

SYSTEMATIC LITERATUR REVIEW PENDEKATAN MACHINE LEARNING UNTUK PREDIKSI RISIKO KREDIT

Illaiza Nur Sakina¹, Rizka Farida Damayanti², Muh. Muafan AL Farisi³

PSDKU Politeknik Negeri Malang di Kota Kediri

Jl. Lingkar Maskumambang No.1, Sukorame, Kec. Mojoroto, Kota Kediri, Jawa Timur 64119

E-mail: illaiza110305@gmail.com¹, rizkafaridadamayantii@gmail.com², muafan99@gmail.com³

Abstrak - Penelitian ini bertujuan untuk melakukan tinjauan sistematis terhadap pendekatan *machine learning* dalam prediksi risiko kredit melalui *Systematic Literature Review* (SLR). Tujuan utama adalah mengidentifikasi tren algoritma *machine learning* yang dominan, mengevaluasi kelebihan dan kekurangannya, serta menganalisis apakah data yang digunakan merupakan *big data*. Metode penelitian melibatkan tahapan perencanaan, pencarian literatur dari Google Scholar (2019–2024), seleksi berdasarkan kriteria inklusi-eksklusi, penilaian kualitas, dan ekstraksi data. Hasil penelitian menunjukkan bahwa algoritma seperti *Neural Network*, *Random Forest*, *Support Vector Machine (SVM)*, *K-Nearest Neighbor (K-NN)*, dan *Naïve Bayes* banyak, dengan *Neural Network* dan *Random Forest* menjadi yang terpopuler karena kemampuan menangani data kompleks dan stabilitasnya. Namun, mayoritas studi menggunakan *dataset* berskala kecil hingga digunakan menengah, bukan *big data*. Penelitian ini memberikan kontribusi teoritis dengan memperkaya wawasan tentang aplikasi *machine learning* dalam risiko kredit dan kontribusi praktis sebagai panduan bagi lembaga keuangan dalam memilih model yang tepat untuk meningkatkan akurasi prediksi dan efisiensi pengambilan keputusan.

Kata Kunci: *Machine Learning*, *Neural Network*, Prediksi Risiko Kredit, *Random Forest*, *Systematic Literature Review*

I. PENDAHULUAN

Risiko kredit merupakan salah satu tantangan utama yang dihadapi oleh lembaga keuangan, khususnya bank dan perusahaan pembiayaan. Risiko ini terjadi ketika debitur gagal memenuhi kewajibannya dalam membayar utang pokok maupun bunga sesuai perjanjian yang telah disepakati. Risiko kredit dapat didefinisikan sebagai potensi kerugian yang dialami oleh kreditor karena ketidakmampuan atau ketidakmauan debitur untuk melunasi kewajibannya pada saat jatuh tempo (N. A. Putri & Pardede, 2023), (Ensa Yusna et al., 2023). Dalam konteks perbankan, risiko kredit disebut juga sebagai eksposur kerugian akibat kegagalan pihak lawan (counterparty) untuk memenuhi seluruh isi perjanjian kredit, yang sering berujung pada terjadinya kredit macet atau Non-Performing Loan (NPL) (Ummah, 2019), (Nova & Hayra, 2025).

Bank Indonesia menetapkan ambang batas rasio NPL sebesar 5%. Melebihi ambang ini dapat menurunkan pendapatan bank dari bunga kredit, memaksa bank untuk membentuk cadangan kerugian, dan pada akhirnya dapat menyebabkan instabilitas keuangan (Muharyadi et al., 2023). Peningkatan NPL biasanya terjadi karena kurangnya kesadaran debitur dalam pengembalian kredit. Dengan kata lain, manajemen risiko kredit yang buruk tidak hanya berdampak pada kinerja operasional bank, tetapi juga dapat berujung pada kegagalan lembaga keuangan dalam menjalankan fungsinya secara menyeluruh (Windasari & Purwanto, 2020).

Seiring dengan terus meningkatnya jumlah peminjam, khususnya dari kalangan pelaku usaha

yang memerlukan tambahan modal untuk pengembangan bisnis, proses penentuan kelayakan kredit menjadi semakin menantang dan kompleks. Permintaan kredit yang tinggi harus diimbangi dengan sistem evaluasi yang tepat agar tidak menimbulkan risiko yang merugikan bagi lembaga keuangan. Kesalahan dalam menilai kemampuan finansial dan kredibilitas peminjam dapat berujung pada meningkatnya angka kredit macet, yang pada akhirnya berdampak negatif terhadap kesehatan keuangan lembaga tersebut.

Untuk mengatasi tantangan ini, diperlukan solusi berbasis teknologi yang dapat membantu mengotomatisasi proses analisis serta meningkatkan tingkat akurasi dalam penilaian kelayakan kredit. Salah satu pendekatan yang semakin banyak diadopsi dalam industri keuangan adalah penerapan algoritma pembelajaran mesin (*machine learning*). Teknologi ini memungkinkan pengolahan data nasabah dalam skala besar dengan cepat, serta mampu mengenali pola dan karakteristik peminjam yang berisiko tinggi berdasarkan histori data, perilaku transaksi, dan berbagai indikator lainnya.

Dengan menggunakan *machine learning*, lembaga keuangan dapat membuat model prediktif yang lebih canggih dan adaptif, sehingga keputusan kredit yang diambil menjadi lebih objektif dan berbasis data. Selain itu, penerapan teknologi ini juga berkontribusi dalam meningkatkan efisiensi operasional, mengurangi ketergantungan pada penilaian manual, serta mendukung sistem keuangan yang lebih inklusif dan berkelanjutan (Andi & Thamrin, 2024).

Lebih lanjut, klasifikasi risiko kredit yang tidak akurat dapat memperburuk kondisi keuangan lembaga keuangan. Kesalahan dalam penilaian dan klasifikasi dapat mengakibatkan peningkatan jumlah kredit bermasalah yang berdampak langsung pada stabilitas sektor keuangan. Oleh karena itu, penting bagi lembaga keuangan untuk memiliki sistem evaluasi risiko kredit yang akurat, efisien, dan adaptif terhadap perubahan.

Di tengah perkembangan teknologi dan volume data yang semakin besar, pendekatan konvensional dalam menilai risiko kredit menjadi kurang efektif. Meskipun demikian, sebagian besar studi yang ada masih menggunakan dataset berskala kecil hingga menengah, dan belum sepenuhnya mengadopsi pendekatan big data (Rais & Warjiyono, 2024). Kondisi ini menunjukkan adanya kesenjangan antara potensi teknologi yang tersedia dengan praktik yang saat ini diterapkan.

Pertumbuhan volume data yang sangat cepat dalam sektor keuangan menghadirkan tantangan baru dalam hal pengelolaan dan pemanfaatan data secara efektif dan efisien. Lembaga keuangan kini tidak hanya dituntut untuk mampu menyimpan dan mengolah data dalam jumlah besar, tetapi juga harus dapat mengekstrak informasi yang relevan guna mendukung pengambilan keputusan yang strategis. Salah satu tantangan utama yang dihadapi adalah dalam proses penilaian kelayakan kredit. Keputusan pemberian pinjaman memerlukan pertimbangan yang matang, karena berkaitan langsung dengan risiko keuangan yang harus ditanggung lembaga.

Dalam konteks ini, kemampuan untuk memprediksi kelancaran pembayaran pinjaman secara akurat menjadi sangat krusial, terlebih di tengah dinamika pasar yang terus berubah dan kondisi ekonomi yang tidak menentu. Prediksi yang tepat dapat membantu lembaga keuangan mengurangi potensi kredit bermasalah dan menjaga stabilitas portofolio pinjaman. Oleh karena itu, pemanfaatan teknologi cerdas seperti analisis data besar (big data analytics) dan kecerdasan buatan (artificial intelligence) semakin diandalkan untuk meningkatkan akurasi prediksi dan mempercepat proses pengambilan keputusan. Dengan demikian, lembaga keuangan dapat lebih adaptif dan responsif terhadap perubahan pasar, sekaligus memperkuat daya saing mereka di era digital (Windy Mardiyah et al., 2024).

Permintaan terhadap kredit juga terus meningkat secara signifikan, khususnya di negara berkembang seperti Indonesia. Survei Bank Indonesia pada triwulan II tahun 2021 menunjukkan kenaikan permintaan kredit sebesar 53,9%, mencerminkan kebutuhan masyarakat terhadap layanan keuangan yang terus bertumbuh (Andika Saputra et al., 2024). Peningkatan ini menambah kompleksitas dalam pengelolaan risiko kredit, karena semakin beragamnya profil

peminjam dan meningkatnya jumlah transaksi kredit.

Untuk menjawab tantangan tersebut, teknologi machine learning mulai banyak dilirik sebagai solusi dalam proses evaluasi dan prediksi risiko kredit. Machine learning mampu memproses data dalam jumlah besar dan menemukan pola-pola tersembunyi yang sulit diidentifikasi secara manual, sehingga berpotensi meningkatkan akurasi prediksi dan efisiensi proses penilaian kredit. Penelitian ini mengembangkan sistem informasi berbasis web untuk prediksi risiko kredit dengan menggunakan algoritma machine learning. Sistem ini bertujuan untuk memberikan dukungan pengambilan keputusan yang lebih akurat dan cepat bagi lembaga keuangan, serta mengurangi risiko kerugian akibat keputusan pemberian kredit yang tidak tepat (Rais & Warjiyono, 2024).

Penelitian ini juga menekankan pentingnya studi literatur dalam memahami perkembangan terkini serta potensi aplikasi algoritma machine learning dalam konteks prediksi risiko kredit. Oleh karena itu, dilakukan tinjauan sistematis terhadap berbagai literatur akademik yang mengkaji penerapan machine learning untuk tujuan ini (Rais & Warjiyono, 2024). Fokus kajian mencakup identifikasi model algoritma yang dominan digunakan, analisis keunggulan dan kelemahannya, serta eksplorasi faktor-faktor yang memengaruhi akurasi prediksi.

Hasil dari tinjauan ini diharapkan dapat memberikan kontribusi baik secara teoretis maupun praktis. Secara teoretis, penelitian ini akan memperkaya khasanah ilmu pengetahuan mengenai penerapan machine learning dalam analisis risiko kredit dan menjadi dasar bagi penelitian lanjutan. Sementara itu, secara praktis, temuan ini dapat menjadi panduan bagi para profesional di industri keuangan untuk mengadopsi model machine learning yang tepat, guna mendukung pengambilan keputusan yang lebih baik, meminimalkan potensi kerugian, dan menjaga stabilitas keuangan lembaga (Rais & Warjiyono, 2024).

II. TINJAUAN PUSTAKA

Penggunaan algoritma *machine learning* untuk prediksi risiko kredit membandingkan Support Vector Machine (SVM), *Random Forest*, dan *XGBoost* pada penentuan persetujuan pengajuan kredit, di mana *Random Forest* dan *XGBoost* memberikan hasil akurasi tinggi pada data berskala menengah (Givari et al., 2022).

Sistem Informasi Prediksi Risiko Kredit Keuangan berbasis Website *Machine Learning* dengan mengintegrasikan teknologi *machine learning* dan antarmuka berbasis website yang efektif dalam meningkatkan efisiensi dan akurasi analisis data risiko kredit keuangan dengan pengurangan waktu pemrosesan dantiwantu

prediksi berdasarkan data histori. Hasil ini menunjukkan potensi besar untuk implementasi dalam industri keuangan, terutama dalam pengambilan keputusan yang lebih cepat dan akurat. Namun, untuk penyempurnaan, diperlukan pengujian pada data yang lebih kompleks dan bervariasi menggunakan data primer sesuai dengan keadaan masing-masing industri keuangan, serta pengembangan algoritma berdasarkan data yang ada sebagai pondasi *machine learning* (Rais & Warjiyono, 2024).

Pengujian pada data rekapitulasi peminjam yang berjumlah 450 data dari Koperasi Keluarga Guru Jakarta dengan proses mining algoritma naïve bayes menghasilkan tingkat akurasi 84,00%, dimana dalam pengujian model data, keseluruhan *dataset* digunakan sebagai data *training*. Penentuan data *training* dapat mempengaruhi hasil pengujian, karena pola dari data *training* tersebut akan dijadikan sebagai rule untuk menentukan kelas pada data *testing*. Sehingga besar atau kecil tingkat akurasi yang di dapat dipengaruhi oleh penentuan data training (Indriyani & Susanto, 2019).

Penelitian lain menunjukkan bahwa algoritma *Random Forest* efektif dalam meramalkan kemungkinan kredit macet di Koperasi Simpan Pinjam Baitut Tamwil Tazakka, dengan mencapai tingkat akurasi prediksi yang tinggi hingga 94,8% pada pembagian *dataset* 90:10. Implikasi dari penelitian ini sangat relevan dalam konteks manajemen risiko kredit di lembaga keuangan mikro, menawarkan pendekatan yang lebih akurat dan efisien untuk menjaga stabilitas keuangan institusi. Meskipun demikian, studi ini terbatas oleh keterbatasan dalam mengakses data yang lebih luas dan fokus hanya pada satu jenis algoritma *Machine Learning*. Untuk penelitian berikutnya, disarankan untuk memperluas cakupan data dan menggabungkan beberapa algoritma untuk analisis yang lebih menyeluruh. Dengan demikian, kontribusi penelitian ini diharapkan dapat meningkatkan strategi manajemen risiko yang lebih proaktif dan terapan, memberikan manfaat yang lebih besar bagi masyarakat umum (Saputra et al., 2024).

III. METODE PENELITIAN

Metode penelitian yang digunakan pada penelitian ini adalah *Systemic Literatur Review (SLR)*, adapun tahapannya sebagai berikut:

1) Planning

Dalam penelitian ini diangkat dua *Research Question (RQ)* yakni berikut:

- a. Apa trend *machine learning* yang digunakan dalam prediksi resiko kredit?
- b. Apakah data prediksi merupakan big data?

2) Conducting

Maksud dari strategi pencarian adalah untuk menemukan studi yang akan membantu dalam menjawab RQ, ada tiga fase:

- a. Identifikasi Kata Kunci
Kata kunci yang di gunakan dalam pencarian literatur pada penelitian ini adalah: *Machine Learning*, *Neural Network*, *Prediksi Risiko Kredit*, *Random Forest*, *Systematic Literature Review*
- b. Sumber Data
Data literatur dalam penelitin ini bersumber dari “Google Scholar” & “Garuda Journal” yang diterbitkan dari tahun 2019 – 2025.
- c. Proses pencarian di sumber data
Pada proses ini mencari literatur yang sesuai dengan *keyword* yang telah di tentukan di dalam sumber data, Dimana menghasilkan total 148 artikel yang dikunjungi pada tanggal 4 maret 2025.

3) Inclusion / Exclusion Criteria For Selecting Studies

Tahapan *Inclusion / Exclusion Criteria For Selecting Studies* di lakukan untuk menemukan data yang layak digunakan untuk penelitian ini , Evaluasi makalah dilakukan dengan membaca judul dan abstrak terlebih dahulu dan dicek apakah ada kaitannya dengan isu isu yang di bahas dalam RQ. Adapun kriterianya yaitu:

- a. Data yang digunakan harus 6 tahun terakhir
- b. Data yang di peroleh melalui *google scholar* & *garuda journal*.
- c. Data yang digunakan relevan dengan *Systematic Literatur Review Pendekatan Machine Learning Untuk Prediksi Risiko Kredit*

4) Quality Assessment

Setelah kriteria inklusi dan ekseklusi, penilaian kualitas untuk setiap studi dipastikan. Penilaian kualitas dicapai dengan membagikan skor untuk studi yang dipilih lima pertanyaan penilaian disiapkan yang dapat dijawab dengan skor 1 (ya), 0,5 (parsial), 0 (tidak). Pertanyaan tercantum di bawah ini :

RQ1. Apa trend *machine learning* yang digunakan dalam prediksi resiko kredit?

RQ2. Apakah data prediksi merupakan big data?

5) Data ekstraksi


Tahap ekstraksi data merupakan pengambilan informasi data dari artikel yang telah terpilih berdasarkan relevansi terhadap RQ yang akan dibahas. Informasi yang diambil dari masing-masing artikel meliputi judul, penulis, tahun, jenis sumber data, dan sumber publikasi.

6) Reporting

- Tinjauan Studi yang Dipilih
Menunjukkan distribusi literatur yang dipilih melalui sumber yang diterbitkan, dari 148 literatur kemudian difilter berdasarkan *machine learning* dan resiko kredit , menghasilkan 50 literatur, selanjutnya difilter kembali menjadi 30 literatur yang sesuai dengan *Quality Assessment*.
- Interpretasi Data untuk Menjawab RQ1
RQ1 berfokus pada trend model apa saja yang di gunakan dalam mengimplementasikan metode *machine learning* dan resiko kredit, untuk menjawab RQ1 menggunakan 30 literatur yang terpilih
- Interpretasi Data untuk Menjawab RQ1
RQ2 berfokus pada data yang di implementasikan apakah menggunakan database dalam perolehan data, RQ2 dengan menggunakan 30 literatur yang terpilih.

IV. HASIL DAN PEMBAHASAN

Penelitian ini dilaksanakan menggunakan pendekatan *Systematic Literature Review* (SLR), yang melibatkan beberapa tahapan. Setiap tahapan ini berkontribusi terhadap pemahaman yang lebih mendalam mengenai tren penggunaan algoritma *machine learning* dalam prediksi risiko kredit serta karakteristik data yang digunakan. Tahapan awal dilakukan dengan menjelajahi *database* jurnal ilmiah seperti “Google Scholar” & “Garuda Journal” dengan Kata kunci *Systematic Literatur Review* Pendekatan *Machine Learning* Untuk Prediksi Risiko Kredit. Dari hasil penelusuran awal, ditemukan sebanyak 148 jurnal yang memiliki keterkaitan dengan topik prediksi risiko kredit menggunakan algoritma *machine learning*. Lalu artikel yang telah dikumpulkan disaring berdasarkan relevansi judul dan abstrak terhadap permasalahan penelitian. Hasilnya, 50 jurnal berhasil lolos ke tahap berikutnya setelah dipastikan membahas prediksi risiko kredit menggunakan metode *machine learning*. Selanjutnya, dilakukan penilaian terhadap kualitas artikel dengan melihat kelengkapan isi, kejelasan metode, dan keterkaitannya dengan Research Question (RQ). Penilaian dilakukan dengan sistem skoring: 1 (sesuai), 0,5 (parsial), dan 0 (tidak sesuai). Dari proses ini diperoleh 30 artikel yang layak untuk dianalisis lebih lanjut, karena dianggap memenuhi standar metodologis dan relevansi isi dengan fokus penelitian. dan berikut gambar grafik kesesuaian jurnal dari tahun 2019 – 2025.



Gambar 1. Grafik kesesuaian jurnal

Artikel tersebut kemudian dilakukan *Quality Assessment (QA)* dan menghasilkan relevansi isi artikel dengan RQ. Hasil dapat dilihat di Tabel 1 :

Tabel 1. Relevansi RQ 1 dan RQ 2

Artikel	Relevansi RQ
(Rais & Warjiyono, 2024)	Tinggi
(Khoiri & Wahid, 2024)	Sedang
(Sunaryo, 2025)	Sedang
(Wibowo et al., 2024)	Tinggi
(Nurdin et al., 2023)	Tinggi
(Wulansari & Purwitasari, 2023)	Tinggi
(Andi & Thamrin, 2024)	Sedang
(Billah & Saputra, 2024)	Sedang
(Andika Saputra et al., 2024)	Tinggi
(Urrochman et al., 2023)	Sedang
(Syafi'i et al., 2022)	Tinggi
(Indriyani & Susanto, 2019)	Tinggi
(Givari et al., 2022)	Tinggi
(Saputra et al., 2024)	Tinggi
(Maulidya et al., n.d.)	Tinggi
(Ulfah, Maria Hamonangan Saragih, Triando , Kartini, Dwi Itqan Mazdadi, Muhammad Abadi, 2023)	Tinggi
(Windy Mardiyah et al., 2024)	Tinggi
(Sidik Febrianto, 2024)	Tinggi
(Donny & Bunyamin, 2023)	Tinggi
(Renata & Ayub, 2020)	Tinggi
(N. Putri et al., 2025)	Tinggi
(Surya et al., 2025)	Tinggi
(Andriani et al., 2025)	Tinggi
(Vebriyanti et al., 2024)	Tinggi
(Agustian & Bisri, 2019)	Tinggi
(Tarsicius Sunaryo, 2022)	Sedang
(Handayani et al., 2021)	Tinggi

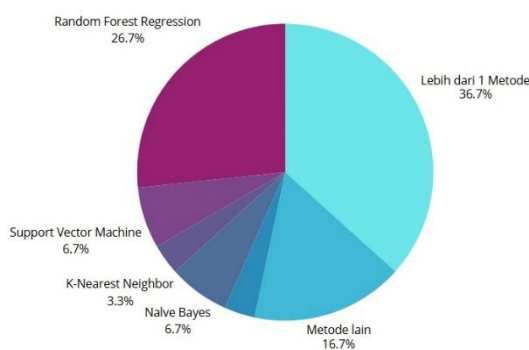
Artikel	Relevansi RQ
(Pahlevi et al., 2023)	Tinggi
(Hanif et al., 2024)	Tinggi
(Andika Saputra et al., 2024)	Tinggi

Selanjutnya berikut ini hasil dari pencarian jawaban untuk masing-masing RQ:

1. RQ1. Apa trend *Machine Learning* yang digunakan dalam prediksi resiko kredit ?

Jawaban : *Random Forest Regression*

Berdasarkan 30 literatur terpilih dari tahun 2019–2025, terdapat beberapa studi yang menggunakan lebih dari satu metode machine learning. Metode yang paling sering digunakan adalah Random Forest Regression (26,7%), disusul oleh Naive Bayes dan Support Vector Machine (masing-masing 6,7%), serta K-Nearest Neighbor (3,3%). Sebanyak 36,7% literatur menggunakan lebih dari satu metode, sementara 16,7% lainnya menggunakan metode yang tergolong ke dalam kategori "metode lain". Metode lain tersebut mencakup algoritma seperti XGBoost, LightGBM, Logistic Regression, dan Deep Learning, yang menunjukkan peningkatan adopsi teknik-teknik modern untuk meningkatkan akurasi prediksi. Adapun diagram tren penggunaan metode machine learning dalam prediksi risiko kredit ditunjukkan pada diagram berikut :




Gambar 2. Klasifikasi RQ 1

2. RQ2. Apakah data prediksi merupakan big data?

Jawaban : Tidak

Berdasarkan 30 literatur terpilih dari tahun 2019–2025, mayoritas studi menggunakan dataset berskala kecil hingga menengah, seperti data dari *UCI Repository*, data internal bank, atau dataset hasil simulasi. Sebagian besar literatur (80%) tidak mengkategorikan data prediksi risiko kredit sebagai *bigdata*. Hal ini menunjukkan bahwa penggunaan *bigdata* dalam konteks prediksi risiko kredit, baik di Indonesia maupun secara global, belum umum

dilakukan selama periode kajian tersebut. Hanya sekitar 20% studi yang secara eksplisit menggunakan atau menyebut data berkarakteristik *bigdata* dalam penelitiannya.



Gambar 3. Klasifikasi RQ 2

Jadi Penelitian ini menemukan beberapa cara machine learning digunakan untuk memprediksi risiko kredit. Namun, ada beberapa keterbatasan yang penting untuk diperhatikan. Salah satunya, banyak penelitian belum menggunakan data dalam jumlah besar (*big data*). Hal ini bisa karena teknologi yang belum mendukung, sulitnya akses data besar yang sifatnya rahasia, dan kurangnya kerja sama antara akademisi dengan perusahaan keuangan. Kebanyakan penelitian menggunakan data publik atau data internal yang tidak terlalu besar, sehingga pilihan algoritma jadi terbatas.

Hal ini memengaruhi jenis algoritma yang dipakai (RQ1). Seperti Random Forest lebih sering digunakan karena cocok untuk data yang tidak terlalu besar dan mudah dijalankan. Sedangkan algoritma yang lain yang lebih canggih jarang dipakai, bukan karena jelek, tapi karena data yang dibutuhkan tidak tersedia (RQ2).

Dari sisi praktik, temuan ini penting untuk dunia keuangan di Indonesia. Banyak lembaga keuangan kecil, seperti koperasi, masih menghadapi masalah serupa soal data dan teknologi. Jadi, algoritma yang simpel dan efisien masih sangat berguna. pilihan algoritma (RQ1) sangat dipengaruhi oleh jenis dan jumlah data yang ada (RQ2). Penelitian lebih banyak memilih algoritma yang cocok dengan data yang tersedia, bukan hanya karena algoritmanya bagus di teori.

V. KESIMPULAN DAN SARAN

Kesimpulan

Pemilihan algoritma machine learning dalam analisis risiko kredit perlu disesuaikan dengan kebutuhan lembaga keuangan dan karakteristik dataset yang tersedia. Tinjauan ini menunjukkan bahwa Random Forest adalah algoritma yang paling dominan digunakan untuk prediksi risiko kredit. Hasil penelitian ini bisa menjadi panduan

bagi praktisi di industri keuangan untuk memilih metode yang tepat guna meminimalkan risiko kredit dan meningkatkan efisiensi pengambilan keputusan. Selain itu, sebagian besar studi masih menggunakan dataset berukuran kecil hingga menengah.

Saran

Berdasarkan hasil penelitian, disarankan agar lembaga keuangan memilih algoritma machine learning yang sesuai dengan jenis dan ukuran data yang mereka miliki, seperti Random Forest, agar prediksi risiko kredit menjadi lebih akurat. Penelitian selanjutnya juga perlu menggunakan data yang lebih besar dan beragam, termasuk big data, supaya hasilnya lebih bisa diandalkan dan sesuai dengan kondisi nyata. Selain itu, penting bagi akademisi dan lembaga keuangan untuk bekerja sama agar akses data bisa lebih luas dan penerapan teknologi machine learning dalam manajemen risiko kredit dapat berjalan lebih baik. Terakhir, pengembangan model yang menggabungkan beberapa algoritma juga perlu dilakukan agar prediksi menjadi lebih tepat dan fleksibel mengikuti perubahan data.

DAFTAR PUSTAKA

- Agustian, A. A., & Bisri, A. (2019). Data Mining Optimization Using Sample Bootstrapping and Particle Swarm Optimization in the Credit Approval Classification. *Indonesian Journal of Artificial Intelligence and Data Mining*, 2(1), 18–27. <https://doi.org/10.24014/ijaidm.v2i1.6299>
- Andi, & Thamrin. (2024). Komparasi Kinerja Algoritma Random Forest Dan Support Vector Machine Berbasis Adaptive Boosting Untuk Analisis Kelayakan Kredit Nasabah (p. 8).
- Andika Saputra, A., Sari, B. N., Rozikin, C., Singaperbangsa, U., & Abstrak, K. (2024). Penerapan Algoritma Extreme Gradient Boosting (Xgboost) Untuk Analisis Risiko Kredit. *Jurnal Ilmiah Wahana Pendidikan*, 10(7), 27–36. <https://doi.org/10.5281/zenodo.10960080>
- Andriani, W., Gunawan, G., Nabila, N., & Wahyuning, P. (2025). IT-EXPLORE Analisis perbandingan machine learning untuk prediksi kelayakan kredit perbankan pada Bank BRI Tegal. 04(27), 82–92. <https://doi.org/10.24246/itexplore.v4i1.2025.p82-92>
- Billah, K. S., & Saputra, R. A. (2024). Deteksi Penipuan Kartu Kredit Menggunakan Metode Random Forest (p. 9).
- Donny, D., & Bunyamin, H. (2023). Analisis dan Prediksi Default Kartu Kredit dengan Model Machine Learning. *Jurnal STRATEGI ...*, 5(November), 364–377. <https://mail.strategi.it.maranatha.edu/index.php/strategi/article/view/445%0Ahttps://mail.strategi.it.maranatha.edu/index.php/strategi/article/download/445/332>
- Ensa Yusna, F., Langgeng Wijaya, A., & Taufiq, A. R. (2023). Pengaruh Risiko Kredit, Penyaluran Kredit dan Corporate Social Responsibility (CSR) Terhadap Kinerja Keuangan Dengan Self Assesment Sebagai Variabel Moderasi. *Seminar Inovasi Manajemen Bisnis Dan Akuntansi (SIMBA) 5, September*.
- Givari, M. R., Sulaeman, M. R., & Umaidah, Y. (2022). Perbandingan Algoritma SVM, Random Forest Dan XGBoost Untuk Penentuan Persetujuan Pengajuan Kredit. *Nuansa Informatika*, 16(1), 141–149. <https://doi.org/10.25134/nuansa.v16i1.5406>
- Handayani, N., Wahyono, H., Trianto, J., & Permana, D. S. (2021). Prediksi Tingkat Risiko Kredit dengan Data Mining Menggunakan Algoritma Decision Tree C.45. *JURIKOM (Jurnal Riset Komputer)*, 8(6), 198. <https://doi.org/10.30865/jurikom.v8i6.3643>
- Hanif, N., Aziz, A., Putra, E. K., & Komarudin, A. (2024). Klasifikasi Penilaian Pinjaman Agunan Pada PT KB Finansia Multi Finance Menggunakan Metode Random Forest. 12(2), 113–122.
- Indriyani, L., & Susanto, W. (2019). Analisis Penerapan Naïve Bayes Untuk Memprediksi Resiko Kredit Anggota Koperasi Keluarga Guru. *Jurnal Informatika*, 6(2), 262–270. <https://doi.org/10.31311/ji.v6i2.5724>
- Khoiri, S. A., & Wahid, A. (2024). Analisis Kinerja Algoritma Machine Learning dalam Prediksi Harga Cryptocurrency (p. 9).
- Maulidya, A., Az, C., & Amelia, S. (n.d.). *Prediksi Keputusan Persetujuan Kredit Menggunakan Metode Machine Learning: Analisis pada Dataset German Credit*. 1–16.
- Muharyadi, A., Gurendrawati, E., & Handarini, D. (2023). Pengaruh Dana Pihak Ketiga, Likuiditas Pendanaan Dan Risiko Kredit Terhadap Penyaluran Kredit Bank Saat Covid-19 Di Indonesia. *Transekonomika: Akuntansi, Bisnis Dan Keuangan*, 3(4), 674–684. <https://doi.org/10.55047/transekonomika.v3i4.473>
- Nova, A., & Hayra, P. N. (2025). Kredit Macet Pada Listrik Pasca Bayar Implementation Of Risk Management To Minimize The Risk Of Non-Performance Loans In Postpaid Electricity (Case Study At PT . PLN ULP Kolaka). 2351–2357.
- Nurdin, A., Zunaidi, R. A., Wicaksono, M. A. F., & Martadinata, A. L. J. (2023). Analisis Kredit

- Pembayaran Biaya Kuliah Dengan Pendekatan Pembelajaran Mesin (p. 10).
- Pahlevi, O.-, Amrin, A.-, & Handrianto, Y.-. (2023). Implementasi Algoritma Klasifikasi Random Forest Untuk Penilaian Kelayakan Kredit. *Jurnal Infortech*, 5(1), 71–76. <https://doi.org/10.31294/infortech.v5i1.15829>
- Putri, N. A., & Pardede, R. P. (2023). Pengaruh Risiko Kredit, Risiko Likuiditas Dan Risiko Operasional Terhadap Profitabilitas Bank BUMN Periode 2013-2020. *Jurnal Ilmiah Akuntansi Kesatuan*, 11(2). <https://doi.org/10.37641/jiakes.v11i2.1612>
- Putri, N., Fauzi, N., Khomsah, S., Dwi, A., Wicaksono, (2025). Penerapan Feature Engineering Dan Hyperparameter Tuning Untuk Meningkatkan Akurasi Model Random Forest Pada Application Of Feature Engineering And Hyperparameter Tuning To Improve The Accuracy Of Random Forest Models On Credit Risk. 12(2), 251–262. <https://doi.org/10.25126/jtiik.2025128472>
- Rais, A. N., & Warjiyono. (2024). *Sistem Informasi Prediksi Risiko kredit Keuangan Berbasis Web Machine Learning* (p. 5).
- Renata, E., & Ayub, M. (2020). Penerapan Metode Random forest untuk Analisis Risiko pada dataset Peer to peer lending. *Jurnal Teknik Informatika Dan Sistem Informasi*, 6(3), 462–474. <https://doi.org/10.28932/jutisi.v6i3.2890>
- Saputra, D. B., Atina, V., & Nastiti, F. E. (2024). Penerapan Model CRISP-DM pada Prediksi Nasabah Kredit Menggunakan Algoritma Random Forest (p. 8).
- Sidik Febrianto, L. (2024). *Perbandingan Metode Robust*. 13(6).
- Sunaryo, D. (2025). Prediksi Tren Risiko Keuangan Perusahaan Berdasarkan Model Machine Learning (ARIMA): Tinjauan Literature Corporate Financial Risk Trend Prediction Using ARIMA-Based Machine Learning *Jurnal Akuntansi Manajemen*, 3(January 2024), 18. <https://doi.org/10.30656/jakmen.v3i2.9704>
- Surya, A. A., Darmawan, D. R., & Solichin, A. (2025). *Prediksi Kapabilitas Calon Debitur Menggunakan Analisis Data Machine Learning Dengan Metode Random Forest*. 777–788. <https://doi.org/10.33364/algoritma/v.22-1.1929>
- Syafi'i, Nurdiawan, O., & Dwilestari, G. (2022). Penerapan Machine Learning untuk Menentukan Kelayakan Kredit Menggunakan Metode Support Vektor Machine. 10(2).
- Tarsicius Sunaryo. (2022). Mengukur Risiko Kredit dengan Model Merton. *Jurnal Manajemen Risiko*, 3(1), 29–41. <https://doi.org/10.33541/mr.v3i1.4546>
- Ulfah, Maria Hamonangan Saragih, Triando, Kartini, Dwi Itqan Mazdadi, Muhammad Abadi, F. (2023). Kredit. Penerapan MWMOTE Untuk Mengatasi Ketidakseimbangan Kelas Pada Klasifikasi Risiko Kredit, 477–486.
- Ummah, M. S. (2019). risiko kredit, risiko likuiditas, risiko oprasional dan profitabilitas. *Sustainability (Switzerland)*, 11(1), 1–14. http://scioteca.caf.com/bitstream/handle/123456789/1091/RED2017-Eng-8ene.pdf?sequence=12&isAllowed=y%0Ahttp://dx.doi.org/10.1016/j.regsciurbeco.2008.06.005%0Ahttps://www.researchgate.net/publication/305320484_SISTEM_PEMBETUNGAN_TERPUSAT_STRATEGI_MELESTARI
- Urrochman, M. Y., Setyati, E., & Kristian, Y. (2023). Prediksi Timing Financial Distress Pada Bank Perkreditan Rakyat di Indonesia Menggunakan Machine Learning. *Jutisi: Jurnal Ilmiah ...*, 12(2), 576–584.
- Vebriyanti, L. M. L., Martha, S., Andani, W., & Rizki, S. W. (2024). Analisis Kelayakan Kredit Menggunakan Classification Tree dengan Teknik Random Oversampling. *Euler : Jurnal Ilmiah Matematika, Sains Dan Teknologi*, 12(1), 1–8. <https://doi.org/10.37905/euler.v12i1.24182>
- Wibowo, C. R. H., Utami, E., & Hanafi. (2024). *Optimalisasi Seleksi Fitur dengan RFECV dalam Credit Scoring menggunakan ANN* (p. 9).
- Windasari, D., & Purwanto, A. (2020). Pengaruh Risiko Kredit, Risiko Pasar, Risiko Likuiditas, Dan Risiko Modal Terhadap Return Saham Dengan Ukuran Perusahaan Sebagai Variabel Moderating. *Diponegoro Journal of Accounting*, 9(3), 1–12. <http://ejournal-s1.undip.ac.id/index.php/accounting>
- Windy Mardiyah, N., Rahaningsih, N., & Ali, I. (2024). Penerapan Data Mining Menggunakan Algoritma K-Nearest Neighbor Pada Prediksi Pemberian Kredit Di Sektor Finansial. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 8(2), 1491–1499. <https://doi.org/10.36040/jati.v8i2.9010>
- Wulansari, & Purwitasari, D. (2023). *Algoritma Random Forest pada Prediksi Status Kredit Usaha Rakyat untuk Mengurangi Nonperforming Loan Rate* (p. 6).