

Klasifikasi Perilaku Keuangan UMKM Medan dengan Machine Learning dan SHAP

Saliman¹, Rivaldi Lubis², Sunaryo Winardi³, Mustika Ulina⁴

¹Teknologi Informasi, Fakultas Informatika, Universitas Mikroskil, saliman@mikroskil.ac.id

²Teknologi Informasi, Fakultas Informatika, Universitas Mikroskil, rivaldi.lubis@mikroskil.ac.id

³Teknik Informatika, Fakultas Informatika, Universitas Mikroskil, sunaryo.winardi@mikroskil.ac.id

⁴Teknologi Informasi, Fakultas Informatika, Universitas Mikroskil, mustika.ulina@mikroskil.ac.id

Keywords

CatBoost
Financial Behavior
Machine Learning
MSME
SHAP

ABSTRACT

Good financial behavior is an important factor in sustaining micro, small, and medium enterprises (MSMEs), particularly in financial recording, debt management, and investment planning. Previous research using Structural Equation Modeling Partial Least Squares (SEM-PLS) identified financial attitude as the dominant factor influencing MSMEs' financial behavior in Medan City. Based on these findings, this study develops a complementary machine learning-based approach to classify MSMEs' financial behavior at the individual level and evaluate its consistency with SEM results through SHAP-based Explainable Artificial Intelligence (XAI). The dataset consists of 100 MSME respondents with seven main features, including three financial constructs and four demographic variables. Three ensemble algorithms, namely CatBoost, XGBoost, and Random Forest, were evaluated using hold-out and Stratified 5-Fold Cross-Validation. The results show that CatBoost achieved the best performance with 80.00% accuracy and 82.46% F1-score. SHAP analysis confirmed the dominance of attitude score and revealed the significant predictive contribution of demographic variables. Integrating machine learning and SHAP is an effective complementary approach to extend the understanding of MSMEs' financial behavior comprehensively.

Kata Kunci

CatBoost
Machine Learning
Perilaku Keuangan
SHAP
UMKM

ABSTRAK

Perilaku keuangan yang baik merupakan faktor penting dalam menjaga keberlanjutan usaha mikro, kecil, dan menengah (UMKM), terutama dalam aspek pencatatan keuangan, pengelolaan utang, dan perencanaan investasi. Penelitian sebelumnya menggunakan pendekatan Structural Equation Modeling Partial Least Squares (SEM-PLS) menunjukkan bahwa sikap keuangan merupakan faktor dominan yang memengaruhi perilaku keuangan UMKM di Kota Medan. Berdasarkan temuan tersebut, penelitian ini mengembangkan pendekatan komplementer berbasis machine learning untuk mengklasifikasikan perilaku keuangan UMKM pada tingkat individu serta mengevaluasi konsistensinya dengan hasil SEM melalui Explainable Artificial Intelligence (XAI) berbasis SHAP. Dataset yang digunakan terdiri atas 100 responden UMKM dengan tujuh fitur utama yang mencakup tiga konstruk keuangan dan empat variabel demografis. Tiga algoritma ensemble, yaitu CatBoost, XGBoost, dan Random Forest, dievaluasi menggunakan hold-out dan Stratified 5-Fold Cross-Validation. Hasil menunjukkan bahwa CatBoost memberikan performa terbaik dengan accuracy 80,00% dan F1-score 82,46%. Analisis SHAP mengonfirmasi dominasi attitude score serta mengungkap kontribusi signifikan variabel demografis. Integrasi machine learning dan SHAP efektif sebagai pendekatan komplementer untuk memperluas pemahaman mengenai perilaku keuangan UMKM secara komprehensif.

Korespondensi Penulis:

Rivaldi Lubis
Jl. M.H Thamrin No.140, Kota
Medan, Sumatera Utara
Telepon : +6285107107761
Email:rivaldi.lubis@mikroskil.ac.id

Submitted: 13-06-2026; Accepted: 10-06-2026;
Published: 01-09-2026

Copyright (c) 2026 The Author (s) This article is distributed under a Creative Commons Attribution-ShareAlike 4.0 International License (CC BY-SA 4.0)

1. PENDAHULUAN

Perilaku keuangan pelaku Usaha Mikro, Kecil, dan Menengah (UMKM) merupakan aspek kritis yang memengaruhi keberlanjutan dan pertumbuhan usaha secara langsung [1]. Perangin-Angin et al. [2] telah melakukan penelitian menggunakan pendekatan *Structural Equation Modeling Partial Least Squares* (SEM-PLS) pada 100 UMKM di Kota Medan dan menemukan bahwa sikap keuangan merupakan faktor yang berpengaruh signifikan terhadap perilaku keuangan ($\beta=0,939$, $p=0,000$), sedangkan literasi keuangan dan inklusi keuangan tidak menunjukkan pengaruh yang signifikan. Temuan tersebut memberikan landasan pemahaman yang kuat mengenai faktor-faktor yang memengaruhi perilaku keuangan UMKM melalui pendekatan kausal berbasis konstruk laten, dan sejalan dengan sejumlah penelitian lain yang menempatkan sikap keuangan sebagai determinan utama perilaku keuangan [3], [4].

Berdasarkan temuan tersebut, terbuka peluang untuk mengembangkan pendekatan komplementer yang memanfaatkan *dataset* dan konstruk yang telah tervalidasi dari penelitian sebelumnya [2] ke dalam kerangka prediktif berbasis *machine learning*. Dalam konteks pengambilan keputusan berbasis data, kemampuan mengklasifikasikan perilaku keuangan pada tingkat individu menjadi penting karena memungkinkan identifikasi dini terhadap kelompok pelaku UMKM yang berpotensi memiliki perilaku keuangan baik maupun kurang baik. Beberapa studi terdahulu telah menerapkan algoritma *ensemble* untuk klasifikasi perilaku keuangan, namun integrasi antara landasan kausal berbasis SEM, pemodelan prediktif, dan mekanisme interpretabilitas masih relatif terbatas dalam literatur [5], [6].

Machine learning menawarkan kemampuan untuk mempelajari pola data yang kompleks dan menghasilkan model klasifikasi yang berorientasi pada prediksi [7]. Tiga algoritma berbasis *ensemble* yang banyak diterapkan pada data tabular terstruktur, yaitu CatBoost, XGBoost, dan *Random Forest* [8], [9], [10], dipilih untuk dibandingkan secara sistematis dalam mengklasifikasikan perilaku keuangan UMKM ke dalam kategori *Good* dan *Poor*. Ketiga algoritma tersebut dipilih karena kemampuannya menangani hubungan non-linear dan interaksi kompleks antar variabel yang tidak terakomodasi dalam model kausal linear, sekaligus telah terbukti memberikan performa kompetitif pada berbagai permasalahan klasifikasi berbasis data survei [11], [12].

Model *machine learning* berbasis ensemble umumnya bersifat *black-box* sehingga sulit diinterpretasikan oleh pemangku kepentingan non-teknis [13]. Dalam domain perilaku keuangan, keterbatasan ini menjadi tantangan tersendiri karena pemahaman mengenai faktor-faktor pendorong prediksi sama pentingnya dengan akurasi prediksi itu sendiri. Pendekatan *Explainable Artificial Intelligence* (XAI) berbasis SHAP (*SHapley Additive exPlanations*) [14] hadir untuk menjawab tantangan tersebut dengan mengidentifikasi kontribusi prediktif setiap fitur terhadap hasil klasifikasi, sekaligus memungkinkan perbandingan langsung antara *feature importance* prediktif dengan *path coefficient* kausal dari model SEM.

Penelitian ini bertujuan untuk mengidentifikasi *model machine learning* terbaik dalam mengklasifikasikan perilaku keuangan UMKM Medan serta menganalisis konsistensi antara kontribusi prediktif berbasis SHAP dengan temuan kausal penelitian SEM sebelumnya. Melalui integrasi kedua pendekatan, penelitian ini diharapkan memperluas pemahaman tentang determinan perilaku keuangan UMKM sekaligus membuka perspektif baru dalam kajian perilaku keuangan UMKM melalui integrasi pendekatan kausal dan prediktif berbasis kecerdasan buatan.

2. METODE PENELITIAN

Penelitian ini merupakan penelitian komputasional berbasis data survei dengan pendekatan *machine learning* untuk klasifikasi perilaku keuangan UMKM. Tahapan penelitian meliputi pengumpulan data, *preprocessing* data, *feature engineering*, *label generation*, *feature selection*, pengembangan model, evaluasi, dan analisis SHAP. Tahapan lengkap penelitian ditunjukkan pada Gambar 1.



Gambar 1. Tahapan Alur Penelitian

2.1 Pengumpulan Data

Dataset yang digunakan dalam penelitian ini merupakan *dataset* identik dengan penelitian SEM-PLS sebelumnya [2], terdiri atas 100 responden UMKM di Kota Medan. Penggunaan *dataset* yang sama bertujuan untuk memungkinkan evaluasi komparatif dan validasi lintas-paradigma antara pendekatan kausal berbasis SEM dan pendekatan prediktif berbasis *machine learning*. Instrumen penelitian terdiri atas empat konstruk utama, yaitu *Financial Literacy* (FL), *Financial Attitude* (FA), *Financial Inclusion* (FI), dan *Financial Behavior* (FB). Setiap konstruk diukur menggunakan sembilan indikator. *Financial Literacy* menggunakan pertanyaan objektif benar/salah terkait konsep dasar keuangan seperti penganggaran, tabungan, dan pengelolaan utang. *Financial Attitude*, *Financial Inclusion*, dan *Financial Behavior* diukur menggunakan skala Likert lima poin. Validitas dan reliabilitas instrumen telah diverifikasi pada penelitian SEM-PLS sebelumnya [2] dengan nilai *Cronbach's alpha* > 0,90 dan AVE > 0,50 untuk seluruh konstruk. Oleh karena itu, *composite score* digunakan langsung sebagai fitur prediktif tanpa pengujian reliabilitas ulang pada tahap *machine learning*.

2.2 Preprocessing Data

Data penelitian tersimpan dalam lima *sheet* terpisah pada file Excel. Setiap *sheet* merepresentasikan satu kelompok variabel yang berbeda sebagaimana ditunjukkan pada Tabel 1.

Tabel 1. Struktur *Dataset*

<i>Sheet</i>	Isi Data
Demografi	Karakteristik responden: umur, pendidikan, pendapatan, lama UMKM
Literasi	Item <i>Financial Literacy</i> FL1-FL9
Attitude	Item <i>Financial Attitude</i> FA1-FA9
Inklusi	Item <i>Financial Inclusion</i> FI1-FI9
Perilaku	Item <i>Financial Behavior</i> FB1-FB9

Seluruh *sheet* digabungkan secara horizontal berdasarkan identitas responden sehingga menghasilkan *dataset* terpadu dengan 100 observasi dan 43 variabel. Tahap *preprocessing* meliputi penghapusan data duplikat, penanganan *missing values*, serta transformasi variabel umur dari format teks menjadi numerik. Setelah pembersihan, jumlah data tetap berada pada jumlah 100 observasi.

Encoding diterapkan sesuai karakteristik setiap variabel. Indikator *Financial Literacy* dikonversi ke format biner (Benar=1, Salah=0). Indikator *Financial Attitude*, *Financial Inclusion*, dan *Financial Behavior* dikonversi menggunakan skema Likert numerik (Sangat tidak setuju=1 hingga Sangat setuju=5). Variabel demografis diencode secara ordinal: pendidikan (SMP=1 hingga S2=5), pendapatan bulanan (<Rp3 juta=1, Rp3-5 juta =2, >Rp5 juta =3), dan lama UMKM berdiri (<1 tahun =1, 1-3 tahun =2, >3 tahun =3).

2.3 Feature Engineering dan Label Generation

Skor komposit untuk setiap konstruk dihitung menggunakan rata-rata aritmetika dari seluruh indikator penyusunnya. Pendekatan ini menghasilkan empat fitur konstruk: *literacy score* (rentang 0-1), *attitude score*, *inclusion score*, dan *behavior score* (rentang 1-5). Variabel target dibentuk menggunakan *mean-split* pada *behavior score*. Nilai rata-rata sebesar 4,4311 digunakan sebagai threshold: responden dengan *behavior score* $\geq 4,4311$ dikategorikan sebagai *Good*, sedangkan yang di bawah nilai tersebut dikategorikan sebagai *Poor*.

Pemilihan threshold berbasis rata-rata didasarkan pada hasil analisis distribusi yang menunjukkan tidak adanya outlier ekstrem dan tingkat kemencengan yang masih berada pada kategori moderat (*skewness* = -0,6094). *Behavior score* hanya digunakan sebagai dasar pembentukan label klasifikasi dan tidak dimasukkan sebagai fitur input model, sehingga tidak menimbulkan potensi *data leakage*. Distribusi label yang dihasilkan menunjukkan proporsi relatif seimbang dengan rasio *Good:Poor* sebesar 56:44, yang mengurangi risiko dominasi kelas selama pelatihan model.

2.4 Feature Selection dan Train-test Split

Tujuh fitur digunakan sebagai variabel masukan model, terdiri atas tiga fitur konstruk utama (*literacy score*, *attitude score*, *inclusion score*) dan empat fitur demografi (Umur, Pendidikan, Pendapatan/Bulan, Lama UMKM berdiri). *Dataset* dibagi menggunakan *train-test split* dengan proporsi 80:20, *random_state*=42, dan parameter *stratify=y* untuk menjaga reproduktibilitas eksperimen dan distribusi kelas.

2.5 Pengembangan Model

Tiga algoritma berbasis *ensemble* dipilih karena kemampuannya menangani hubungan non-linear dan interaksi antar variabel pada data tabular. *CatBoost Classifier* digunakan karena kemampuannya menangani fitur kategorikal secara efektif dan ketahanannya terhadap *overfitting* [15]. *XGBoost Classifier* digunakan sebagai model berbasis *gradient boosting* dengan kemampuan optimasi yang kuat [16]. *Random Forest Classifier* digunakan karena stabilitasnya pada *dataset* berukuran kecil [17]. Parameter utama ketiga model ditampilkan pada Tabel 2.

Tabel 2. Parameter Model Machine Learning

Model	Parameter Utama
CatBoost	<i>iterations</i> =200, <i>learning_rate</i> =0,05, <i>depth</i> =6, <i>loss_function</i> =Logloss
XGBoost	<i>n_estimators</i> =200, <i>learning_rate</i> =0,05, <i>max_depth</i> =6, <i>random_state</i> =42
Random Forest	<i>n_estimators</i> =200, <i>max_depth</i> =6, <i>random_state</i> =42

Parameter model pada penelitian ini menggunakan konfigurasi *baseline* yang disesuaikan berdasarkan parameter umum yang lazim digunakan [18], [19]. Pendekatan ini dipilih untuk menjaga konsistensi perbandingan performa antar model tanpa dipengaruhi oleh proses *hyperparameter tuning*, evaluasi lebih berfokus pada kemampuan intrinsik masing-masing algoritma dalam mengklasifikasikan perilaku keuangan UMKM.

2.6 Evaluasi Model

Performa model dievaluasi menggunakan empat metrik klasifikasi, yaitu akurasi, presisi, *recall*, dan *F1-Score* dengan *positive label* ditetapkan pada kelas *Good*. Evaluasi dilakukan dalam dua skenario: *hold-out* 80:20 dan *Stratified 5-Fold Cross-Validation* untuk menghasilkan estimasi performa yang lebih *robust* [20].

2.7 Analisis SHAP

Untuk meningkatkan interpretabilitas model, penelitian ini menerapkan SHAP (*SHapley Additive exPlanations*) [7] pada model terbaik hasil evaluasi. SHAP digunakan untuk mengukur kontribusi prediktif masing-masing fitur terhadap hasil klasifikasi, baik secara global maupun individual. Analisis dilakukan melalui tiga perspektif utama: *global feature importance* untuk mengidentifikasi fitur dominan, distribusi nilai SHAP untuk mengevaluasi arah dan konsistensi pengaruh fitur, serta analisis hubungan fitur terhadap kontribusi prediktifnya. Hasil SHAP kemudian dibandingkan dengan *path coefficients* dari penelitian SEM sebelumnya [2] untuk mengevaluasi konsistensi dan perbedaan antara pendekatan kausal dan pendekatan prediktif.


3. HASIL DAN ANALISIS

3.1 Evaluasi Tanpa Cross-Validation

Pada skenario ini, XGBoost dan *Random Forest* menghasilkan performa identik dengan akurasi 70% dan *F1-Score* 75,00%. CatBoost menunjukkan performa lebih rendah pada seluruh metrik. Hasil evaluasi pada data pengujian *hold-out* berikut ditampilkan pada Tabel 3 dan Gambar 2.

Tabel 3. Hasil Evaluasi Tanpa Cross-Validation

Model	Akurasi	Presisi	Recall	F1-Score
XGBoost	70,00%	69,23%	81,82%	75,00%
Random Forest	70,00%	69,23%	81,82%	75,00%
CatBoost	60,00%	61,54%	72,73%	66,67%




Gambar 2. Grafik Perbandingan Metrik Antar Model

3.2 Evaluasi dengan Cross-Validation

Penerapan *cross-validation* menghasilkan peningkatan performa pada seluruh model dibandingkan evaluasi menggunakan satu kali pembagian data. CatBoost memperoleh nilai tertinggi dari keseluruhan metrik, sedangkan *Random Forest* menunjukkan performa yang sangat kompetitif dengan selisih yang relatif kecil. XGBoost menghasilkan *precision* yang tinggi namun masih di bawah CatBoost. Hasil evaluasi *cross-validation* ditunjukkan pada Tabel 4 dan Gambar 3.

Tabel 4. Hasil Evaluasi dengan Cross-Validation

Model	Akurasi	Presisi	Recall	F1-Score
CatBoost	80,00%	81,03%	83,93%	82,46%
Random Forest	79,00%	80,70%	82,14%	81,42%
XGBoost	76,00%	80,77%	75,00%	77,78%



Gambar 3. Grafik Perbandingan Metrik Antar Model

Perbedaan hasil antara evaluasi hold-out dan cross-validation menunjukkan bahwa performa model cukup sensitif terhadap variasi pembagian data pada dataset yang berukuran relatif kecil. Metode cross-validation memberikan estimasi performa yang lebih stabil karena setiap observasi memperoleh kesempatan menjadi data pelatihan dan data pengujian secara bergantian, sehingga hasil evaluasi tidak terlalu dipengaruhi oleh satu skenario pembagian data tertentu.

3.3 Global Feature Importance (SHAP)

Analisis SHAP diterapkan pada model CatBoost sebagai model terbaik. Hasil mean SHAP ditampilkan pada Tabel 5.


Tabel 5. SHAP Global Feature Importance dan Perbandingan dengan SEM

Peringkat	Fitur	Mean SHAP	Kategori	SEM β
1	Attitude score	1,1820	Konstruk SEM	0,939 (signifikan)
2	Umur	1,1604	Demografis	-
3	Pendapatan/Bulan	0,7200	Demografis	-
4	Pendidikan	0,5662	Demografis	-
5	Inclusion score	0,4268	Konstruk SEM	-0,046 (tidak signifikan)
6	Literacy score	0,2890	Konstruk SEM	0,193 (tidak signifikan)
7	Lama UMKM Berdiri	0,1030	Demografis	-

Dominasi *attitude score* pada posisi pertama (*Mean SHAP*=1,1820) menunjukkan konsistensi dengan temuan SEM yang menempatkan *Financial Attitude* sebagai satu-satunya konstruk signifikan (β =0,939). Umur menempati posisi kedua (1,1604) dengan selisih tipis, mengungkap kontribusi prediktif variabel demografis yang tidak tertangkap SEM. Secara agregat, fitur demografis berkontribusi sebesar 57,3% dari total SHAP, sedangkan konstruk SEM berkontribusi 42,7%.


3.4 Analisis Beeswarm dan Dependence Plot

Beeswarm Plot menunjukkan bahwa *attitude score* memiliki rentang SHAP terluas dengan pola positif yang jelas: nilai *attitude* tinggi menghasilkan SHAP positif (mendorong prediksi *Good*) dan sebaliknya. Variabel Umur menunjukkan hubungan positif, di mana responden berusia lebih tua cenderung diprediksi ke kelas *Good*. Pendapatan dan pendidikan yang lebih tinggi juga berkorelasi dengan SHAP positif. Lama UMKM berdiri merupakan fitur dengan kontribusi paling terbatas, dengan mayoritas nilai SHAP mendekati nol. Grafik *Beeswarm Plot* ditunjukkan pada Gambar 4.



Gambar 4. Grafik Beeswarm Plot

Dependence Plot pada *attitude score* memperlihatkan kecenderungan hubungan positif antara nilai *attitude* dan SHAP. Pada rentang *attitude score* 2,6-3,1, nilai SHAP negatif (-3,1 hingga -1,0). Pada rentang 3,2-3,4, SHAP bertransisi mendekati nol. Pada *attitude score* di atas 3,6, hampir seluruh observasi memiliki SHAP positif. Interaksi dengan variabel umur terlihat dari variasi warna: responden lebih tua pada rentang *attitude* tinggi menghasilkan SHAP positif yang lebih besar. Grafik *Dependence Plot* ditunjukkan pada Gambar 5.



Gambar 5. Grafik Dependence Plot

3.5 Perbandingan SEM dan SHAP

Perbandingan antara *path coefficient* SEM dan SHAP *feature importance* menghasilkan dua temuan utama. Pertama, *attitude score* konsisten mendominasi pada kedua pendekatan, mengonfirmasi bahwa *Financial Attitude* merupakan faktor paling determinan terhadap *Financial Behavior* UMKM Medan baik secara kausal maupun prediktif. Kedua, *inclusion score* menunjukkan divergensi antara kedua pendekatan: koefisien SEM negatif kecil (-0,046) dan tidak signifikan, namun SHAP *importance*-nya (0,4268) melebihi *literacy score* (0,2890). Divergensi ini mencerminkan perbedaan inheren antara efek kausal linear yang diukur SEM dan kontribusi prediktif non-linear yang diidentifikasi SHAP, bukan inkonsistensi antara dua pendekatan.

4. KESIMPULAN

Penelitian ini mengembangkan model prediktif *Financial Behavior* UMKM Kota Medan menggunakan tiga algoritma *machine learning* dengan interpretabilitas berbasis SHAP. CatBoost teridentifikasi sebagai model terbaik dengan Akurasi 80,00%, Presisi 81,03%, Recall 83,93%, dan F1-Score 82,46% pada evaluasi *Stratified 5-Fold Cross-Validation*, dengan stabilitas performa tertinggi dibandingkan XGBoost dan *Random Forest*. Analisis SHAP mengonfirmasi konsistensi dengan temuan SEM sebelumnya, di mana *attitude score* merupakan fitur dengan kontribusi prediktif tertinggi (Mean SHAP=1,1820), sejalan dengan posisi *Financial Attitude* sebagai satu-satunya konstruk signifikan dalam model SEM ($\beta=0,939$). Perbandingan lintas-paradigma ini menunjukkan keselarasan antara pendekatan kausal dan prediktif pada fitur utama. Di sisi lain, variabel demografis seperti umur, pendapatan, dan pendidikan menunjukkan kontribusi prediktif yang substansial dan tidak terakomodasi dalam model SEM, sementara perbedaan urutan *inclusion score* dan *literacy score* antara SEM dan SHAP mencerminkan perbedaan inheren antara efek kausal linear dan kontribusi prediktif non-linear. Penelitian selanjutnya disarankan menggunakan dataset yang lebih besar dan cakupan wilayah lebih luas untuk meningkatkan generalisasi model.

REFERENSI

- [1] S. Eriyanti, R. M. Dai, and D. Fordian, "The Influence of Financial Management Behavior On MSMEs Sustainability of Tourist Attraction Services," *Islamic Banking : Jurnal Pemikiran dan Pengembangan Perbankan Syariah*, vol. 11, no. 1, pp. 119–132, Aug. 2025, doi: 10.36908/isbank.v11i1.1530.
- [2] N. Perangin-Angin, L. T. B. Ginting, and S. O. Ginting, "Building the Foundation of Financial Behavior among MSMEs in Medan An Analysis of the Roles of Financial Literacy, Financial Attitude, and Financial Inclusion," *Jurnal Manajemen Motivasi*, vol. 21, pp. 1344–1355, 2025.
- [3] P. E. Nopiyani and P. R. Indiani, "Pengaruh Sikap Keuangan, Perilaku Keuangan dan Literasi Keuangan terhadap Kinerja Keuangan UMKM pada Pemdes Ambengan," *Jurnal Akuntansi Kompetif*, vol. 6, no. 3, pp. 411–418, Sep. 2023.
- [4] G. M. Putri, D. S. P. Koesoemasari, and I. Rokhayati, "Literasi, Sikap, Inklusi, Perencanaan Keuangan terhadap Perilaku Manajemen Keuangan UMKM Batik di Kabupaten Purbalingga," *Goodwood Akuntansi dan Auditing Reviu*, vol. 3, no. 1, pp. 1–13, Nov. 2024, doi: 10.35912/gaar.v3i1.3344.
- [5] Z. Zhang, C. Wu, S. Qu, and X. Chen, "An explainable artificial intelligence approach for financial distress prediction," *Inf. Process. Manag.*, vol. 59, no. 4, p. 102988, 2022, doi: <https://doi.org/10.1016/j.ipm.2022.102988>.
- [6] K. Mandal, A. Ghosh, S. Gupta, S. Chowdhury, B. B. Dash, and S. S. Patra, "Redefining Crash Prediction with Interpretable Machine Intelligence," in *2025 5th International Conference on Intelligent Technologies (CONIT)*, 2025, pp. 1–7. doi: 10.1109/CONIT65521.2025.11167794.
- [7] S. J. MacEachern and N. D. Forkert, "Machine learning for precision medicine," *Genome*, vol. 64, no. 4, pp. 416–425, 2021, doi: 10.1139/gen-2020-0131.
- [8] C. Bentéjac, A. Csörgö, and G. Martínez-Muñoz, "A comparative analysis of gradient boosting algorithms," *Artif. Intell. Rev.*, vol. 54, no. 3, pp. 1937–1967, 2021, doi: 10.1007/s10462-020-09896-5.
- [9] T. R. Noviandy *et al.*, "Ensemble Machine Learning Approach for Quantitative Structure Activity Relationship Based Drug Discovery: A Review," *Infolitika Journal of Data Science*, vol. 1, no. 1, pp. 32–41, Sep. 2023, doi: 10.60084/ijds.v1i1.91.
- [10] R. Rivaldo, R. Taufik, I. S. Ilman, and O. D. E. Wulansari, "A Comparative Study of XGBoost, LightGBM, and CatBoost Models for Customer Churn Prediction in the Banking Industry," *Jurnal Pepadun*, vol. 6, no. 2, pp. 178–187, 2025, doi: 10.23960/pepadun.v6i2.277.
- [11] E. R. Putri and D. B. Arianto, "Perbandingan Performa Algoritma Metode Bagging dan Boosting pada Prediksi Konsentrasi PM10 di Jakarta Utara," *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 10, no. 1, pp. 72–81, May 2024, doi: 10.25077/TEKNOSI.v10i1.2024.72-81.
- [12] E. L. Crossesa and A. Sofro, "Application of XGBoost and CatBoost Algorithms for Elderly Hypertension Classification on IFLS 5 Data," *Leibniz: Jurnal Matematika*, vol. 6, no. 1, pp. 1–14, Jan. 2026, doi: 10.59632/leibniz.v6i01.734.
- [13] T. Buyuktanir and K. Yildiz, "Improving Interpretability and Explainability in Financial Models through Ensemble Tree Simplification," in *2025 10th International Conference on Computer Science and Engineering (UBMK)*, 2025, pp. 818–823. doi: 10.1109/UBMK67458.2025.11206812.
- [14] J. Černevičienė and A. Kabašinskas, "Explainable artificial intelligence (XAI) in finance: a systematic literature review," *Artif. Intell. Rev.*, vol. 57, no. 8, p. 216, 2024, doi: 10.1007/s10462-024-10854-8.
- [15] S. Darekar, P. Nilekar, S. Lilhare, A. Chaudhari, R. Narayan, and V. Borate, "A Machine Learning Approach for Bug or Error Prediction using Cat-Boost Algorithm," in *2025 6th International Conference for Emerging Technology (INCET)*, 2025, pp. 1–5. doi: 10.1109/INCET64471.2025.11140996.
- [16] Z. Rais, M. F. S, S. Saida, and A. Triutomo, "Implementation of Machine Learning Algorithm with Extreme Gradient Boosting (XGBoost) Method in Hypertension Level Classification," *Journal of Applied Science, Engineering, Technology, and Education*, vol. 7, no. 1, pp. 126–136, Apr. 2025, doi: 10.35877/454RI.asci4191.
- [17] W. Zhang and H. Zhang, "A Feature Extraction Method for Small Sample Data Based on Optimal Ensemble Random Forest," *Journal of Northwestern Polytechnical University*, vol. 40, no. 6, pp. 1261–1268, Dec. 2022, doi: 10.1051/jnwpu/20224061261.
- [18] J. Bergstra and Y. Bengio, "Random search for hyper-parameter optimization," *J. Mach. Learn. Res.*, vol. 13, no. null, pp. 281–305, Feb. 2012.
- [19] A. Géron, *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*, 2nd ed. Sebastopol, CA: O'Reilly Media, 2019.
- [20] J. Qiu, "An Analysis of Model Evaluation with Cross-Validation: Techniques, Applications, and Recent Advances," in *Proceedings of ICFTBA 2024 Workshop: Finance in the Age of Environmental Risks and Sustainability*, 2024, pp. 69–72. doi: 10.54254/2754-1169/99/2024OX0213.