

BAB I

PENDAHULUAN

1.1 Latar Belakang Masalah

Lembaga pemberi pinjaman merupakan bisnis yang sangat potensial. Bisnis pinjaman dapat memberikan keuntungan besar bagi perusahaan. Namun, bisnis tersebut juga memungkinkan perusahaan dapat menghadapi kerugian finansial yang besar juga. Oleh karena itu, lembaga pemberi pinjaman perlu melakukan analisis secara komprehensif informasi dasar dan riwayat kredit pemohon untuk memperkirakan kemungkinan pembayaran kredit dan kemudian memutuskan apakah permohonan tersebut dapat disetujui.

Metode *credit scoring* dapat membantu institusi pemberi pinjaman dalam membedakan antara calon peminjam yang mendapat persetujuan dan yang tidak. Teknologi *machine learning* telah banyak digunakan dalam penilaian kredit, seperti contohnya *Neural Network* (NN) menjadi yang paling umum [1], *Support Vector Machine* (SVM) [2], dan *Decision Tree* (DT) [3]. *Neural Network* adalah sebuah model yang meniru struktur koneksi simpatik yang ada dalam otak, di mana bobotnya disesuaikan secara berulang-ulang untuk mengurangi kesalahan prediksi. Kemampuan *Neural Network* dalam mengolah data yang tidak linear bermanfaat untuk mengenali pola-pola yang mendasar dalam data kredit yang kompleks. Munkhdalai Lkhagvadorj, dkk [4] mengusulkan model penilaian kredit *hybrid* yang menggabungkan *Neural Network*, di mana dalam tahap pertama model ini memilah aplikasi menjadi kelompok yang diterima dan ditolak. Hasil penelitian menunjukkan bahwa model ini menghasilkan prediksi yang lebih akurat dibandingkan metode pembandingan lainnya. He dan Zhang [5] mengusulkan proses dua tahap yang menggunakan *fuzzy* sebagai masukan untuk model NN menggunakan peringkat *credit scoring* sebagai respon untuk melakukan analisis. Hasilnya menunjukkan prediksi model yang memuaskan.

SVM adalah teknik yang cocok untuk penilaian kredit sebagai klasifikasi biner [6]. Tujuan dari SVM adalah untuk mengidentifikasi *hyperplane* yang dapat memisahkan *instance* pelatihan dengan benar ke dalam kelas yang benar. Yoa dan Chen [7] memanfaatkan SVM yang dikombinasikan dengan skor indeks seleksi fitur yang mengukur kemampuan fitur untuk membedakan dua kategori. Hasilnya menunjukkan bahwa metode tersebut lebih unggul dari metode eksperimen lainnya dalam hal presisi dan waktu perhitungan. Hasil yang diperoleh SVM masih sensitif terhadap pemilihan parameter kernel. Yuarita dan Rustam [8] Mengusulkan model SVM yang bebas kernel untuk menghindari pemilihan kernel dan parameter kernel terkait. Hasil yang menjanjikan menunjukkan keefektifan metode yang diusulkan pada data kredit pribadi.

Decision Tree disukai oleh pengambil keputusan karena kemampuan interpretasinya yang masih masuk akal [3]. Dengan memisahkan node, DT membentuk struktur keputusan pohon. DT pandai dalam menangkap informasi interaktif antara fitur kredit dan menunjukkan indikasi variabel yang penting. Xia dkk [3] menyajikan model baru dengan menggunakan model berbasis pohon lanjutan. Model ini dievaluasi berdasarkan metrik (akurasi, *Area Under Curve* (AUC), dan *Brier Score*) pada lima data kredit publik. Hasilnya menunjukkan bahwa model yang diusulkan secara signifikan mengungguli sebagian besar model patoan pada akurasi prediksi. DT memiliki sedikit asumsi tentang distribusi data yang memungkinkannya menangani data kredit yang kompleks. Karena representasi pohon yang intuitif dari DT, hasil model dapat ditafsirkan. Metode ansambel yang diusulkan dapat secara dinamis menetapkan bobot pengklasifikasian dasar berdasarkan kinerja model, yang mengatasi kelemahan DT tunggal terhadap data dengan fitur redundan. Pemodelan ansambel memberi pengklasifikasi kesempatan untuk mengekspresikan kemampuan mereka untuk belajar di berbagai bagian data dan fitur. Berdasarkan teori "*no free lunch*" [9] dan karena struktur dan karakteristik data kredit yang dapat diubah berbeda, akurasi prediksi sangat dibatasi oleh satu pengklasifikasi.

Pembelajaran ansambel menggabungkan beberapa pengklasifikasi yang memproses hipotesis berbeda untuk membangun hipotesis yang lebih baik dan mendapatkan prediksi yang sangat baik. Model ansambel sudah banyak diterapkan dalam *credit scoring*[10]. Li Hao dkk. [11] menggunakan strategi augmentasi data dan menggabungkan NN, SVM, dan pengklasifikasi tunggal lainnya ke dalam pengklasifikasi ansambel. Pendekatan ansambel yang digunakan mendapatkan akurasi yang jauh lebih baik daripada pengklasifikasi tunggal ini pada dataset Jerman. Xiao dkk. [12] klasifikasi ansambel yang digunakan berdasarkan *Supervised Clustering* untuk *credit scoring*. Dalam metode ini, pengklasifikasi dasar pada setiap subset, yang dibagi dengan *Supervised Clustering*, digabungkan dengan voting berbobot. Pendekatan yang digunakan memiliki akurasi prediksi yang lebih tinggi daripada pengklasifikasi dasar DT, *Logistic Regression* (LR), dan SVM pada dataset Jerman dan Australia. Xia dkk. [13] mengusulkan model kredit ansambel yang menggabungkan *bagging* dengan *stacking*. Pada dataset Jerman, Australia, dan P2P, model ansambel lebih baik daripada pengklasifikasi tunggal (LR, SVM, dan DT) dalam hal akurasi, AUC, dan skor *Brier*. Sejumlah penelitian telah menunjukkan bahwa model untuk mengintegrasikan satu pengklasifikasi mencapai kinerja yang lebih baik [14] yang menunjukkan bahwa pembelajaran ansambel memiliki kemampuan yang baik untuk melakukan *credit scoring*.

Selanjutnya, Chen dan Guestrin [15] mengusulkan lanjutan dari Algoritma Peningkatan Gradien (*Gradient Boosting*) yaitu Algoritma *eXtreme Gradient Boosting* (XGBoost), yang telah memperoleh hasil yang lebih baik dalam kompetisi data Kaggle. Zieba dan Tomczak [16] menggunakan XGBoost untuk memprediksi kebangkrutan. Untuk data yang tidak seimbang yang riil dari perusahaan Polandia, model XGBoost memanfaatkan keuntungan karena tidak sensitif terhadap data yang tidak seimbang karena memungkinkan pemilihan ukuran AUC untuk evaluasi dan memaksakan pengurutan yang tepat dari data tidak seimbang. Model bekerja jauh lebih baik daripada metode lain, termasuk NN, LR, SVM, dan *Random Forest* (RF). Berdasarkan anggapan bahwa data

kredit termasuk ke dalam data yang beresiko [6], XGBoost menyediakan skema yang layak untuk melakukan *credit scoring*. Chang [17] menggunakan XGBoost untuk membangun model penilaian kredit dengan *undersampling* berbasis *cluster*. XGBoost sendiri memiliki basis dari *Decision Tree* dan didukung oleh *Gradient Boosting* yang dapat meningkatkan daya prediktifnya. Dengan data riil dari lembaga keuangan, model akan menunjukkan akurasi yang unggul dan nilai AUC untuk LR, NN, dan SVM. Zhang dkk [18] mengusulkan model *credit risk assessment* dengan XGBoost untuk memprediksi risiko pinjaman. Prediksi probabilitas *default* dari model yang dimaksud lebih baik daripada LR dan RF pada dua data pinjaman *Peer to Peer* dari platform *LendingClub* dan *Renrendai*. dari *Exploratory Data Analysis* (EDA) menunjukkan bahwa variabel berbeda dalam memprediksi probabilitas gagal bayar dan profitabilitas, karena interpretasi dari struktur pohon XGBoost.

Data keuangan dalam bentuk data kredit memiliki ciri-ciri khusus. Salah satunya adalah ketidakseimbangan data kredit yang muncul akibat dari berbagai hal, seperti pengajuan kredit yang gagal, beragam fitur terkait kredit, serta keterkaitan kompleks antar fitur tersebut. Banyaknya variasi nilai dan *missing value* pada data sering menimbulkan permasalahan dalam analisis. Ketika kita menghadapi berbagai permasalahan ini, terdapat beberapa metode klasik dalam *machine learning* dan pendekatan yang menggabungkan beberapa metode yang dapat membantu mengatasi sejumlah kendala tersebut. Dalam bidang penilaian kredit, hal ini sangat terkait dengan hasil ekonomi yang diharapkan. Untuk menghadapi tuntutan ini, diperlukan model yang memiliki kemampuan unggul dalam menghadapi ciri-ciri khusus dari data kredit dalam berbagai aspek. XGBoost merupakan alat yang memungkinkan adanya penyesuaian tujuan khusus serta indikator penilaian untuk membimbing model dalam menghadapi berbagai situasi yang beragam. Sebagai contoh, XGBoost dapat mengatasi masalah ketidakseimbangan kelas dengan menggunakan indikator AUC sebagai tujuan yang ingin dicapai. Dalam XGBoost, pendekatan ini melibatkan perhitungan keuntungan sampel pada bagian kiri dan kanan dari setiap cabang pohon untuk

menentukan arah keputusan terkait *missing value*. Dengan cara ini, XGBoost belajar bagaimana mengatasi nilai yang hilang dengan cara yang sesuai untuk konteks data kredit. Salah satu kelebihan XGBoost adalah kemampuannya dalam menjelaskan kontribusi setiap fitur terhadap prediksi yang dihasilkan. Hal ini memungkinkan identifikasi pola atau hubungan antara dua fitur yang bisa sangat bermanfaat dalam pengambilan keputusan [15].

1.2 Rumusan Masalah

Berdasarkan latar belakang di atas, prediksi kelayakan kredit berbasis algoritma *eXtreme Gradient Boosting* (XGBoost) memerlukan performa yang tinggi sehingga diperlukan penyelidikan model XGBoost dengan parameter yang memiliki performa tinggi.

1.3 Pertanyaan Penelitian

Berdasarkan uraian permasalahan di atas, peneliti merumuskan pertanyaan terkait yang akan diteliti yaitu bagaimana parameter model XGBoost yang memiliki performa tinggi untuk prediksi kelayakan kredit berdasarkan data keuangan dan riwayat kredit seseorang?

1.4 Batasan Masalah

Berdasarkan uraian di atas, maka untuk memenuhi penelitian yang selaras dengan masalah yang diuraikan terdapat batasan-batasan masalah penelitian sebagai berikut:

1. Dataset yang digunakan merupakan data histori kredit yang berasal dari Kaggle yang bertipe numerik dengan parameter sebanyak 11 variabel (<https://www.kaggle.com/competitions/GiveMeSomeCredit/data?select=cs-training.csv>).
2. Parameter yang digunakan untuk mengukur performa model yaitu menggunakan nilai F1-score dan akurasi yang dihitung dengan *confusion matrix*.

1.5 Tujuan Penelitian

Tujuan penelitian ini yaitu:

1. Mengetahui akurasi dan F1-score dari algoritma XGBoost untuk prediksi kelayakan kredit.
2. Mengetahui parameter XGBoost yang memiliki performa yang tinggi untuk prediksi kelayakan kredit.

1.6 Manfaat Penelitian

Adapun dengan adanya penelitian ini, diharapkan dapat memberikan beberapa manfaat bagi peneliti maupun pembaca. Berikut adalah hal-hal yang diharapkan dapat menjadi manfaat dari penelitian ini.

1. Penelitian ini akan memungkinkan penulis untuk memperdalam pemahaman tentang algoritma *machine learning*, khususnya Algoritma XGBoost, serta penerapannya dalam konteks penilaian kredit.
2. Pembaca dapat menambah ilmu mengenai penerapan XGBoost untuk *credit scoring*.
3. Hasil penelitian dapat memicu minat pembaca untuk melakukan penelitian lebih lanjut tentang topik ini.