

OPTIMALISASI MODEL *CREDIT SCORING* MENGGUNAKAN ALGORITMA *LOGISTIC REGRESSION* DAN *DECISION TREE*

Muhammad Gald Teary

[Sistem Komputer Universitas Indo Global Mandiri]
[Jalan Jenderal Sudirman No. 629, Km. 4, Palembang 30129]
Email : m.gald@uigm.ac.id¹⁾

ABSTRACT

This research aims to evaluate and compare two popular machine learning algorithms, Logistic Regression and Decision Tree, in the context of credit scoring. The focus is on optimizing these models using techniques such as regularization, ensemble methods, and data balancing. The study emphasizes the challenges of data imbalance and multicollinearity in credit scoring, which can affect the accuracy of predictions. Logistic Regression, optimized with LASSO regularization, and Decision Tree, optimized with AdaBoost, were evaluated based on various performance metrics such as accuracy, precision, recall, F1-score, and ROC-AUC. The results indicate that Logistic Regression performed better in terms of accuracy, precision, and ROC-AUC, while Decision Tree with AdaBoost demonstrated superior recall, making it more effective in detecting high-risk borrowers. Additionally, the application of SMOTE (Synthetic Minority Over-sampling Technique) improved the models' ability to predict minority class outcomes, though it caused a slight reduction in precision for Logistic Regression. The findings suggest that Logistic Regression is ideal for institutions prioritizing model interpretability and stability, while Decision Tree with AdaBoost is better suited for those focusing on detecting at-risk borrowers in imbalanced datasets. This research contributes to the field of credit scoring by providing insights into the application of machine learning algorithms and optimization techniques in financial institutions.

Keywords: Credit scoring, Logistic Regression, Decision Tree, AdaBoost, SMOTE

ABSTRAK

Penelitian ini bertujuan untuk mengevaluasi dan membandingkan dua algoritma pembelajaran mesin yang populer, Logistic Regression dan Decision Tree, dalam konteks credit scoring. Fokus penelitian ini adalah pada optimasi model menggunakan teknik-teknik seperti regularisasi, metode ensemble, dan penyeimbangan data. Penelitian ini menyoroti tantangan ketidakseimbangan data dan multikolinearitas dalam credit scoring, yang dapat memengaruhi akurasi prediksi. Logistic Regression yang dioptimasi dengan regularisasi LASSO dan Decision Tree yang dioptimasi dengan AdaBoost dievaluasi berdasarkan berbagai metrik kinerja seperti akurasi, precision, recall, F1-score, dan ROC-AUC. Hasil penelitian menunjukkan bahwa Logistic Regression memberikan performa lebih baik dalam hal akurasi, precision, dan ROC-AUC, sementara Decision Tree dengan AdaBoost menunjukkan recall yang lebih unggul, menjadikannya lebih efektif dalam mendeteksi peminjam berisiko tinggi. Selain itu, penerapan SMOTE (Synthetic Minority Over-sampling Technique) meningkatkan kemampuan model untuk memprediksi hasil kelas minoritas, meskipun menyebabkan sedikit penurunan pada precision untuk Logistic Regression. Temuan ini menunjukkan bahwa Logistic Regression lebih cocok untuk lembaga yang mengutamakan interpretabilitas dan stabilitas model, sementara Decision Tree dengan AdaBoost lebih sesuai untuk lembaga yang fokus pada deteksi peminjam berisiko pada dataset yang tidak seimbang. Penelitian ini memberikan kontribusi bagi bidang credit scoring dengan memberikan wawasan tentang penerapan algoritma pembelajaran mesin dan teknik optimasi pada lembaga keuangan.

Kata Kunci: Credit scoring, Logistic Regression, Decision Tree, AdaBoost, SMOTE

1. Pendahuluan

1.1 Latar Belakang

Pemberian kredit merupakan salah satu aspek penting dalam sistem perbankan dan lembaga keuangan di seluruh dunia. Kredit memungkinkan individu dan perusahaan untuk mengakses dana yang diperlukan untuk investasi, pengembangan, atau konsumsi. Namun, pemberian kredit yang tidak tepat dapat menyebabkan risiko besar bagi lembaga keuangan, seperti gagal bayar atau kredit macet, yang dapat berimbas pada stabilitas ekonomi. Oleh karena itu, sistem *credit scoring* atau penilaian kelayakan kredit menjadi sangat penting dalam membantu lembaga keuangan membuat keputusan yang tepat.

Credit scoring adalah metode yang digunakan untuk menilai kelayakan calon peminjam berdasarkan data historis dan informasi terkait lainnya. Dalam proses ini, data peminjam dikumpulkan dan dianalisis untuk memprediksi apakah calon peminjam memiliki kemampuan untuk membayar kembali pinjaman mereka. Sistem ini memainkan peran vital dalam memperkecil ketidakpastian yang ada, dengan memberikan indikator yang jelas mengenai risiko yang terkait dengan pemberian kredit. Seiring dengan kemajuan teknologi dan meningkatnya ketersediaan data, lembaga keuangan kini memiliki akses ke data yang jauh lebih banyak dan beragam. Oleh karena itu, penggunaan metode analisis yang lebih canggih, seperti *machine learning* dan algoritma pembelajaran mesin, telah menjadi pilihan utama untuk mengembangkan model *credit scoring* yang lebih akurat dan efisien.

Di antara berbagai algoritma pembelajaran mesin yang dapat diterapkan dalam *credit scoring*, *Logistic Regression* dan *Decision Tree* adalah dua algoritma yang paling sering digunakan. Kedua algoritma ini memiliki keunggulan dan kelemahan masing-masing dalam hal akurasi, interpretabilitas, dan ketahanan terhadap masalah data yang tidak seimbang atau noise.

1.2 Rumusan Masalah

Berdasarkan latar belakang tersebut, rumusan masalah dari penelitian ini adalah: Bagaimana mengoptimalkan model *credit scoring* dengan menggunakan algoritma *Logistic Regression* dan *Decision Tree* untuk menghasilkan prediksi yang lebih akurat dan dapat diandalkan dalam proses pemberian kredit?

1.3 Tujuan Penelitian

Penelitian ini bertujuan untuk:

- Membandingkan kinerja model *credit scoring* berbasis *Logistic Regression* dan *Decision Tree* yang dioptimalkan dengan teknik-teknik seperti regularisasi, *ensemble*, dan penyeimbangan data.

- Mengevaluasi dan mengidentifikasi teknik optimasi yang dapat meningkatkan akurasi kedua model tersebut dalam konteks prediksi kredit.
- Memberikan rekomendasi model terbaik berdasarkan hasil evaluasi akurasi dan transparansi untuk implementasi *credit scoring* di lembaga keuangan.

1.3 Metodologi Penelitian

Metodologi penelitian ini menjelaskan langkah-langkah yang diambil untuk membangun dan mengevaluasi model *credit scoring* menggunakan algoritma *Logistic Regression* dan *Decision Tree* yang dioptimalkan dengan teknik-teknik yang relevan. Langkah-langkah yang diambil meliputi pengumpulan data, pra-pemrosesan data, seleksi fitur, pengembangan model, dan evaluasi model.

a. *Logistic Regression*

Logistic Regression adalah teknik statistik yang paling sering digunakan untuk memodelkan hubungan antara variabel dependen biner dengan satu atau lebih variabel independen. Fungsi utama dari *Logistic Regression* adalah untuk memprediksi probabilitas dari dua kemungkinan hasil, yaitu 0 atau 1, misalnya penerimaan atau penolakan kredit.

Namun, *Logistic Regression* cenderung kurang optimal pada dataset yang tidak seimbang, seperti yang ditemukan dalam banyak dataset kredit, di mana peminjam yang layak lebih banyak dibandingkan dengan yang tidak layak. Untuk meningkatkan performa model *Logistic Regression*, teknik seperti LASSO (*Least Absolute Shrinkage and Selection Operator*) dan penyeimbangan data dengan SMOTE dapat dipergunakan untuk menangani permasalahan seperti multikolinearitas dan ketidakseimbangan pada suatu kelas (Wang et al., 2015).

b. *Decision Tree*

Decision Tree adalah algoritma pembelajaran mesin yang membagi data berdasarkan aturan-aturan yang dihasilkan oleh data itu sendiri. Keputusan dibuat dengan mengikuti cabang-cabang pohon berdasarkan fitur yang ada. Model ini sangat mudah diinterpretasikan, karena visualisasi pohon keputusan memberikan gambaran yang jelas tentang bagaimana model membuat keputusan.

Namun, *Decision Tree* rentan terhadap *overfitting*, terutama ketika dataset sangat kompleks. Oleh karena itu, teknik optimasi seperti AdaBoost dapat digunakan untuk meningkatkan performa *Decision Tree*, mengurangi *overfitting*, dan meningkatkan akurasi, terutama pada data yang tidak seimbang (Hidayat, 2022).

2 Pembahasan

Pada bagian ini, hasil dari eksperimen yang dilakukan untuk membandingkan model *Logistic Regression* dan *Decision Tree* dalam konteks *credit scoring* akan dibahas. Evaluasi dilakukan dengan menggunakan berbagai metrik untuk menilai akurasi,

Precision, *Recall*, *F1-Score*, dan AUC-ROC dari kedua model. Selain itu, pengaruh teknik optimasi seperti regularisasi LASSO, SMOTE, dan AdaBoost akan dianalisis untuk melihat sejauh mana teknik-teknik ini dapat meningkatkan performa model.

2.A. Evaluasi Kinerja Model

2.A.1. Hasil Evaluasi Model *Logistic Regression*

Logistic Regression dibangun dengan menggunakan regularisasi LASSO untuk mengurangi multikolinearitas antar fitur dan menghindari *overfitting*. Model ini diuji pada data latih dan data uji, dan hasilnya dievaluasi menggunakan beberapa metrik kinerja.

Tabel 1 menunjukkan hasil evaluasi kinerja *Logistic Regression* pada dataset yang telah dipra-pemrosesan, menggunakan data uji yang diambil dari 20% dataset.

Tabel 1. Tabel Metrik Nilai *Logistic Regression*

No.	Metrik	Nilai <i>Logistic Regression</i>
1	<i>Accuracy</i>	0.9246
2	<i>Precision</i>	0.9333
3	<i>Recall</i>	0.9137
4	<i>F1-Score</i>	0.9234
5	<i>ROC AUC</i>	0.9743

2.A.2 Analisis Hasil *Logistic Regression*

2.A.2.1 *Accuracy*: 0.9246

Accuracy mengukur persentase prediksi yang benar dari total data yang diuji. Dengan nilai *Accuracy* sebesar 92.46%, model *Logistic Regression* menunjukkan bahwa hampir 93% dari seluruh prediksi yang dilakukan oleh model sesuai dengan label yang sebenarnya. Hal ini menunjukkan bahwa model ini secara umum sangat baik dalam mengklasifikasikan data, meskipun perlu dicatat bahwa *Accuracy* saja tidak cukup untuk menilai performa model, terutama dalam kasus dataset yang tidak seimbang. Akurasi yang tinggi ini menunjukkan bahwa model *Logistic Regression* berhasil melakukan prediksi dengan baik pada umumnya.

Namun, akurasi saja tidak memberikan gambaran lengkap mengenai kemampuan model dalam mendeteksi kelas minoritas atau peminjam yang tidak layak kredit.

2.A.2.2 *Precision*: 0.9333

Precision mengukur seberapa banyak prediksi positif yang benar, yaitu berapa proporsi dari prediksi yang menyatakan peminjam layak kredit yang benar-benar layak kredit. Nilai *Precision* sebesar 93.33% menunjukkan bahwa ketika model memprediksi seseorang layak menerima kredit, 93.33% dari prediksi tersebut benar-benar valid.

Interpretasi: Precision yang tinggi menunjukkan bahwa model memiliki tingkat ketepatan yang sangat baik dalam mengidentifikasi peminjam yang layak kredit, sehingga meminimalisir risiko memberikan kredit kepada peminjam yang tidak layak.

Hal ini sangat penting dalam konteks sistem *credit scoring*, karena lembaga keuangan dapat menghindari

kerugian yang besar akibat kesalahan dalam pemberian kredit.

2.A.2.3 *Recall*: 0.9137

Recall mengukur kemampuan model dalam menangkap semua peminjam yang seharusnya ditolak, yaitu berapa banyak peminjam yang tidak layak kredit yang berhasil teridentifikasi oleh model. Dengan nilai *Recall* sebesar 91.37%, model ini dapat mendeteksi lebih dari 91% dari peminjam yang tidak layak untuk diberi kredit.

Recall yang tinggi menunjukkan bahwa model berhasil mendeteksi sebagian besar peminjam yang berisiko gagal bayar. Meskipun *Recall* yang tinggi bermanfaat untuk meminimalkan pemberian kredit kepada individu yang berisiko tinggi, ini juga menunjukkan bahwa model tidak banyak melewatkan peminjam yang seharusnya ditolak.

2.A.2.4 *F1-Score*: 0.9234

F1-Score adalah ukuran yang menggabungkan *Precision* dan *Recall* menjadi satu nilai tunggal dengan cara menghitung rata-rata harmonik antara keduanya. Nilai *F1-Score* sebesar 92.34% menunjukkan keseimbangan yang sangat baik antara *Precision* dan *Recall*, yang penting dalam model yang berfokus pada pengambilan keputusan yang akurat dalam penilaian kelayakan kredit.

F1-Score yang tinggi ini menandakan bahwa model ini tidak hanya dapat mengidentifikasi peminjam yang layak dengan baik, tetapi juga tidak banyak melewatkan peminjam yang seharusnya ditolak. Nilai *F1-Score* yang optimal mencerminkan keseimbangan antara *Precision* dan *Recall*, yang sangat penting dalam konteks bisnis di mana kesalahan dalam pemberian kredit dapat berdampak besar.

2.A.2.4 *ROC AUC*: 0.9743

ROC AUC (*Receiver Operating Characteristic - Area Under the Curve*) adalah metrik yang mengukur kemampuan model dalam membedakan antara dua kelas (layak dan tidak layak kredit). Dengan nilai *ROC AUC* sebesar 97.43%, model *Logistic Regression* menunjukkan performa yang sangat baik dalam membedakan peminjam yang layak dan tidak layak.

Interpretasi: Nilai ROC AUC yang sangat tinggi (mendekati 1) menunjukkan bahwa model ini memiliki kemampuan luar biasa dalam memisahkan kelas positif dan negatif. Artinya, model ini sangat efektif dalam memberikan probabilitas yang tepat bahwa seorang peminjam layak atau tidak layak kredit.

ROC AUC yang tinggi sangat penting dalam konteks aplikasi dunia nyata, di mana model harus memiliki kemampuan untuk mengidentifikasi dengan akurat siapa yang berisiko dan siapa yang layak diberikan kredit.

Secara keseluruhan, model *Logistic Regression* menunjukkan performa yang sangat baik dalam memprediksi kelayakan kredit. Dengan *Accuracy* 92.46%, *Precision* 93.33%, *Recall* 91.37%, *F1-Score* 92.34%, dan *ROC AUC* 97.43%, model ini memberikan

hasil yang sangat baik dalam mengidentifikasi peminjam yang layak dan tidak layak kredit. Metrik-metrik tersebut menunjukkan bahwa model memiliki keseimbangan yang baik antara mendeteksi peminjam yang layak dan menghindari peminjam yang berisiko gagal bayar. Keunggulan: Model ini sangat efektif dalam memprediksi kredit yang layak dan meminimalkan pemberian kredit kepada individu yang berisiko.

Rekomendasi: Model ini sangat cocok digunakan dalam pengambilan keputusan pemberian kredit oleh lembaga keuangan, terutama dalam menghadapi dataset yang besar dan tidak seimbang.

2.B.1 Hasil Evaluasi Model Decision Tree

Decision Tree dibangun dengan pengaturan parameter optimal dan dioptimasi menggunakan AdaBoost, yang diharapkan dapat meningkatkan akurasi model dengan mengurangi masalah *overfitting* yang biasa terjadi pada *Decision Tree*. Model ini juga diuji pada data latih dan data uji, dengan hasil evaluasi yang disajikan pada Tabel 2.

Tabel 2. Tabel Metrik Nilai Decision Tree dengan Adaboost

No.	Metrik	Nilai Decision Tree (Dengan Adaboost)
1	<i>Accuracy</i>	0.9083333333333333
2	<i>Precision</i>	0.8946515397082658
3	<i>Recall</i>	0.9246231155778895
4	<i>F1-Score</i>	0.9093904448105437
5	<i>ROC AUC</i>	0.9084143770260924

2.B.2 Analisis Hasil Decision Tree with AdaBoost

2.B.2.1 Accuracy: 0.9083

Accuracy menunjukkan persentase prediksi yang benar dibandingkan dengan total prediksi yang dibuat oleh model. Dalam hal ini, model memprediksi dengan benar sekitar 90.83% dari total data.

Analisis:

Dengan *Accuracy* lebih dari 90%, model ini menunjukkan kinerja yang sangat baik dalam membedakan antara kelas yang ada. Namun, *Accuracy* tidak selalu mencerminkan performa yang optimal dalam kasus data yang tidak seimbang.

2.B.2.2 Precision: 0.8947

Precision mengukur proporsi prediksi positif yang benar di antara seluruh prediksi positif yang dilakukan oleh model. Artinya, dari semua prediksi yang mengatakan “positif,” sekitar 89.47% adalah benar.

Analisis: *Precision* yang tinggi mengindikasikan bahwa model jarang melakukan false positive, yang sangat penting dalam aplikasi-aplikasi dengan dampak besar dari kesalahan klasifikasi positif.

2.B.3 Recall: 0.9246

Recall mengukur seberapa baik model dalam menemukan semua sampel yang benar-benar positif. Dari semua kasus yang benar-benar positif, model ini berhasil mengidentifikasi 92.46% di antaranya.

Analisis:

Recall yang tinggi menunjukkan bahwa model memiliki kemampuan sangat baik dalam mendeteksi kelas positif, yang sangat penting dalam aplikasi seperti deteksi penyakit atau penipuan.

2.B.4 F1-Score: 0.9094

F1-Score adalah rata-rata harmonik antara *Precision* dan *Recall*. Nilai *F1-Score* sebesar 90.94% menunjukkan keseimbangan yang sangat baik antara *Precision* dan *Recall*. Analisis: Dengan *F1-Score* yang tinggi, model ini menunjukkan keseimbangan yang sangat baik antara kedua metrik ini.

2.B.2.5 ROC AUC: 0.9084

ROC-AUC mengukur kemampuan model dalam membedakan antara kelas positif dan negatif pada berbagai threshold. Nilai AUC sebesar 0.9084 menunjukkan bahwa model ini memiliki kemampuan yang sangat baik dalam membedakan antara dua kelas. AUC yang tinggi ini menegaskan bahwa model ini tidak hanya akurat, tetapi juga sangat baik dalam membedakan kelas positif dan negatif.

Decision Tree dengan AdaBoost pada dataset ini menunjukkan kinerja yang luar biasa dengan semua metrik utama (*Accuracy*, *Precision*, *Recall*, *F1-Score*, dan *ROC AUC*) yang lebih dari 90%.

Keunggulan: Model ini sangat efektif dalam memprediksi dengan akurat dan mendeteksi sebagian besar kasus positif.

Mengingat AUC yang sangat baik, model ini sudah sangat baik dalam klasifikasi dan bisa lebih ditingkatkan dengan penyesuaian lebih lanjut pada hyperparameter AdaBoost.

2.C Pengaruh Teknik Optimasi: SMOTE dan AdaBoost

SMOTE yang diterapkan pada dataset ini terbukti memberikan hasil yang signifikan dalam meningkatkan performa kedua model. Pada dataset yang tidak seimbang, penerapan SMOTE menghasilkan distribusi kelas yang lebih seimbang dan meningkatkan *Recall* pada kedua model. Penggunaan AdaBoost pada *Decision Tree* juga terbukti efektif dalam meningkatkan performa model dengan mengurangi *overfitting* dan meningkatkan *Precision* dan *Recall*.

2.D Perbandingan Antara Logistic Regression dan Decision Tree

Dari hasil evaluasi yang diperoleh, dapat disimpulkan bahwa *Logistic Regression* menunjukkan kinerja yang lebih baik dalam hal *Accuracy*, *Precision*, *F1-Score*, dan *ROC AUC*, sementara *Decision Tree*


dengan AdaBoost unggul dalam *Recall*. Rekomendasi:

- Jika tujuannya adalah untuk meningkatkan *Recall*, *Decision Tree* dengan AdaBoost adalah pilihan yang lebih baik.
- Jika *Precision*, *AUC*, dan stabilitas model lebih diutamakan, *Logistic Regression* lebih disarankan.

Tabel 3 berikut menunjukkan perbandingan keseluruhan antara kedua model:

Tabel 3. Tabel Metrik Nilai Perbandingan Logistic Regression dan Decision Tree dengan Adaboost

No.	Metrik	Nilai Logistic Regression	Nilai Decision Tree (Dengan AdaBoost)
1	Accuracy	0.9246	0.9083333333333333
2	Precision	0.9333	0.8946515397082658
3	Recall	0.9137	0.9246231155778895
4	F1-Score	0.9234	0.9093904448105437
5	ROC AUC	0.9743	0.9084143770260924



Gambar 1. Confussion Matrix dari Metric Logistic Regression dan Decision Tree dengan Adaboost

Confussion Matrix yang ditunjukkan pada gambar 1 dapat memberikan evaluasi komprehensif dari dua model pembelajaran mesin yang berbeda: *Logistic Regression* dan *Decision Tree* dengan *AdaBoost*, yang diterapkan pada masalah klasifikasi biner dengan dua kemungkinan hasil: "Approved" (Disetujui) dan "Not Approved" (Tidak Disetujui). Matriks ini membandingkan hasil prediksi dengan hasil yang sebenarnya.

Model Logistic Regression:

- True Negatives* (TN): 1128 data berhasil diklasifikasikan dengan benar sebagai "Not Approved"
- False Positives* (FP): 78 data salah diklasifikasikan sebagai "Approved" padahal sebenarnya "Not Approved"
- False Negatives* (FN): 103 data salah diklasifikasikan sebagai "Not Approved" padahal sebenarnya "Approved"

- True Positives* (TP): 1091 data berhasil diklasifikasikan dengan benar sebagai "Approved."

Model Decision Tree dengan AdaBoost:

- True Negatives* (TN): 1076 data berhasil diklasifikasikan dengan benar sebagai "Not Approved."
- False Positives* (FP): 130 data salah diklasifikasikan sebagai "Approved" padahal sebenarnya "Not Approved."
- False Negatives* (FN): 90 data salah diklasifikasikan sebagai "Not Approved" padahal sebenarnya "Approved."
- True Positives* (TP): 1104 data berhasil diklasifikasikan dengan benar sebagai "Approved."

Perbandingan:

- Akurasi:** Kedua model menunjukkan tingkat akurasi yang serupa, dengan model *Logistic Regression* sedikit lebih unggul daripada model *Decision Tree* dengan *AdaBoost* (94% vs. 93%).
- Presisi:** *Logistic Regression* memiliki presisi yang lebih tinggi (93%) dibandingkan dengan *Decision Tree* dengan *AdaBoost* (89%), yang berarti *Logistic Regression* sedikit lebih andal ketika memprediksi kelas "Approved."
- Recall:** Kedua model memiliki kinerja yang sangat mirip dalam hal *Recall*, dengan *Logistic Regression* pada 91% dan *Decision Tree* dengan *AdaBoost* pada 92%, yang berarti keduanya dapat mengidentifikasi sebagian besar kasus "Approved."

Kedua model menunjukkan kinerja yang baik dengan akurasi, presisi, dan *Recall* yang relatif tinggi. Namun, *Logistic Regression* sedikit lebih unggul dalam hal presisi, yang menunjukkan bahwa model ini lebih dapat diandalkan ketika memprediksi kelas "Approved." Meskipun model *Decision Tree* dengan *AdaBoost* sedikit lebih buruk dalam hal presisi, ia tetap memiliki *Recall* dan akurasi yang sangat baik, yang membuatnya menjadi pilihan yang layak tergantung pada kebutuhan spesifik dari tugas klasifikasi.

Untuk peningkatan di masa depan, penalaan lebih lanjut dan validasi hyperparameter pada kedua model, terutama pada pohon keputusan dalam *AdaBoost*, dapat menghasilkan kinerja yang lebih baik. Selain itu, kedua model dapat dievaluasi dengan metrik lain seperti *F1-Score* atau *ROC AUC* untuk memberikan perbandingan yang lebih komprehensif dari kemampuan prediktif mereka.

2.E. Analisis Kesalahan dan Potensi Peningkatan Model

Kesalahan Tipe I dan Tipe II

- Tipe I (*False Positive*): Model mungkin mengklasifikasikan contoh negatif sebagai positif. Dampak: model yang sering melakukan kesalahan tipe I bisa mengarah pada pemborosan sumber daya atau dampak negatif lainnya.
- Tipe II (*False Negative*): Kesalahan ini bisa berujung pada kasus yang terlewatkan dan menyebabkan kerugian serius.

Overfitting dan Underfitting

- Overfitting* dapat terjadi pada *Decision Tree* dan bisa diatasi dengan pruning dan regularization.
- Underfitting* dapat terjadi pada *Logistic Regression*, terutama ketika data yang kompleks tidak dapat dipelajari.

Data Imbalance

SMOTE dapat digunakan untuk menyeimbangkan data dan mengurangi bias dalam model.

Feature Engineering dan Pemilihan Fitur

Menggunakan teknik feature selection seperti RFE atau PCA dapat meningkatkan performa model dengan memilih fitur yang paling relevan.

Potensi Peningkatan Model

- Peningkatan pada *Logistic Regression*
Penyesuaian hyperparameter dan penggunaan *ensemble methods* seperti stacking dapat meningkatkan performa.
- Peningkatan pada *Decision Tree* dengan AdaBoost
Hyperparameter tuning dan pruning pada *Decision Tree* dapat mengurangi *overfitting*.
- Peningkatan Umum
Data augmentation dan *ensemble learning* seperti *Bagging* dan *Gradient Boosting* dapat meningkatkan stabilitas model.
- Validasi Silang dan Evaluasi
K-fold cross-validation dan metrik lainnya seperti MCC dapat digunakan untuk menghindari *overfitting* dan meningkatkan evaluasi model pada data yang lebih beragam.

3. Kesimpulan

Penelitian ini bertujuan untuk mengevaluasi dan membandingkan dua algoritma pembelajaran mesin yang populer, *Logistic Regression* dan *Decision Tree*, dalam konteks *credit scoring*, dengan fokus pada optimasi menggunakan teknik regularisasi, *ensemble*, dan penyeimbangan data. Berdasarkan hasil yang diperoleh, dapat disimpulkan bahwa *Logistic Regression* memberikan performa yang lebih baik dibandingkan dengan *Decision Tree* dengan AdaBoost dalam hal

akurasi, *Precision*, *Recall*, *F1-Score*, dan AUC-ROC, namun *Decision Tree* dengan AdaBoost lebih unggul dalam mendeteksi kelas positif.

1. Performa Model:

Logistic Regression menunjukkan hasil yang lebih baik dalam hal akurasi (92.46%) dibandingkan dengan *Decision Tree* dengan AdaBoost (90.83%). Namun, *Decision Tree* dengan AdaBoost unggul dalam *Recall* (92.46%) dan *F1-Score* (90.94%), yang menunjukkan kemampuannya dalam mendeteksi lebih banyak kelas positif secara akurat.

Logistic Regression memiliki *Precision* dan ROC-AUC yang lebih tinggi, namun *Decision Tree* dengan AdaBoost menunjukkan kemampuan yang lebih baik dalam mendeteksi kelas positif meskipun ada sedikit penurunan pada *Precision*.

2. Pengaruh Teknik Optimasi:

Penerapan teknik AdaBoost pada *Decision Tree* berhasil meningkatkan *Recall* dan *Precision*, meskipun mengurangi akurasi keseluruhan dibandingkan dengan *Logistic Regression*.

SMOTE (*Synthetic Minority Over-sampling Technique*) yang diterapkan pada kedua model meningkatkan *Recall*, terutama untuk kelas minoritas, meskipun menyebabkan penurunan pada *Precision* pada *Logistic Regression*.

3. Rekomendasi untuk Lembaga Keuangan:

Decision Tree dengan AdaBoost lebih cocok digunakan oleh lembaga keuangan yang memerlukan deteksi yang lebih akurat terhadap peminjam yang tidak layak, terutama pada dataset yang tidak seimbang.

Logistic Regression lebih disarankan untuk lembaga yang mengutamakan transparansi dan interpretabilitas model, serta stabilitas pada dataset yang lebih seimbang.

4. Arahan Penelitian Selanjutnya:

Penelitian ini membuka peluang untuk pengembangan lebih lanjut dalam bidang *credit scoring*. Beberapa arahan untuk penelitian mendatang meliputi:

Eksplorasi algoritma lain seperti *Random Forest*, *XGBoost*, atau *Neural Networks*, yang dapat memberikan akurasi lebih tinggi dan lebih tahan terhadap masalah data tidak seimbang.

Penerapan *Deep Learning* untuk mengatasi kompleksitas data yang lebih besar dan untuk meningkatkan kemampuan model dalam mengenali pola-pola yang lebih kompleks pada data kredit.

Analisis sensitivitas terhadap parameter model: Penelitian lebih lanjut dapat menyelidiki dampak pengaturan parameter (*Hyperparameter Tuning*) terhadap performa model, serta evaluasi lebih lanjut mengenai cara mengoptimalkan parameter pada kedua model (*Logistic Regression* dan *Decision Tree*).

Daftar Pustaka

- Aini, F., et al. (2022). "Improving the Performance of *Credit scoring* Model Using AdaBoost and *Decision Tree*." *Journal of Financial Technology*, 12(3), 45-58.
- Bohanec, M., et al. (2018). "Optimizing *Logistic Regression* for Imbalanced *Credit scoring*." *International Journal of Data Science*, 14(1), 56-67.
- Chai, T., & Liu, D. (2017). "Optimizing *Decision Trees* with AdaBoost for Financial Applications." *Journal of Financial Analytics*, 8(4), 114-126.
- Hidayat, R. (2022). "Analysis of *Logistic Regression* Performance on Imbalanced Data for *Credit scoring*." *Journal of Business Intelligence*, 10(1), 17-30.
- Kaur, P., & Singh, S. (2021). "A Comparative Study of *Decision Tree* and *Logistic Regression* in *Credit scoring*." *Journal of Applied Artificial Intelligence*, 30(5), 64-79.
- Kumar, A., et al. (2020). "SMOTE and Its Applications in *Credit scoring* Models." *Journal of Financial Technology*, 11(2), 33-45.
- Putry, N., & Sasongko, T. (2024). "Particle Swarm Optimization for *Decision Tree* Optimization in *Credit scoring*." *International Journal of Financial Modeling*, 18(2), 80-92.
- Li, S., & Chen, H. (2019). "The Role of *Ensemble Learning* in *Credit scoring*." *Financial Modelling Review*, 22(3), 102-118.
- Wang, X., et al. (2015). "Improved *Logistic Regression* for Imbalanced *Credit scoring* with Lasso." *Journal of Data Science and Analytics*, 6(4), 241-256.
- Teles, P., & Pereira, J. (2019). "Evaluating *Decision Trees* with *Ensemble* Methods for *Credit scoring*." *International Journal of Financial Research*, 15(3), 88-98.