risiko kredit, target pertumbuhan kredit, serta variabel makroekonomi seperti PDB, inflasi, dan nilai tukar, sehingga penilaian risiko perlu mempertimbangkan kondisi ekonomi yang berubah (Hartanto & Setijaningsih, 2023). Dari sisi pasar modal, kebijakan pencadangan berbasis IFRS 9/PSAK 71 juga relevan karena ditemukan adanya respons investor terhadap implementasi standar tersebut pada perusahaan perbankan Indonesia (Firmansyah et al., 2023). Pada level sistemik, informasi probabilitas gagal bayar per bank penting bagi rancangan mekanisme premi penjaminan berbasis risiko dan penguatan stabilitas sistem keuangan (Wijoyo, 2021).

Transformasi risiko kredit juga didorong digitalisasi layanan keuangan, termasuk kartu kredit dan pembiayaan digital, yang memperkaya data tetapi menambah kompleksitas pola perilaku debitur. Pada konteks nasabah kartu kredit, pendekatan *machine learning* dan deep learning dilaporkan meningkatkan kualitas prediksi gagal bayar dibanding metode tradisional karena mampu menangkap hubungan nonlinier dan interaksi fitur (Chang et al., 2024). Di platform peer-to-peer lending, kebutuhan model prediksi makin kuat karena pertumbuhan portofolio

biasanya disertai masalah ketidakseimbangan kelas antara peminjam lancar dan bermasalah (Souadda et al., 2025). Isu ketidakseimbangan ini juga muncul pada penyesuaian *credit scoring* di entitas ekonomi solidaritas, di mana metodologi yang menekankan strategi penanganan kelas minoritas diperlukan agar debitur berisiko tidak “hilang” dalam prediksi (Bermudez Vera et al., 2025).

Pada ranah pemodelan, *Logistic Regression* (LR) dan *Random Forest* (RF) sering dipertandingkan karena mencerminkan kompromi interpretabilitas dan kekuatan prediksi. Studi komparatif LR, RF, dan XGBoost pada klasifikasi persetujuan pinjaman menegaskan LR dapat menjadi baseline yang kompetitif sekaligus mudah dijelaskan (Putra, 2025). Sebaliknya, pada klasifikasi kelayakan penerimaan kredit, RF dilaporkan menghasilkan kinerja lebih tinggi daripada LR pada metrik evaluasi yang digunakan (Adrian et al., 2025). Dalam konteks *credit scoring*, evaluasi juga tidak cukup berhenti pada akurasi karena metrik seperti *F1-Score* dan AUC diperlukan untuk memahami kemampuan diskriminasi model (Billy Riantono & Andarsyah, 2024). Pada kasus Home Credit, penggunaan teknik penyeimbangan seperti SMOTE dilaporkan meningkatkan performa model dan membuat RF menjadi pilihan dengan hasil terbaik pada beberapa metrik (Yulianti et al., 2024). Pada pembiayaan kendaraan, model prediksi risiko berbasis data mining menunjukkan algoritma *machine learning* dapat membantu mengidentifikasi potensi kredit bermasalah lebih dini dan meningkatkan efisiensi seleksi kredit (Permadani et al., 2025). Dalam pembiayaan mikro, LR digunakan untuk penilaian awal yang mudah dijelaskan, sedangkan RF digunakan untuk memprediksi kelayakan top-up dan mengelompokkan risiko nasabah ke beberapa kategori (Azam & Qoiriah, 2025). Pada dataset *Loan Approval*, RF juga dilaporkan memberikan performa terbaik dibanding algoritma klasifikasi lain dalam prediksi persetujuan pinjaman, sehingga mendukung otomatisasi keputusan kredit (Ichlasul et al., 2025).

Di tingkat teknis, performa model sangat dipengaruhi oleh pra-pemrosesan dan pengaturan hyperparameter. Penerapan *hyperparameter tuning* melalui *Grid Search Cross Validation* dilaporkan mampu meningkatkan kinerja prediksi pada beberapa algoritma dalam konteks risiko kredit (Ismunandar et al., 2024).

Kombinasi preprocessing dan *hyperparameter tuning* juga dilaporkan dapat mengubah peringkat model terbaik di antara beberapa algoritma, menandakan rancangan pipeline berpengaruh langsung pada hasil evaluasi (Nur Rais et al., 2025). Namun peningkatan performa sering berhadapan dengan tantangan interpretabilitas, karena model kompleks cenderung dipersepsikan sebagai black box. Pendekatan *Explainable AI* seperti LIME dapat digunakan untuk menjelaskan kontribusi fitur secara lokal pada prediksi individual dan membantu menguji konsistensi keputusan model (Aljadani et al., 2023). Studi lain menunjukkan metode XAI seperti SHAP, ALE, *Anchor*, dan *ProtoDash* dapat memberikan penjelasan global maupun lokal sehingga meningkatkan transparansi *credit scoring* dalam konteks operasional bank (Setiawan et al., 2025). Selain XAI, desain ansambel yang memasukkan pengetahuan domain juga dikembangkan melalui domain-constrained stacking untuk menggabungkan kekuatan model linier dan nonlinier sekaligus menjaga konsistensi dengan praktik industri (Ding et al., 2025).

Berdasarkan landasan tersebut, penelitian **“Perbandingan Algoritma *Random Forest* dan *Logistic Regression* untuk Prediksi Risiko Kredit Berdasarkan Data Pinjaman Bank Mandiri”** difokuskan pada pembuktian empiris di konteks bank komersial besar, dengan protokol evaluasi yang sensitif terhadap ketidakseimbangan kelas. Penelitian ini menggunakan dataset “DATA KREDIT” yang memuat 8.032 observasi dan 55 variabel; proporsi kelas bermasalah relatif kecil (sekitar 4% bila kolektibilitas 3–5 diperlakukan sebagai bermasalah), dataset yang digunakan merupakan snapshot pada satu periode pelaporan dan terbatas pada cakupan wilayah/unit operasional tertentu, sehingga generalisasi ke seluruh portofolio Bank Mandiri dilakukan secara hati-hati, sehingga evaluasi akan menitikberatkan metrik yang relevan untuk kelas minoritas seperti *Recall*, *F1-Score*, dan AUC.

Selain membandingkan performa LR dan RF secara kuantitatif, penelitian ini juga menghubungkan hasil prediksi dengan indikator bisnis yang terkait risiko kredit misalnya konsekuensi salah klasifikasi dan menilai keterjelasan keputusan model melalui pendekatan XAI, sehingga hasil yang diperoleh tidak hanya akurat, tetapi juga dapat dipertanggungjawabkan dalam praktik pengelolaan risiko kredit.

1.2 Identifikasi Masalah

Berdasarkan latar belakang yang telah dijelaskan, beberapa isu dapat diidentifikasi sebagai fokus penelitian ini, sebagai berikut.

1. Membandingkan kinerja *Random Forest* dan *Logistic Regression* pada data pinjaman Bank Mandiri yang dievaluasi dengan AUC, *F1-Score*, dan *Recall* kelas gagal bayar.
2. Menganalisis pengaruh pra-pemrosesan data, penyeimbangan kelas, pemilihan fitur seperti penyaringan fitur berdasarkan missing value, fitur identitas, dan korelasi atau variansi, serta penyesuaian hyperparameter terhadap hasil perbandingan kinerja kedua model.
3. Mengkaji perbedaan dampak bisnis antara *Random Forest* dan *Logistic Regression* melalui simulasi biaya kesalahan klasifikasi serta proyeksi kerugian berbasis skenario *Loss Given Default* (LGD) pada data pinjaman Bank Mandiri.
4. Mengidentifikasi keseimbangan antara kemampuan prediksi dan tingkat kejelasan (interpretabilitas) model yang digunakan dalam pengambilan keputusan risiko kredit.

1.3 Tujuan Penelitian

Berdasarkan identifikasi masalah yang ada, penelitian ini bertujuan untuk:

1. Menganalisis dan membandingkan kinerja algoritma *Random Forest* dan *Logistic Regression* pada data pinjaman Bank Mandiri dengan menggunakan metrik evaluasi yang peka terhadap ketidakseimbangan kelas, khususnya AUC, *F1-Score*, dan *Recall* untuk kelas pinjaman yang gagal bayar.
2. Mengkaji pengaruh tahapan teknis pemodelan yang meliputi pra-pemrosesan data, penyeimbangan kelas, pemilihan fitur melalui penyaringan fitur yang tidak relevan (seperti fitur identitas, missing value tinggi, dan fitur redundan), serta penyesuaian hyperparameter, terhadap hasil perbandingan kinerja *Random Forest* dan *Logistic Regression*.

3. Mengevaluasi dampak bisnis dari penggunaan masing-masing model dengan mensimulasikan biaya kesalahan klasifikasi serta proyeksi perubahan estimasi kerugian berbasis skenario *Loss Given Default* (LGD) pada portofolio pinjaman Bank Mandiri.
4. Menilai tingkat kejelasan (interpretabilitas) hasil prediksi *Random Forest* dan *Logistic Regression* dengan memanfaatkan pendekatan *Explainable AI* (XAI) yang dibatasi pada metode tertentu seperti LIME atau SHAP untuk menjelaskan kontribusi fitur pada sejumlah kasus, serta mengkaji kesesuaiannya terhadap kebutuhan akuntabilitas dan transparansi bagi manajemen internal maupun regulator.

1.4 Batasan Masalah

Untuk penelitian yang lebih terarah, ada beberapa batasan masalah yang ditetapkan:

1. Penelitian ini membandingkan dua algoritma klasifikasi, yaitu *Random Forest* dan *Logistic Regression*, untuk prediksi risiko gagal bayar.
2. Data yang digunakan terbatas pada dataset pinjaman historis internal yang disediakan oleh Bank Mandiri (Persero) Tbk Area Jakarta Imam Bonjol pada Oktober 2025, dengan variabel prediktor berupa fitur terstruktur (karakteristik pinjaman, pola pembayaran/ arus kas angsuran, tenor dan/atau suku bunga, saluran/kemitraan penyaluran, serta atribut terkait cabang dan penghasilan).
3. Variabel target dibatasi pada status default berdasarkan kriteria internal Bank Mandiri, yang diperlakukan sebagai variabel biner (*default* vs *non-default*).
4. Ruang lingkup penelitian mencakup pra-pemrosesan data, penyeimbangan kelas, pemilihan fitur berbasis penyaringan, pemodelan, evaluasi kinerja, serta simulasi dampak bisnis; analisis bisnis dibatasi pada estimasi biaya kesalahan klasifikasi dan proyeksi kerugian menggunakan parameter *Loss Given Default* (LGD) berbasis skenario/asumsi.

5. Evaluasi model difokuskan pada metrik yang sensitif terhadap ketidakseimbangan kelas (AUC, *F1-Score*, *Recall* untuk kelas *default* sebagai kelas minoritas), serta interpretabilitas dibahas melalui koefisien *Logistic Regression* dan *feature importance Random Forest*, dengan penerapan XAI dibatasi pada SHAP pada sampel observasi terpilih.

1.5 Kontribusi

Penelitian ini diharapkan dapat memberikan kontribusi yang bermanfaat untuk pengembangan ilmu pengetahuan dan praktik di bidang risiko kredit serta data science secara lebih luas, dengan rincian sebagai berikut.

1. Studi ini memberikan bukti empiris tentang perbandingan antara model ansambel (*Random Forest*) dan model linear (*Logistic Regression*) pada data risiko kredit yang secara alami memiliki ketidakseimbangan. Model analisis ini dapat diterapkan di berbagai konteks pembiayaan lainnya baik di sektor perbankan, fintech, maupun lembaga keuangan mikro sehingga memperkaya literatur yang membahas pemodelan risiko pada data yang tidak seimbang di sektor keuangan.
2. Dengan menjadikan AUC, *F1-Score*, dan *Recall* kelas *default* sebagai metrik utama, penelitian ini mendorong pergeseran perhatian dari hanya akurasi menuju metrik yang lebih relevan untuk pengambilan keputusan risiko. Pendekatan ini bisa menjadi pedoman bagi peneliti dan praktisi lain saat merancang serta melaporkan evaluasi model dalam bidang *Credit Scoring*, deteksi penipuan, maupun risiko operasional.
3. Hubungan antara performa model dan indikator kerugian seperti biaya kesalahan klasifikasi serta proyeksi kerugian berbasis skenario *Loss Given Default* (LGD) mendorong pemanfaatan model statistik dan *machine learning* bukan sekadar alat prediksi, melainkan juga sebagai instrumen kuantitatif dalam perencanaan risiko dan modal. Kerangka ini dapat diterapkan dan dikembangkan lebih jauh dalam studi yang meneliti keterkaitan antara model risiko dan kebijakan pengelolaan portofolio di berbagai lembaga keuangan.

4. Dengan menjadikan *Explainable AI* (XAI) sebagai elemen penting dalam penilaian model melalui koefisien/feature importance dan XAI, penelitian ini memberikan kontribusi terhadap pengembangan kerangka ilmiah untuk menjelaskan keputusan model kredit kepada pihak non-teknis. Pendekatan ini dapat diaplikasikan pada penelitian lain yang berkaitan dengan tata kelola model, ketaatan pada peraturan, dan etika penggunaan algoritma dalam pengambilan keputusan finansial.
5. Walaupun studi kasus ini menyoroti data pinjaman dari Bank Mandiri, termasuk pengolahan data, penyeimbangan kelas, penyaringan dan pemilihan fitur seperti pemilihan metrik, simulasi dampak bisnis, dan penerapan XAI. Diharapkan dapat menjadi acuan metodologis untuk penelitian serupa di institusi perbankan lain, lembaga keuangan bukan bank, serta otoritas pengawas di wilayah hukum yang berlainan. Oleh karena itu, studi ini memiliki potensi untuk berperan dalam menyelaraskan praktik pemodelan risiko kredit di level industri dan akademik yang lebih luas.

