

# **BAB I**

## **PENDAHULUAN**

### **A. Latar Belakang**

Sejak diatur oleh Otoritas Jasa Keuangan (OJK) melalui Peraturan OJK No. 77/POJK.01/2016, industri *P2p lending* di Indonesia terus menunjukkan perkembangan positif. Berdasarkan data statistik yang dirilis oleh OJK (2024), hingga September 2024, total pinjaman yang telah disalurkan oleh penyelenggara *P2p lending* di Indonesia mencapai lebih dari Rp950 triliun, dengan jumlah *borrower* aktif melampaui 135 juta pengguna. Pada bulan yang sama, nilai outstanding pinjaman tercatat sebesar Rp74,48 triliun, meningkat sebesar 33,73% dibandingkan periode yang sama pada tahun sebelumnya (OJK, 2024).

Perkembangan *financial technology* (fintech) telah memfasilitasi hadirnya layanan *peer-to-peer* (P2P) lending sebagai alternatif pembiayaan yang mempertemukan peminjam dengan pemberi dana secara daring. Meskipun memberikan kemudahan akses, industri P2P lending tetap dihadapkan pada permasalahan utama terkait pengelolaan risiko gagal bayar (default). Pertama, tingginya tingkat gagal bayar dari peminjam yang tidak dapat memenuhi kewajiban pembayaran tepat waktu. Masalah ini diperburuk oleh keterbatasan informasi pada sebagian peminjam, seperti tidak tersedianya riwayat kredit atau data finansial formal yang biasa digunakan dalam penilaian kelayakan kredit di sektor perbankan. sehingga dibutuhkan pendekatan prediktif yang mampu menangkap pola non-linear dari data alternatif dengan

akurasi tinggi. Kedua kurangnya transparansi dan *interpretabilitas* dari sistem prediksi berbasis kecerdasan buatan (AI). Model *Machine Learning* seperti *Random Forest* atau *XGBoost*, meskipun unggul dalam performa, sering kali dianggap sebagai *black box* oleh pengguna non-teknis. Hal ini menimbulkan keraguan terhadap hasil prediksi dan dapat menghambat adopsi sistem otomatisasi dalam pengambilan keputusan kredit.

Sejumlah penelitian terdahulu telah berupaya menjawab tantangan dalam memprediksi risiko gagal bayar pada platform P2P lending. Misalnya, studi yang dilakukan oleh (Mendrofa et al., 2023) Penulis menggunakan metode evaluasi kurva ROC dan nilai AUC untuk menilai performa dari kedua algoritma. Pada kurva ROC, nilai AUC dari algoritma XGBoost 0,92 dan nilai AUC dari algoritma AdaBoost adalah 0,89. Berdasarkan perbandingan nilai AUC tersebut dapat disimpulkan algoritma XGBoost menghasilkan klasifikasi yang lebih baik untuk model klasifikasi pemberian pinjaman. Selanjutnya, Studi yang dilakukan oleh (Lin et al., 2022), Dalam artikel ini, kami mengusulkan model *penalized deep neural network* untuk memprediksi risiko gagal bayar dan melakukan ekstraksi fitur berdasarkan data survival. Dibandingkan dengan pendekatan yang ada, model SAFE-DNN yang diusulkan menunjukkan kinerja yang lebih unggul baik dalam hal prediksi maupun seleksi fitur. Melalui analisis data pinjaman dunia nyata dan simulasi, kami menunjukkan keunggulan kompetitif model tersebut. Hasilnya menunjukkan bahwa model kami memiliki potensi aplikasi yang menjanjikan pada platform peer-to-peer lending. Pekerjaan di masa depan dapat

mempertimbangkan untuk mengintegrasikan arsitektur jaringan yang lebih maju dan mengeksplorasi interpretabilitas model. Namun, penelitian ini masih memiliki keterbatasan karena belum dibandingkan secara langsung dengan algoritma boosting seperti XGBoost, serta belum menekankan aspek transparansi model melalui metode interpretabilitas seperti LIME atau SHAP, yang penting dalam konteks pengambilan keputusan di bidang keuangan. Kemudian, penelitian yang dilakukan oleh (Saputra et al., 2024) Berdasarkan analisis yang dilakukan menggunakan algoritma XGBoost, menunjukkan bahwa algoritma XGBoost sangat baik dalam menganalisis data kredit. Dalam tahap data mining, 10 model dibangun untuk mengidentifikasi model yang terbaik. Sebelum melakukan pemodelan pada german credit data, penyeimbangan kelas data dilakukan terlebih dahulu dengan SMOTE. Hasil evaluasi menunjukkan bahwa penggunaan algoritma XGBoost dapat digunakan untuk menganalisis data kredit sebelum menerima/ menolak pengajuan kredit. Hasil evaluasi model juga menunjukkan bahwa performa model semakin baik setelah dilakukan SMOTE dengan nilai accuracy dan nilai AUC yang mengalami peningkatan. Model terbaik didapatkan pada skenario 1 (data train 90% dan 10 data test) dengan nilai accuracy 0,83 dan AUC 0,918. Meski demikian, penelitian ini hanya menggunakan satu dataset sehingga hasilnya belum dapat digeneralisasi secara luas. Selain itu, penelitian tidak menyoroti interpretabilitas model yang penting untuk memahami faktor-faktor yang memengaruhi keputusan prediksi.. Studi yang dilakukan oleh (Givari et al., 2022) mengemukakan bahwa dalam analisis kelayakan kredit menggunakan

metodologi CRISP-DM, dengan evaluasi yang jelas melalui metrik akurasi, *precision*, *recall*, dan AUC. Hasilnya menunjukkan *XGBoost* memiliki performa terbaik dengan akurasi 82%, *recall* 70%, dan *precision* 92%. Namun, penelitian ini memiliki keterbatasan, kurangnya fokus pada *interpretabilitas* model dan efisiensi waktu eksekusi. Penelitian yang dilakukan oleh (Gramegna dkk, 2021) membandingkan *SHAP* dan *LIME* dalam menjelaskan prediksi resiko kredit menggunakan *XGBoost*. Oleh karena itu, nilai *SHAP* tampaknya lebih baik daripada bobot *LIME* dalam memberikan nilai pada dinamika gagal bayar kredit sebagaimana ditangkap oleh algoritma *XGBoost*, dinamika yang menjadi fokus kami untuk mencari kekuatan diskriminatif. Penelitian ini hanya menguji satu algoritma utama, yaitu *XGBoost*, sehingga belum diketahui apakah hasil perbandingan *SHAP* dan *LIME* konsisten pada model lain seperti *Neural Network*.

Penelitian terdahulu telah menunjukkan efektivitas metode machine learning seperti *Neural Network* dan *XGBoost* dalam memprediksi risiko gagal bayar. Namun demikian, masih terdapat keterbatasan terkait keragaman dataset, *interpretabilitas* model, serta optimasi algoritma. Untuk menjawab permasalahan tersebut, penelitian ini memanfaatkan dataset dari Kaggle yang terdiri atas 10.000 entri pinjaman dengan 112 variabel, meliputi informasi demografi peminjam, kondisi keuangan, dan riwayat transaksi yang berkaitan dengan status pembayaran. Kompleksitas fitur pada dataset ini memungkinkan penerapan *Neural Network* untuk mengekstraksi pola non-linear yang sulit ditangkap oleh metode konvensional, sementara hasil ekstraksinya

dimanfaatkan sebagai input *XGBoost* yang unggul dalam klasifikasi data tabular. Dengan demikian, dataset yang digunakan tidak hanya menyediakan variasi informasi yang memadai untuk melatih dan menguji model, tetapi juga mendukung pembangunan sistem klasifikasi gagal bayar pada platform P2P lending yang lebih akurat dan interpretatif.

Penelitian ini bertujuan untuk mengatasi tantangan dalam klasifikasi gagal bayar pada platform peer-to-peer (P2P) lending melalui integrasi metode ekstraksi fitur berbasis Neural Network dengan algoritma klasifikasi *XGBoost*, serta meningkatkan interpretabilitas prediksi menggunakan metode *LIME*. Neural Network berperan dalam mengekstraksi representasi fitur dari data pinjaman yang kompleks dan bersifat non-linear, sehingga mampu mengidentifikasi pola-pola laten yang sulit ditangkap oleh metode konvensional secara lebih efektif. Hasil ekstraksi dari *Neural network* kemudian digunakan sebagai input bagi *XGBoost*, yang dikenal memiliki performa tinggi dalam klasifikasi melalui pendekatan boosting yang efisien dan akurat. Untuk mendukung transparansi model, digunakan metode *LIME* sebagai pendekatan *interpretasi* lokal agar pengguna dapat memahami kontribusi masing-masing fitur terhadap keputusan klasifikasi yang dihasilkan oleh model. Dengan pendekatan terintegrasi ini, diharapkan penelitian dapat menghasilkan sistem klasifikasi yang tidak hanya akurat dan efisien, tetapi juga dapat dipertanggungjawabkan secara interpretatif, sehingga mampu meningkatkan kepercayaan pengguna dalam konteks manajemen risiko gagal bayar di *platform P2P lending*.

## B. Rumusan Masalah

Berdasarkan Latar belakang di atas, rumusan masalah dari penelitian ini adalah :

1. Seberapa baik performa model klasifikasi gagal bayar pada *platform peer-to-peer (P2P) lending* melalui integrasi metode *ekstraksi fitur* menggunakan *Neural network* dan algoritma *XGBoost*?
2. Sejauh mana peningkatan metode *LIME* berkontribusi meningkatkan *interpretabilitas* model terhadap prediksi resiko gagal bayar pada *platform P2P lending*?

## C. Tujuan Penelitian

Tujuan penelitian ini disusun untuk memberikan arah yang jelas sekaligus menjawab permasalahan yang telah dikemukakan :

1. Menganalisis performa model klasifikasi gagal bayar pada *platform peer-to-peer (P2P) lending* melalui integrasi metode *ekstraksi fitur* menggunakan *Neural network* dan algoritma *XGBoost*.
2. Mengevaluasi kontribusi metode *LIME* dalam meningkatkan *interpretabilitas* model terhadap prediksi risiko gagal bayar pada *platform P2P lending*.

#### D. Batasan Masalah

Penelitian ini memiliki batasan masalah yang ditentukan dalam penelitian sebagai berikut:

1. Penelitian ini hanya menggunakan data set yang tersedia secara public di *Kaggle* : <https://www.kaggle.com/code/rohanc7/bondora-peer-to-peer-lending/input>.
2. Jumlah dataset yang digunakan pada penelitian ini sebanyak 10.000 dengan kolom sebanyak 112 kolom.
3. Penelitian ini hanya terfokus pada penggunaan *Neural network* dan *XGBoost* tanpa membandingkannya dengan model prediksi lain.
4. Proses *ekstraksi fitur* akan dilakukan hanya menggunakan metode *Neural network*, tanpa mempertimbangkan teknik *ekstraksi fitur* lainnya.
5. Penilaian efektivitas model hanya akan dilakukan berdasarkan *metrik evaluasi* seperti akurasi, presisi, *recall*, *F1-score*, dan ROC-AUC.
6. Penelitian ini membatasi analisis hanya pada pengujian model prediksi resiko gagal bayar, tanpa membahas penerapan model pada sistem real-time atau perangkat keras.

#### E. Manfaat Penelitian

Hasil dari penelitian ini diharapkan dapat memberikan manfaat sebagai berikut :

1. Memberikan kontribusi dalam pengembangan model prediksi resiko gagal bayar pada *platform P2P lending* berbasis kombinasi *Neural network* dan

*XGBoost*, sehingga dapat dijadikan referensi bagi penelitian lebih lanjut di bidang kecerdasan buatan dan analisis resiko keuangan.

2. Menghasilkan model yang lebih akurat dan interpretatif, sehingga dapat diterapkan dalam sistem berbasis kecerdasan buatan untuk membantu penyedia layanan *P2p lending* dalam mengidentifikasi calon peminjam beresiko tinggi, serta meningkatkan kepercayaan pengguna melalui prediksi yang lebih transparan dan dapat dijelaskan.