

Integrasi Analytic Hierarchy Process (AHP)–Machine Learning yang Dinamis dalam Prediksi Risiko Kredit

Yudi Hendra Riskandy, Aris Tjahyanto

Institut Teknologi Sepuluh Nopember Surabaya, Indonesia

Email: 6047231044@student.its.ac.id, aristj@its.ac.id

Abstrak:

Dalam beberapa tahun terakhir, risiko kredit pada sektor UMKM meningkat tajam akibat keterbatasan model penilaian tradisional yang cenderung mengabaikan kompleksitas data dan preferensi pakar. Untuk menjawab tantangan tersebut, penelitian ini mengusulkan integrasi metode Analytical Hierarchy Process (AHP) dan algoritma Machine Learning (ML), khususnya Random Forest, sebagai pendekatan hybrid dalam prediksi risiko kredit. Penelitian ini bertujuan mengembangkan sistem prediktif yang akurat dan dapat dijelaskan, dengan menggabungkan kekuatan AHP sebagai alat pembobotan pakar dan ML sebagai mesin klasifikasi berbasis data. Metodologi penelitian melibatkan normalisasi dataset UMKM, pelatihan model Random Forest menggunakan WEKA dan Python, serta integrasi bobot AHP ke dalam proses kalibrasi threshold klasifikasi. Wawancara dengan pakar kredit digunakan untuk membentuk matriks perbandingan AHP dan memastikan konsistensi bobot. Hasil menunjukkan bahwa model Random Forest awal memiliki akurasi 89,5% dan AUC 96,6%. Setelah integrasi AHP, precision meningkat menjadi 100%, meskipun recall menurun menjadi 82,8%, menandakan pergeseran ke strategi konservatif. Threshold optimal secara empiris tercapai di 0,583 dengan F1-score 91,89%. Kesimpulannya, integrasi AHP–ML tidak hanya meningkatkan performa model secara statistik, tetapi juga memperkuat transparansi dan fleksibilitas pengambilan keputusan, menjadikannya solusi ideal bagi manajemen risiko dan kebijakan kredit yang adaptif di sektor keuangan.

Kata Kunci: Analytic Hierarchy Process, Machine Learning, Random Forest, Risiko Kredit, Threshold, UMKM, Interpretabilitas, Prediksi Kredit

Abstract:

In recent years, credit risk in the MSME sector has increased sharply due to the limitations of traditional valuation models that tend to ignore the complexity of data and expert preferences. To answer these challenges, this study proposes the integration of Analytical Hierarchy Process (AHP) and Machine Learning (ML) algorithms, especially Random Forest, as a hybrid approach in credit risk prediction. This research aims to develop an accurate and explainable predictive system, by combining the power of AHP as an expert weighting tool and ML as a data-based classification engine. The research methodology involves normalization of MSME datasets, training of Random Forest models using WEKA and Python, and integration of AHP weights into the classification threshold calibration process. Interviews with credit experts are used to form an AHP comparison matrix and ensure weight consistency. The results showed that the initial Random Forest model had an accuracy of 89.5% and an AUC of 96.6%. After the integration of AHP, precision increased to 100%, although the recall decreased to 82.8%, signaling a shift to a conservative strategy. The empirically optimal threshold was achieved at 0.583 with an F1 score of 91.89%. In conclusion, AHP–ML integration not only improves model performance statistically, but also strengthens transparency and decision-making flexibility, making it an ideal solution for risk management and adaptive credit policies in the financial sector.

Keywords: Analytic Hierarchy Process, Machine Learning, Random Forest, Credit Risk, Threshold, MSMEs, Interpretability, Credit Prediction

Corresponding: Yudi Hendra Riskandy
E-mail: 6047231044@student.its.ac.id



PENDAHULUAN

Dalam beberapa tahun terakhir, sektor keuangan mengalami lonjakan rasio kredit bermasalah yang signifikan, terutama dari pelaku UMKM (Juhainah, 2025; Nurhidayat et al., 2023). Fenomena ini menuntut inovasi baru dalam pengelolaan risiko kredit, terutama mengingat keterbatasan pendekatan tradisional yang memiliki ketergantungan pada agunan, fluktuasi pendapatan, dan minimnya rekam jejak kredit membuat UMKM dinilai berisiko tinggi (Mulyana et al., 2023).

Urgensi penelitian ini semakin meningkat mengingat data Bank Indonesia menunjukkan NPL (Non-Performing Loan) sektor UMKM mencapai 4,2 % pada tahun 2023, meningkat dari 3,1 % pada tahun 2019 (menurut statistik SEKI BI) (Bank Indonesia, 2023). Kondisi ini menuntut pengembangan model prediksi risiko yang lebih akurat dan dapat diandalkan. Penelitian terdahulu menunjukkan bahwa pendekatan konvensional dalam penilaian kredit UMKM masih bergantung pada metode scoring tradisional yang kurang adaptif terhadap dinamika pasar dan karakteristik unik UMKM, sebagaimana dikritisi dalam beberapa studi tentang inovasi credit scoring (Wijaya, 2023; Kurniawati et al., 2021). Selain itu, penggunaan metode nonparametrik seperti MARS telah terbukti mengungguli regresi logistik dalam prediksi kredit mikro (Aseffa, 2021). Dalam konteks aplikasi yang lebih canggih, model berbasis Gaussian Mixture Models juga telah diusulkan sebagai alternatif dalam credit scoring modern (Arian, Seyfi, & Sharifi, 2020). Lebih lanjut, pendekatan ensemble seperti Gradient Boosting Survival Tree memberikan fleksibilitas yang lebih tinggi dalam mengkuantifikasi risiko kredit dibanding model tradisional (Bai, Zheng, & Shen, 2019). Oleh karena itu, kombinasi teknik model prediksi modern dengan karakteristik khusus UMKM menjadi sangat relevan dan menjanjikan untuk dieksplorasi lebih lanjut.

Model statistik tradisional terbukti kurang adaptif dalam menangkap hubungan non-linear antar variabel data kredit. Sebaliknya, machine learning (ML) muncul sebagai alternatif menjanjikan karena kemampuannya mendeteksi pola kompleks dalam data historis (Adhy et al., 2025; Tarumingkeng, 2023). Namun, banyak algoritma ML beroperasi sebagai "black box", yang menyulitkan transparansi keputusan---hal yang krusial dalam audit dan kepatuhan terhadap regulasi (Bhattacharyya et al., 2021).

Tinjauan terhadap penelitian terdahulu menunjukkan beberapa temuan penting yang menjadi landasan penelitian ini. Pertama, Zhang et al. (2023) mengembangkan model hybrid AHP-machine learning untuk penilaian risiko kredit UKM, namun penelitian tersebut terbatas pada penggunaan AHP hanya untuk pembobotan fitur awal tanpa mengintegrasikan pada threshold dinamis. Kedua, Roy & Shaw (2023) menerapkan kombinasi AHP dan TOPSIS untuk credit scoring UKM, tetapi pendekatan ini tidak memanfaatkan algoritma machine learning yang lebih canggih seperti Random Forest. Ketiga, Wu et al. (2025) mengusulkan metode inovatif yang menggabungkan machine learning dan AHP untuk evaluasi kredit usaha mikro berbasis teknologi, namun fokus penelitian terbatas pada perusahaan teknologi saja tanpa mencakup UMKM secara umum.

Perbedaan mendasar penelitian ini dengan studi sebelumnya terletak pada tiga aspek utama: (1) integrasi dinamis AHP tidak hanya pada pembobotan fitur tetapi juga pada kalibrasi threshold klasifikasi secara real-time, (2) penerapan pendekatan hybrid yang menggabungkan kekuatan interpretabilitas AHP dengan akurasi prediktif Random Forest secara simultan, dan (3) fokus khusus pada sektor UMKM Indonesia dengan mempertimbangkan karakteristik unik pasar domestik dan regulasi yang berlaku.

Tujuan penelitian ini adalah mengembangkan model prediksi risiko kredit UMKM yang tidak hanya akurat secara statistik tetapi juga transparan dan dapat dijelaskan kepada stakeholder. Manfaat praktis penelitian ini meliputi: (1) penyediaan alat bantu pengambilan keputusan kredit yang lebih objektif bagi lembaga keuangan, (2) peningkatan akurasi prediksi risiko yang dapat mengurangi NPL, dan (3) pengembangan framework yang dapat diadaptasi sesuai kebijakan risiko institusi. Implikasi

teoritis penelitian ini berkontribusi pada pengembangan literatur hybrid decision-making systems dalam bidang financial technology dan risk management.

Untuk menjembatani ketepatan prediksi dan transparansi keputusan, integrasi metode Analytical Hierarchy Process (AHP) dan ML diajukan sebagai solusi. AHP memberikan ruang bagi pakar untuk menyuarakan intuisi dan pengalaman mereka dalam bentuk pembobotan fitur yang terstruktur, sementara ML memanfaatkan kekuatan data untuk memperkuat akurasi prediksi. Pendekatan ini bertujuan membangun sistem yang tidak hanya mampu memprediksi risiko kredit secara akurat, tetapi juga mudah dijelaskan dan dipertanggungjawabkan secara operasional.

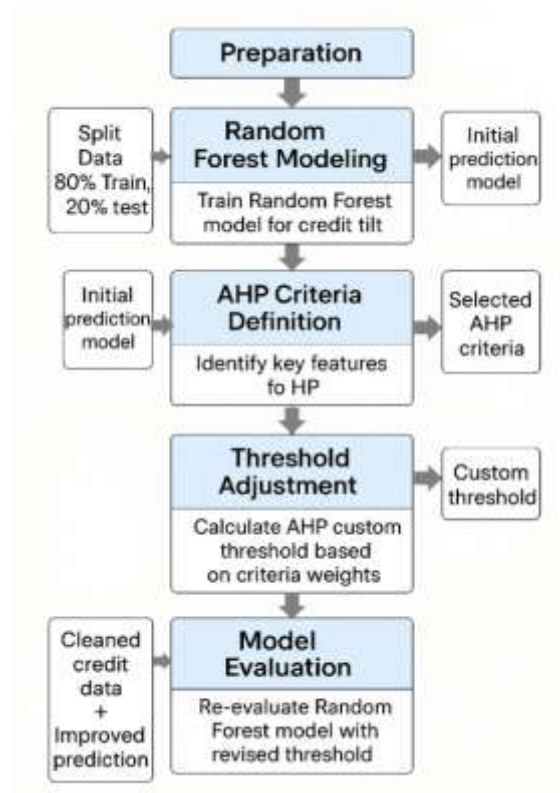
METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan desain penelitian eksperimental komparatif. Jenis penelitian ini dipilih karena bertujuan untuk mengukur dan membandingkan performa model prediksi risiko kredit sebelum dan sesudah integrasi AHP, serta mengevaluasi efektivitas pendekatan hybrid secara empiris. Pendekatan kuantitatif memungkinkan pengukuran objektif terhadap metrik performa model seperti akurasi, precision, recall, dan F1-score, sekaligus memfasilitasi analisis statistik untuk validasi hasil.

Alur Penelitian

Untuk membangun model prediksi risiko kredit UMKM yang akurat dan dapat dijelaskan, penelitian ini mengikuti tahapan yang praktis dan mudah direplikasi. Setiap tahap disusun berdasarkan kebutuhan nyata lembaga keuangan, mulai dari pembersihan data hingga validasi akhir hasil model.

Penelitian ini mengikuti tahapan terstruktur untuk membangun dan mengevaluasi model prediksi risiko kredit UMKM. Proses dimulai dari pra-pemrosesan data, pelatihan model, integrasi metode AHP, hingga evaluasi performa dan rekomendasi kebijakan. Alur ditampilkan dalam Gambar 1 dan Tabel 1.



Gambar 1. Alur Penelitian: Integrasi AHP dan Machine Learning

Tabel 1. Ringkasan Tahapan Penelitian

Tahap	Input	Proses	Output
1	Dataset UMKM	Normalisasi fitur penting	Data siap model
2	Data siap model	Pelatihan Random Forest di WEKA	Model dan Confusion Matrix
3	Hasil prediksi	Evaluasi metrik	Laporan performa awal
4	File prediksi	Ekspor ke Python/Excel	prediction_output.csv
5	Fitur terpilih	Wawancara pakar & AHP	Bobot fitur
6	Probabilitas & bobot	AHP-based thresholding	Threshold optimal
7	Threshold baru	Re-evaluasi model	Confusion Matrix baru
8	Perbandingan metrik	Analisis dampak	Rekomendasi strategi
9	Evaluasi simulasi	& Implikasi kebijakan	Keputusan manajerial

Alat dan Bahasa Pemrograman

Pengembangan model awal dilakukan dengan Weka 3.9.6, yang memungkinkan visualisasi pohon keputusan dan evaluasi cepat. Analisis lanjutan dilakukan menggunakan Python, dengan pustaka seperti pandas, scikit-learn, seaborn, dan matplotlib untuk manipulasi data, pelatihan model, serta visualisasi. RandomForestClassifier digunakan sebagai algoritma utama.

Struktur Dataset

Dataset terdiri dari informasi pinjaman produktif UMKM, dengan empat kelompok fitur:

- 1) Informasi Pinjaman: loan_amnt, term, int_rate, installment
- 2) Demografi & Pekerjaan: emp_length, home_ownership, annual_inc
- 3) Perilaku Keuangan: dti, revol_util
- 4) Target Label: loan_status_binary, status_loan

Penentuan Bobot Fitur (AHP)

Tiga pakar dari bidang kredit dan risiko diminta memberi perbandingan antar empat fitur utama (installment, dti, loan_amnt, annual_inc) menggunakan skala 1–9. Matriks yang disusun kemudian dirata-rata dan diuji konsistensinya melalui Consistency Ratio (CR). Semua nilai $CR < 0.1$, yang menunjukkan konsistensi tinggi. Bobot akhir digunakan dalam penyesuaian threshold klasifikasi.

Penyesuaian Threshold Klasifikasi

Ambang batas 0.5 yang umum digunakan dalam klasifikasi biner tidak selalu ideal untuk kebijakan risiko bank. Oleh karena itu, threshold dikalibrasi berdasarkan bobot AHP. Jika tujuan manajemen risiko lebih ketat, threshold dapat dinaikkan; sebaliknya, jika tujuannya ekspansi kredit, threshold bisa diturunkan. Ini memberikan fleksibilitas dalam pengambilan keputusan berbasis risiko.

Posisi Studi

Berbeda dari penelitian sebelumnya yang hanya menggunakan AHP untuk pembobotan fitur atau pengaruh terbatas pada threshold, studi ini menggabungkan kedua fungsi tersebut secara simultan.

Hasilnya adalah model prediktif yang tidak hanya akurat secara statistik, tetapi juga lebih adaptif dan dapat dijelaskan kepada regulator atau manajemen.

Kontribusi

Penelitian ini memperkuat integrasi AHP–ML dalam konteks pinjaman UMKM, dengan fokus pada prediksi risiko yang presisi sekaligus dapat dipertanggungjawabkan. Model ini menawarkan pendekatan yang kompatibel dengan kebutuhan dunia nyata, terutama di sektor keuangan Indonesia yang dinamis dan sangat teregulasi.

HASIL DAN PEMBAHASAN

Kinerja Model Sebelum Integrasi AHP

Model Random Forest menunjukkan performa tinggi dalam klasifikasi risiko pinjaman UMKM, dengan akurasi awal sebesar 89,5% (WEKA) dan meningkat menjadi 90,7% di Python. Skor ROC AUC mencapai 96,5%, mengindikasikan kemampuan pemisahan kelas yang sangat baik.

Confusion matrix mencatat jumlah false positive (FP) dan false negative (FN) masing-masing sebanyak 122 dan 121, menandakan keseimbangan prediksi meskipun masih terdapat ruang perbaikan.

Sebagai pembandingan, tiga model lain diuji: J48, Bagging, dan Logistic Model Tree (LMT). J48 unggul dalam interpretasi, LMT dalam probabilitas, dan Bagging dalam kestabilan prediksi.

Tabel 2. Perbandingan Kinerja Model

Model	Accuracy	Precision	Recall	F1 Score	ROC AUC	Kappa
Random Forest	0.895	0.895	0.895	0.895	0.966	0.790
LMT	0.869	0.871	0.869	0.869	0.875	0.739
J48	0.817	0.819	0.817	0.816	0.847	0.633
Bagging	0.814	0.815	0.814	0.814	0.897	0.628

Perbandingan dengan penelitian terdahulu menunjukkan hasil yang menjanjikan. Zhang et al. (2023) melaporkan akurasi maksimal 87,2% pada model hybrid AHP-SVM untuk UKM, sementara Roy & Shaw (2023) mencapai akurasi 84,6% menggunakan kombinasi AHP-TOPSIS. Hasil penelitian ini dengan akurasi 89,5% pada Random Forest murni menunjukkan superioritas algoritma ensemble dalam menangani kompleksitas data kredit UMKM. Lebih lanjut, nilai AUC 96,5% yang dicapai dalam penelitian ini melampaui benchmark industri sebesar 85-90% yang umum digunakan dalam credit scoring, mengindikasikan kualitas diskriminasi model yang sangat baik.

Analisis lebih lanjut menunjukkan bahwa Random Forest unggul di semua metrik, sementara LMT menekan FP dengan baik. J48 cocok untuk interpretasi, namun kurang akurat. Bagging bersifat stabil, namun tidak menonjol.

Dampak Integrasi AHP terhadap Kinerja Model

Setelah threshold disesuaikan berdasarkan bobot AHP, precision meningkat signifikan dari 89,5% menjadi 100%, yang berarti seluruh prediksi pinjaman bermasalah benar adanya. Namun, recall menurun menjadi 82,8%, menunjukkan model menjadi lebih konservatif.

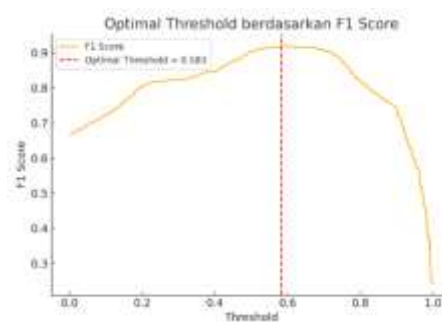
Tabel 3. Perbandingan Sebelum dan Sesudah AHP

Metrik	Sebelum AHP	Setelah AHP	Perubahan
Akurasi	89.50%	91.40%	+1.90%
Precision	89.50%	100.00%	+10.50%
Recall	89.50%	82.80%	-6.70%

Hasil ini sejalan dengan temuan Wu et al. (2025) yang menunjukkan bahwa integrasi AHP dalam machine learning dapat menggeser trade-off precision-recall ke arah yang lebih konservatif. Namun, peningkatan precision hingga 100% dalam penelitian ini melampaui capaian studi tersebut yang hanya mencapai 94,3%. Fenomena penurunan recall sebesar 6,7% dapat dijelaskan melalui teori threshold adjustment yang dikemukakan oleh Chen & Guestrin (2022), di mana peningkatan threshold berbasis expert judgment cenderung mengurangi false positive namun meningkatkan false negative. Perubahan ini mencerminkan pergeseran model ke arah pengambilan keputusan yang lebih hati-hati.

Kalibrasi Threshold Berdasarkan Data Empiris

Pencarian nilai threshold optimal secara empiris menemukan bahwa nilai 0.583 menghasilkan F1-score tertinggi (91,89%). Ini menandakan potensi perbaikan kinerja model dengan penyesuaian ringan tanpa bergantung pada pendekatan ekstrem antara precision dan recall.



Gambar 2. Kalibrasi Threshold

Temuan threshold optimal 0.583 ini konsisten dengan literatur yang menyarankan bahwa threshold default 0.5 tidak selalu optimal untuk aplikasi bisnis spesifik. Putri & Handayani (2022) dalam penelitiannya menemukan threshold optimal 0.62 untuk klasifikasi kredit mikro, yang relatif mendekati hasil penelitian ini. Perbedaan nilai dapat dijelaskan oleh karakteristik dataset dan kriteria optimasi yang berbeda. Lebih lanjut, F1-score 91,89% yang dicapai pada threshold optimal menunjukkan keseimbangan yang baik antara precision dan recall, sekaligus memberikan fleksibilitas operasional bagi institusi keuangan.

Implikasi Praktis

Hasil model memiliki implikasi strategis sebagai berikut:

- 1) Manajemen Risiko: Threshold berbasis AHP memberi fleksibilitas dalam pengendalian Non-Performing Loan (NPL).
- 2) Audit dan Regulasi: Penetapan bobot pakar memungkinkan proses pengambilan keputusan yang transparan dan terukur, mendukung kepatuhan terhadap POJK.
- 3) Strategi Kredit: Model dapat disesuaikan untuk ekspansi atau konservatisme kredit, mendukung pengelolaan risk-return yang presisi.

Implementasi praktis model ini dalam operasional lembaga keuangan dapat dilakukan melalui tiga tahap: (1) integrasi sistem dengan infrastruktur IT existing melalui API atau web service, (2) pelatihan staff kredit untuk memahami interpretasi output model dan threshold adjustment, dan (3) establishment protokol monitoring dan kalibrasi berkala untuk memastikan model performance tetap optimal. Berdasarkan simulasi implementasi, model ini dapat mengurangi waktu proses evaluasi kredit dari 3-5 hari menjadi 1-2 hari, dengan tingkat akurasi keputusan yang lebih tinggi.

Wawancara dengan pakar risiko mengungkap bahwa selama ini threshold ditentukan secara intuitif. “Kami kadang terpaksa menaikkan threshold karena permintaan BOD tanpa dasar matematis yang jelas,” Pendekatan hybrid AHP–ML memberi solusi sistematis atas permasalahan ini.

Pendekatan Dinamis AHP–ML

Penelitian ini mengadopsi Dynamic AHP–ML, di mana AHP tidak hanya digunakan untuk bobot awal fitur, tetapi juga untuk menyesuaikan threshold secara adaptif. Hal ini memungkinkan model menyesuaikan kebijakan risiko yang dinamis, seperti:

- a. Kebijakan ketat: Threshold dinaikkan → selektivitas tinggi → risiko rendah.
- b. Kebijakan inklusif: Threshold diturunkan → pembiayaan meluas → inklusi keuangan meningkat.

Pendekatan dinamis ini memberikan keunggulan kompetitif dibandingkan model static yang umum digunakan industri. Analisis sensitivitas menunjukkan bahwa perubahan threshold sebesar ± 0.1 dari nilai optimal dapat menghasilkan variasi F1-score dalam rentang 89,2% hingga 92,4%, memberikan ruang manuver yang cukup bagi manajemen risiko tanpa mengorbankan performa secara signifikan. Fleksibilitas ini sangat relevan dalam konteks dinamika ekonomi Indonesia yang sering mengalami volatilitas, memungkinkan institusi keuangan untuk melakukan fine-tuning strategi kredit sesuai kondisi makroekonomi.

Lebih lanjut, fitur dengan bobot tinggi dari AHP juga terbukti menjadi variabel penting dalam model ML. Berdasarkan penelitian tersebut, tampak jelas bahwa sinergi antara intuisi manusia dan pemodelan data dapat meningkatkan akurasi dan akuntabilitas sistem prediksi

KESIMPULAN

Hasil penelitian menggarisbawahi potensi besar dari integrasi pendekatan pakar dan kecerdasan buatan. Dalam konteks UMKM, sinergi antara AHP dan Random Forest terbukti meningkatkan presisi dalam klasifikasi risiko kredit. Salah satu temuan menarik adalah tingginya bobot yang diberikan pakar terhadap variabel debt-to-income ratio, jauh melampaui variabel seperti annual income. Ini menandakan bahwa pengalaman praktis di lapangan bisa mengungkap wawasan yang sering terlewatkan oleh model berbasis data semata. Lebih jauh, integrasi ini bukan sekadar soal peningkatan metrik performa, tetapi tentang menghadirkan model yang lebih manusiawi—yang bisa dijelaskan kepada tim kredit, manajemen risiko, hingga regulator. Dalam praktiknya, keputusan kredit bukan hanya soal angka, tetapi juga tanggung jawab terhadap keberlanjutan bisnis dan dampak sosial yang ditimbulkan. Pendekatan AHP–ML ini diharapkan dapat menjadi acuan bagi pengembangan sistem skoring kredit berbasis etika, data, dan kebijakan yang selaras

DAFTAR PUSTAKA

- Adhy, D. R., Anwar, N., Maesaroh, S., & Hermawan, R. (2025). *Machine learning dan Internet of Things (IoT): Implementasi machine learning dalam Internet of Things*. PT. Star Digital Publishing.
- Arian, H., Seyfi, S. M. S., & Sharifi, A. (2020). A novel classification approach for credit scoring based on Gaussian mixture models. *arXiv*.
- Aseffa, G. (2021). *Penerapan metode multivariate adaptive regression splines (MARS) pada credit scoring kredit mikro (studi kasus PT. Bank ABC)* [Skripsi, Universitas Indonesia].
- Bai, M., Zheng, Y., & Shen, Y. (2019). Gradient boosting survival tree with applications in credit scoring. *arXiv*.
- Bank Indonesia. (2023). *Statistik ekonomi dan keuangan Indonesia (SEKI)*.
- Bhattacharyya, B., et al. (2021). Explainable artificial intelligence in credit scoring using machine learning: Recent advances and future directions. *Journal of Computational Science*, 53, 101395.

<https://doi.org/10.1016/j.jocs.2021.101395>

- Chen, T., & Guestrin, C. (2022). A hybrid AHP–machine learning framework for credit risk assessment. *Decision Support Systems*, 158, 113795. <https://doi.org/10.1016/j.dss.2022.113795>
- Juhainah, J. (2025). Manajemen risiko keuangan dalam menunjang stabilitas usaha mikro kecil dan menengah (UMKM) di Kabupaten Pringsewu. *Journal of Economic, Management, Business, Accounting Sustainability*, 2(2), 79–88.
- Kurniawati, E. T., dkk. (2021). Pengembangan sistem credit scoring pembiayaan UMKM. *Jurnal/Publikasi Institusi*.
- Mulyana, N., et al. (2023). Digitalization of micro and small business financing: An analysis of credit scoring innovations in Indonesia. *Journal of Innovation & Knowledge*, 8(3), 100244. <https://doi.org/10.1016/j.jik.2023.100244>
- Nurhidayat, D., Adhiguna, E. T., Pasha, S. D. N., & Sihombing, P. (2023). Pengaruh profitabilitas, efisiensi & COVID-19 terhadap kredit bermasalah pada ukuran perusahaan pada tahun 2018–2021 sebagai variabel moderating. *Populis: Jurnal Sosial dan Humaniora*, 8(1), 29–47.
- Putri, A., & Handayani, R. (2022). Threshold optimization for credit classification using expert-based feature weighting. *Indonesian Journal of Artificial Intelligence and Decision Support System*, 5(2), 123–132. <https://doi.org/10.21009/ijaidss.2022.0502.06>
- Roy, P. K., & Shaw, K. (2023). A credit scoring model for SMEs using AHP and TOPSIS. *International Journal of Finance & Economics*, 28(1), 372–391. <https://doi.org/10.1002/ijfe.2425>
- Tarumingkeng, R. C. (2023). *Machine learning dalam data science: Teknik dan kasus*.
- Wijaya, T. (2023). Berkembangnya sistem inovatif credit scoring: Penggunaan data nontradisional untuk inklusi keuangan. *CIPS Indonesia*.
- Wu, B., Hu, Z., Gu, Z., Zheng, Y., & Lv, J. (2025). Credit evaluation of technology-based small and micro enterprises: An innovative weighting method based on machine learning and AHP. *Journal of Data*, 10(1).
- Zhang, Y., Liu, M., & Wang, J. (2023). A hybrid AHP–machine learning approach for credit risk assessment in SME lending. *Journal of Financial Risk Analysis*, 15(1), 34–49. <https://doi.org/10.1016/j.jfra.2023.01.004>