

PENERAPAN BIG DATA ANALYTICS DAN ARTIFICIAL INTELLIGENCE PADA SEKTOR PERBANKAN DAN KEUANGAN: LITERATURE REVIEW

Joceline Schellenberg W^{1*}, Feri Ranja²

¹Prodi Informatika, Fakultas Teknologi dan Bisnis, Universitas Deztron Indonesia, Indonesia

²Prodi Teknologi Informasi, Fakultas Pendidikan, Bisnis dan Teknologi, Universitas Wirusahada Medan, Indonesia
Email: jocelineschellenberg@udi.ac.id

ABSTRAK

Penerapan Big Data Analytics (BDA) dan Artificial Intelligence (AI) pada sektor perbankan dan keuangan mengalami akselerasi cepat dalam lima tahun terakhir. Penelitian ini menyajikan Systematic Literature Review (SLR) terhadap 37 artikel penelitian empiris terpilih pada empat domain utama: penilaian risiko kredit (credit scoring), deteksi kecurangan (fraud detection), analisis churn nasabah, dan manajemen risiko portofolio. Hasil ulasan menunjukkan pergeseran dari pemodelan statistik tradisional menuju algoritma Gradient Boosting serta Deep Learning. Studi ini juga mengidentifikasi tantangan utama terkait Explainable AI (XAI) untuk kepatuhan regulasi serta strategi penanganan ketidakseimbangan data (data imbalance) pada transaksi finansial real-time.

Kata Kunci: *Big Data Analytics, Artificial Intelligence, Banking Industries, Review*

ABSTRACT

The applications of Big Data Analytics (BDA) and Artificial Intelligence (AI) in the banking and financial sectors have accelerated rapidly over the past five years. This study presents a Systematic Literature Review (SLR) of 37 selected empirical research articles across four main domains: credit scoring, fraud detection, customer churn analysis, and portfolio risk management. The results of the review indicate a shift from traditional statistical modeling toward Gradient Boosting and Deep Learning algorithms. This study also identifies key challenges related to Explainable AI (XAI) for regulatory compliance, as well as strategies for addressing data imbalance in real-time financial transactions

Keywords: *Big Data Analytics, Artificial Intelligence, Banking Industries, Review*

Article History:

Received : 06-06-2026

Revised : 13-06-2026

Accepted : 01-07-2026

Published : 20-07-2026

A. LATAR BELAKANG

Transformasi digital di industri perbankan menghasilkan volume data transaksi yang sangat besar (*Big Data*), mencakup log transaksi, riwayat kredit, interaksi aplikasi seluler, hingga data teks tidak terstruktur dari layanan pelanggan. Untuk mengolah aset data tersebut, lembaga keuangan secara masif mengadopsi teknik *Machine Learning* (ML) dan Deep Learning (DL) guna meningkatkan efisiensi operasional dan mitigasi risiko.

Meskipun potensi *Artificial Intelligence* (AI) pada sektor keuangan sangat tinggi, penerapannya dihadapkan pada tantangan regulasi ketat, ketidakseimbangan kelas (class imbalance) pada transaksi kecurangan, serta tuntutan transparansi keputusan algoritma (explainability). Tinjauan pustaka ini bertujuan untuk mengevaluasi studi-studi empiris terkini guna menjawab pertanyaan penelitian:

1. Algoritma ML/DL apa yang paling efektif dan dominan diterapkan pada masing-masing domain perbankan?

2. Bagaimana peneliti menangani tantangan teknis seperti imbalanced data dan transparansi pemodelan pada data keuangan?

B. METODE PENELITIAN

Kata kunci yang digunakan meliputi "Bid Data Analytics Approaches", "Artificial Intelligence", "Problem-Solving and Challenges in Banking Industries". Tinjauan pustaka ini menyintesis 37 artikel penelitian empiris yang dikurasi menggunakan kerangka kerja PRISMA (Preferred Reporting Items for Systematic Reviews and Meta-Analyses) (Page, et.al., 2021). Kriteria inklusi meliputi:

- Artikel diterbitkan pada jurnal/konferensi bereputasi dalam rentang tahun 2021–2026.
- Menyajikan pengujian empiris menggunakan dataset keuangan riil atau benchmark industri perbankan (seperti dataset Kaggle Credit Card Fraud, German Credit Data, atau data internal bank).
- Menampilkan metrik evaluasi kuantitatif yang jelas (misalnya Accuracy, AUC-ROC, F1-Score, atau Precision-Recall).

Dari total 142 artikel awal yang diidentifikasi melalui basis data IEEE Xplore dan ScienceDirect, sebanyak 37 artikel penelitian primer diulas.

C. HASIL DAN PEMBAHASAN

1. Penilaian Kredit (Credit Scoring) dan Prediksi Gagal Bayar

Dalam pemodelan risiko kredit, algoritma berbasis Gradient Boosted Decision Trees (GBDT) mendominasi literatur empiris karena ketahanannya terhadap data tabular berdimensi tinggi.

Implementasi credit scoring pada platform Peer-to-Peer (P2P) lending dilakukan oleh (Zhang et al, 2022) menggunakan algoritma XGBoost yang terintegrasi dengan kerangka SHAP (Lundberg et.al., 2017) untuk transparansi evaluasi pinjaman. Dalam segmen kredit UMKM, (Kumar et al., 2023) membuktikan bahwa teknik Stacking Ensemble (LightGBM, CatBoost, dan Random Forest) menghasilkan nilai F1-Score sebesar 91,4%. Penggunaan data alternatif seperti jejak digital aplikasi seluler diuji oleh (Prasetyo & Raharjo, 2024) menggunakan Multi-Layer Perceptron (MLP) untuk memprediksi gagal bayar pada populasi unbanked.

Eksplorasi algoritma hibrida untuk klasifikasi risiko kredit juga dikembangkan oleh (Ala'raj et al., 2021), sedangkan (Bussmann et al., 2021) menguji penggabungan Extreme Gradient Boosting dengan pemodelan grafik risiko untuk kepatuhan regulasi perbankan. Pada dataset kredit konsumen skala besar, (Tripathy et al., 2022) menerapkan Deep Neural Networks (DNN) dengan teknik regulasi Dropout, yang terbukti mengungguli Regresi Logistik. Lebih lanjut, (Niu et al, 2023) memanfaatkan arsitektur TabNet untuk mengolah data kredit tabular secara langsung tanpa feature engineering manual, sementara (Silva et al., 2025) menerapkan kerangka Federated Learning untuk memungkinkan kolaborasi pemodelan risiko kredit antar-bank tanpa membagikan data mentah nasabah.

2. Deteksi Kecurangan (Fraud Detection) dan Anti-Pencucian Uang / AML

Tantangan utama pada deteksi kecurangan transaksi perbankan adalah ketidakseimbangan data yang ekstrem, di mana transaksi kecurangan umumnya jauh di bawah 1% dari total populasi transaksi.

Deteksi kecurangan transaksi berbasis relasi grafik dikembangkan oleh (Wang et al., 2023) menggunakan Temporal Graph Convolutional Network (T-GCN) untuk mengidentifikasi jaringan pencucian uang. Penanganan class imbalance dilakukan oleh (Alibeigi et al., 2022) dengan menggabungkan Variational Autoencoder (VAE) dan XGBoost. Untuk pemrosesan aliran data (data stream) real-time, (Chen & Liu, 2025) menerapkan algoritma Local Outlier Factor (LOF) terdistribusi di atas ekosistem Apache Spark.

Studi empiris oleh (Lucas et al., 2021) mengusulkan pemodelan Hidden Markov Model (HMM) berbasis perspektif berganda untuk menangani pergeseran pola transaksi kartu kredit. Penanganan sintesis data fraud menggunakan Generative Adversarial Networks (GANs) diteliti oleh (Fiore et al., 2022), yang berhasil meningkatkan nilai Recall pada klasifikator dasar. Pemodelan deret waktu transaksi diuji oleh (Forough dan Momtazi, 2021) menggunakan kombinasi Bi-LSTM dan mekanisme Attention. Selanjutnya, (Zheng et al., 2024) menggunakan Graph Attention Networks (GAT) untuk mendeteksi transaksi online banking yang mencurigakan. Evaluasi perbandingan algoritma konvensional (KNN, Naive Bayes, Logistic Regression) dilakukan oleh (Awoyemi et al., 2022), dan pendekatan Self-Supervised Learning untuk deteksi kecurangan latensi rendah diusulkan oleh (Nguyen et al., 2026).

3. Bank Service Improvements

Selain Fraud Detection, Generative Adversarial Networks juga digunakan untuk mengatasi class imbalance pada analisis dan prediksi ketersediaan uang tunai di mesin ATM. Studi Kasus penelitian yang dilakukan oleh (Ranja et al., 2023) mengangkat permasalahan bank pemerintah daerah, dimana penggunaannya lebih sedikit dari bank swasta di Indonesia. Peneliti menggunakan Time-GAN (Time- Generative Adversarial Network) untuk memperbanyak jumlah data time-series (data utama penelitian) dan Extreme Gradient Boosting (XGBoost) untuk memprediksi kapan uang tunai dalam mesin ATM perlu diisi kembali, agar bank dapat mengelola dana dengan lebih baik.

4. Analisis Nasabah, Prediksi Churn, dan Layanan Personalisasi

Mempertahankan nasabah merupakan fokus efisiensi biaya perbankan. Machine learning digunakan secara luas untuk memprediksi potensi nasabah menutup rekening (churn) dan memberikan rekomendasi produk finansial.

Prediksi churn nasabah bank berbasis data multimodal dilakukan oleh (De Caigny et.al., 2021) menggabungkan CNN dan penambangan teks (text mining). Analisis sentimen terhadap ulasan aplikasi mobile banking dikembangkan oleh (Li et al., 2024) menggunakan fine-tuned BERT. Penelitian prediksi churn pada perbankan ritel juga dilakukan oleh (Bilgic et al., 2022) menggunakan XGBoost dan (Amin et al., 2021) yang berfokus pada metode sampling berbasis jarak untuk mengatasi imbalance kelas data nasabah. (Putra et al., 2024) melakukan prediksi churn nasabah bank daerah menggunakan Confident Learning untuk mengatasi masalah uncertain atau mislabeled training data, dan XGBoost sebagai algoritma prediksi.

Estimasi Customer Lifetime Value (LTV) dikembangkan oleh (Kim & So, 2023) memanfaatkan Recurrent Neural Networks (RNN). Untuk personalisasi penawaran produk keuangan (cross-selling), (Rahman et al., 2024) membangun sistem rekomendasi hibrida berbasis Collaborative Filtering dan Matrix Factorization. (Santos et al., 2022) menerapkan Random Survival Forests untuk memprediksi durasi retensi nasabah. Integrasi Large Language Models (LLM) untuk otomatisasi layanan pelanggan perbankan diuji oleh (Zhao et al., 2025), sedangkan (Hernandez et.al., 2023) melakukan segmentasi perilaku penggunaan kartu kredit menggunakan klusterisasi K-Means dan DBSCAN.

5. Manajemen Risiko Keuangan dan *Algorithmic Trading*

Pada domain pasar modal dan manajemen risiko portofolio, kecerdasan buatan dimanfaatkan untuk memprediksi volatilitas harga aset dan otomatisasi eksekusi perdagangan.

Optimasi portofolio investasi berbasis Deep Reinforcement Learning (DRL) diuji secara empiris oleh (Jiang et al., 2022) menggunakan algoritma PPO. Prediksi harga aset finansial berbasis time-series diteliti oleh (Zhang dan Tan, 2023) memanfaatkan Temporal Fusion Transformer (TFT). Studi penetapan harga aset berbasis ML secara luas dievaluasi oleh (Gu et al., 2021).

Prediksi risiko sistemik perbankan diuji oleh (Kim et al., 2022) menggunakan integrasi LSTM-Attention. Optimasi portofolio dengan fungsi reward sensitif terhadap risiko dikembangkan oleh (Liu et al., 2024). Korelasi jaringan pasar saham dimodelkan oleh (Wang dan Zhou, 2023) menggunakan Graph Convolutional Networks (GCN). Eksekusi perdagangan frekuensi tinggi (High-Frequency Trading) diuji oleh (Wu et al., 2025) berbasis Deep Q-Networks (DQN). Pemodelan prediksi nilai tukar mata uang dikembangkan oleh (Patel & Shah, 2021) menggunakan hibrida ARIMA-LSTM, serta pengujian stres (stress testing) neraca bank berbasis Bayesian Neural Networks dikembangkan oleh (Rossi et al., 2024).

Tabel berikut merangkum sintesis dari beberapa penelitian empiris utama yang diulas dalam studi ini:

Tabel 1. Perbandingan Penelitian

Peneliti & Tahun	Key Points			
	Domain Aplikasi	Dataset / Ukuran Data	Algoritma Utama	Metrik Kinerja Utama
(Zhang et al., 2022)	Credit Scoring P2P	Dataset P2P Lending (100k+ sampel)	XGBoost + SHAP	AUC: 0.892
(Kumar et al., 2023)	Kredit UMKM	Data Kredit Bank Komersial	Stacking Ensemble	F1-Score: 91.4%
(Prasetyo & Raharjo, 2024)	Kredit <i>Unbanked</i>	Data Perilaku Aplikasi Mobile	Multi-Layer Perceptron	Accuracy: 85.3%

Peneliti & Tahun	Key Points			
	Domain Aplikasi	Dataset / Ukuran Data	Algoritma Utama	Metrik Kinerja Utama
(Ala'raj et al., 2021)	Risiko Kredit	Benchmark Credit Datasets	Hybrid Ensemble Classifier	Accuracy: 87.6%
(Bussmann et al., 2021)	FinTech Credit Risk	Data Pinjaman FinTech	XGBoost + Network Models	AUC: 0.865
(Tripathy et al., 2022)	Default Kartu Kredit	Taiwan Credit Card Dataset	Deep Neural Network	AUC: 0.841
(Niu et al., 2023)	Kredit Ritel	Dataset Perbankan Ritel	TabNet Architecture	F1-Score: 88.9%
(Silva et al., 2025)	<i>Federated Credit Scoring</i>	Cross-Bank Multi-center Data	Federated Learning + XGBoost	AUC: 0.878
(Wang et al., 2023)	Deteksi AML	Graph Transaksi Perbankan	Temporal GNN (T-GCN)	Recall: 89.6%
(Alibeigi et al., 2022)	Fraud Kartu Kredit	Kaggle Fraud (284k data)	VAE + XGBoost	PR-AUC: 0.820
(Chen & Liu, 2025)	Deteksi Anomali Stream	Big Data Transaksi (Spark)	Distributed LOF	Latensi: < 20 ms
(Lucas et al., 2021)	Fraud Kartu Kredit	Data Transaksi Bank Eropa	Multi-perspective HMM	Precision: 84.2%
(Fiore et al., 2022)	Sintesis Data Fraud	Imbalanced Fraud Dataset	GANs + Random Forest	Recall: 91.1%
(Forough & Momtazi, 2021)	Fraud Transaksi	Sequence Transaction Logs	Bi-LSTM + Attention	F1-Score: 86.7%
(Zheng et al., 2024)	Fraud <i>Online Banking</i>	Log Sesi & Transaksi Web	Graph Network Attention	AUC: 0.923
(Awoyemi et al., 2022)	Fraud Detection	Credit Card Fraud Dataset	KNN & Logistic Regression	Accuracy: 97.9%
(Nguyen et al., 2026)	Real-time Fraud	Stream Transaksi Finansial	Self-Supervised Transformer	Latensi: 12 ms

Peneliti & Tahun	Key Points						
	Domain Aplikasi		Dataset / Ukuran Data	Algoritma Utama		Metrik Kinerja Utama	
(Ranja, et al., 2023)	Prediksi Ketersediaan Tunai ATM		Log Transaksi ATM	Time-GAN & XGBoost		MAE 2.57, MSE 1.64, dan R-squared 5.02.	
(De Caigny et al., 2021)	Prediksi <i>Churn</i>		Data Log & Teks Rekening	CNN + Text Mining		Accuracy: 88.7%	
(Putra et al., 2024)	Prediksi <i>Churn</i>		Data log Transaksi	XGBoost		Accuracy: 81.2%.	
(Li et al., 2024)	Sentimen App Banking		App Store Review (50k ulasan)	Fine-tuned BERT		Accuracy: 93.2%	
(Bilgic et al., 2022)	<i>Churn</i> Perbankan Ritel		Data Nasabah Bank Ritel	XGBoost Classifier		AUC: 0.884	
(Amin et al., 2021)	Prediksi <i>Churn</i>		Imbalanced Customer Data	Distance-based Sampling		F1-Score: 83.5%	
(Kim & So, 2023)	Customer Lifetime Value		Transaksi Historis Nasabah	Recurrent Neural Network		MAE: 12.4	
(Rahman et al., 2024)	Rekomendasi Produk		Data Portofolio Produk Bank	Matrix Factorization		Precision@K: 78.4%	
(Santos et al., 2022)	Retensi Nasabah		Longitudinal Bank Dataset	Random Forests	Survival	C-Index: 0.812	
(Zhao et al., 2025)	Layanan Pelanggan AI		Dialog Customer Service Bank	Multi-modal LLM		Satisfaction: 91.5%	
(Hernandez et al., 2023)	Segmentasi Nasabah		Data Pemakaian Kartu Kredit	K-Means + DBSCAN		Silhouette: 0.68	
(Jiang et al., 2022)	Optimasi Portofolio		Data Saham & Komoditas	DRL (PPO Algorithm)		Sharpe Ratio: 1.82	
(Zhang & Tan, 2023)	Prediksi Harga Aset		Time-Series Keuangan 10 Thn	Temporal Fusion Transformer		RMSE: 0.012	
(Gu et al., 2021)	Asset Pricing		Data Pasar Modal AS	Machine Learning Ensembles		R-squared: 18.4%	
(Kim et al., 2022)	Indikator Risiko Sistemik		Data Makro & Perbankan	LSTM-Attention		AUC: 0.895	
(Liu et al., 2024)	Manajemen Portofolio		Data Pasar Multi-Aset	Risk-sensitive RL		Sharpe Ratio: 1.94	

Peneliti & Tahun	Key Points				
	Domain Aplikasi	Dataset / Ukuran Data	Algoritma Utama		Metrik Kinerja Utama
(Wang & Zhou, 2023)	Analisis Jaringan Pasar	Pergerakan Harga Saham	Graph Convolutional Network		Accuracy: 81.2%
(Wu et al., 2025)	High-Frequency Trading	Order Book Level-2 Data	Deep Q-Network (DQN)	Q-Network	Profit/Trade: +1.4%
(Patel & Shah, 2021)	Prediksi Kurs Valas	Time-Series Nilai Tukar	ARIMA-LSTM Hybrid		MAPE: 1.15%
(Rossi et al., 2024)	Stress Testing Bank	Balance Sheet Data Perbankan	Bayesian Networks	Neural	Error Rate: 2.1%

3.5.Tantangan Utama dan Arah Penelitian Masa Depan

Berdasarkan sintesis terhadap 37 artikel penelitian empiris di atas, diidentifikasi tiga tantangan utama yang menjadi perhatian peneliti:

1. Interpretabilitas Model vs Akurasi (*Explainable AI*):

Meskipun model *Deep Learning* seperti GNN (Wang et al., 2023); (Zheng et al., 2024) dan Transformers (Zhang et al, 2022) memiliki akurasi tinggi pada deteksi kecurangan dan pemodelan harga aset, sifatnya yang menyerupai *black-box* membatasi penerapannya dalam *credit scoring* akibat regulasi perbankan yang ketat seperti panduan Basel III/IV (Basel Committee on Banking Supervision, 2017). Implementasi XAI seperti SHAP (Zhang et al, 2022); (Lundberg, et.al, 2017) telah diterapkan pada model tabular, namun metode interpretasi untuk data berstruktur grafik (*graph data*) masih membutuhkan eksplorasi lebih lanjut.

2. Skalabilitas Pemrosesan *Stream Data* Keuangan:

Pengujian sistem analitik pada skala *Big Data* memerlukan infrastruktur yang mampu menangani *high throughput* dan *low latency* (Chen & Liu, 2025); (Nguyen et al., 2026). Penggabungan arsitektur *stream processing* (seperti Apache Kafka dan Spark) dengan pemodelan *Deep Learning* secara *on-the-fly* merupakan tantangan teknis yang membutuhkan optimasi sumber daya komputasi.

3. Pergeseran Pola Transaksi (*Concept Drift*):

Pola penipuan finansial berkembang secara dinamis (Lucas et al., 2021). Algoritma ML yang dilatih pada data historis kerap mengalami penurunan performa seiring waktu (*concept drift*). Diperlukan pengembangan model *Continual Learning* dan *Adaptive Machine Learning* yang dapat memperbarui parameter model secara mandiri tanpa perlu dilatih ulang secara menyeluruh dari awal (*retraining from scratch*).

D. KESIMPULAN DAN SARAN

Tinjauan pustaka sistematis ini membuktikan bahwa integrasi Big Data Analytics dan AI telah mentransformasi operasional industri perbankan dan keuangan. Algoritma berbasis Gradient Boosting (XGBoost, LightGBM) terbukti tetap menjadi pilihan utama untuk data tabular terstruktur seperti pada pemodelan credit scoring, sementara arsitektur Deep Learning modern (GNN, Transformers, dan DRL) mendominasi penanganan data

grafik relasional transaksi kecurangan, deret waktu harga pasar, dan optimasi portofolio. Penelitian mendatang diproyeksikan akan lebih berfokus pada penguatan aspek Explainable AI (XAI) untuk pemenuhan regulasi serta ketahanan model terhadap concept drift.

Meskipun penelitian ini mencakup literatur relevan yang dikumpulkan dari jurnal-jurnal peer-review, masih terdapat beberapa keterbatasan dalam penelitian ini. Ada kemungkinan bahwa artikel-artikel yang tidak terindeks di Scopus dan Web of Science mungkin relevan dengan ruang lingkup penelitian ini. Di masa mendatang, penelitian teoretis dan empiris yang mendalam perlu dilakukan untuk mengatasi tantangan big data di industri perbankan. Selain itu, penelitian ini menyarankan agar dilakukan penelitian lebih lanjut mengenai peningkatan efisiensi melalui analisis big data di industri perbankan.

E. DAFTAR PUSTAKA

- Ala'raj, S., Majdalawieh, M. F., & Nishad, K. (2021). A hybrid ensemble classifier for credit scoring in commercial banking. *Expert Systems with Applications*, 172, Article 114656.
- Alibeigi, M., Hashemi, S., & Hamzeh, A. (2022). A hybrid autoencoder and XGBoost model for addressing extreme class imbalance in credit card fraud detection. *Expert Systems with Applications*, 190, Article 116160.
- Amin, A., Anwar, S., & Adnan, M. (2021). Distance-based sampling for imbalanced customer churn prediction in financial institutions. *Data & Knowledge Engineering*, 131, Article 101868.
- Awoyemi, B. S., Adetunmbi, A. O., & Ali, U. A. (2022). Comparative analysis of machine learning algorithms for credit card fraud detection. *Journal of Financial Crime*, 29(4), 1301–1314.
- Basel Committee on Banking Supervision. (2017). Basel III: Finalising post-crisis reforms (Technical Report). Bank for International Settlements (BIS).
- Bilgic, P., Erdem, M., & Kaya, A. (2022). Customer churn prediction in retail banking using XGBoost classifier. *International Journal of Bank Marketing*, 40(5), 981–999.
- Bussmann, N., Giudici, P., Marinelli, S., & Papenbrock, L. (2021). Explainable AI in Fintech credit risk management. *Finance Research Letters*, 42, Article 101939.
- Chen, X., & Liu, Y. (2025). Real-time distributed anomaly detection in banking Big Data streams using Apache Spark. *IEEE Access*, 13, 10245–10258.
- De Caigny, A., Coussemont, K., & De Bock, K. W. (2021). A new hybrid classification algorithm for customer churn prediction based on text reviews and transactional data. *European Journal of Operational Research*, 290(3), 1182–1194.
- F. Ranja, E. B. Nababan and A. Candra, "Synthetic Data Generation Using Time-Generative Adversarial Network (Time-GAN) to Predict Cash ATM," 2023 International Conference on Computer, Control, Informatics and its Applications (IC3INA), Bandung, Indonesia, 2023, pp. 418-423
- Fiore, U., De Santis, A., Perla, F., Zanetti, P., & Rossi, F. (2022). Using Generative Adversarial Networks to overcome class imbalance in financial fraud detection. *Information Sciences*, 584, 312–327.
- Forough, J., & Momtazi, S. (2021). Sequential transaction log modeling using Bi-LSTM and attention mechanism for credit card fraud detection. *Journal of Information Security and Applications*, 60, Article 102862.
- Gu, S., Kelly, B., & Xiu, D. (2021). Empirical asset pricing via machine learning. *The Review of Financial Studies*, 34(5), 2223–2277.
- Hernandez, M., Lopez, C., & Ramirez, G. (2023). Credit card customer segmentation using hybrid K-Means and DBSCAN clustering. *Expert Systems*, 40(4), Article e13210.
- I. S. Putra, O. S. Sitompul and E. B. Nababan, "Customer Churn Prediction using Confident Learning and XGBoost," 2024 International Conference on Computer, Control, Informatics and its Applications (IC3INA), Bandung, Indonesia, 2024, pp. 315-318
- Jiang, Z., Xu, D., & Liang, J. (2022). Financial portfolio management with deep reinforcement learning: A PPO-based empirical evaluation. *Quantitative Finance*, 22(8), 1501–1515.

- Kim, J., Park, N., & Lee, K. (2022). Systemic risk forecasting in banking networks using LSTM with attention mechanism. *Journal of Financial Stability*, 60, Article 101005.
- Kim, S., & So, H. (2023). Customer lifetime value estimation in retail banking using recurrent neural networks. *Journal of Retailing and Consumer Services*, 71, Article 103210.
- Kumar, S., Sharma, R., & Verma, A. (2023). SME credit scoring using a stacking ensemble of LightGBM and CatBoost. *Journal of Financial Data Science*, 5(2), 45–61.
- Li, H., Wang, Y., & Zhang, T. (2024). Aspect-based sentiment analysis of mobile banking application reviews using fine-tuned BERT. *Computers in Human Behavior*, 151, Article 107980.
- Liu, Y., Zhang, W., & Meng, Z. (2024). Risk-sensitive reinforcement learning for dynamic portfolio optimization. *IEEE Transactions on Neural Networks and Learning Systems*, 35(8), 10890–10902.
- Lucas, Y., Portier, P. E., Laporte, L., He-Guelton, L., Caelen, O., & Granitzer, M. (2021). Multiple perspective Hidden Markov Models for credit card fraud detection. *Pattern Recognition Letters*, 145, 120–127.
- Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. Dalam *Advances in Neural Information Processing Systems (NeurIPS 2017)* (vol. 30, hlm. 4765–4774). Neural Information Processing Systems.
- Nguyen, T., Tran, H., & Le, D. (2026). Low-latency transaction fraud detection via self-supervised vision transformers on tabular embeddings. *IEEE Transactions on Information Forensics and Security*, 21, 405–418.
- Niu, K., Zhang, J., & Wang, L. (2023). TabNet for retail credit risk assessment: An empirical evaluation on tabular banking data. *IEEE Transactions on Reliability*, 72(3), 1102–1114.
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., ... & Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *BMJ*, 372, Article n71.
- Patel, V., & Shah, M. (2021). Foreign exchange rate forecasting using hybrid ARIMA-LSTM model. *Journal of King Saud University - Computer and Information Sciences*, 33(9), 1135–1146.
- Prasetyo, B., & Raharjo, S. (2024). Predicting loan default of unbanked population using mobile digital footprints and multi-layer perceptron. *Asian Journal of Information Systems*, 12(1), 78–92.
- Rahman, M., Islam, T., & Ahmed, R. (2024). Hybrid recommendation system for banking product cross-selling using matrix factorization. *Decision Support Systems*, 176, Article 114050.
- Rossi, E., Ferrari, M., & Conti, A. (2024). Bayesian neural networks for bank balance sheet stress testing under macroeconomic shocks. *Journal of Econometrics*, 240(2), Article 105680.
- Santos, L., Ribeiro, R., & Silva, F. (2022). Random survival forests for customer retention analysis in commercial banking. *Journal of Business Research*, 142, 512–525.
- Silva, R., Santos, M., & Oliveira, J. (2025). Federated learning for cross-institutional credit scoring without privacy leakage. *Future Generation Computer Systems*, 162, 201–214.
- Tripathy, N., Ray, A. K., & Mishra, S. C. (2022). Credit card default prediction using deep neural networks with dropout regularization. *Journal of Banking and Financial Technology*, 6(1), 23–35.
- Wang, H., & Zhou, Y. (2023). Modeling stock market correlation networks using Graph Convolutional Networks. *Knowledge-Based Systems*, 268, Article 110480.
- Wang, Y., Zhang, C., & Zhao, X. (2023). Temporal graph convolutional networks for financial anti-money laundering detection. *IEEE Transactions on Knowledge and Data Engineering*, 35(9), 9110–9123.
- Wu, C., Chen, T., & Huang, L. (2025). High-frequency trading execution strategy using Deep Q-Networks on level-2 limit order book data. *Financial Innovation*, 11(1), Article 14.
- Zhang, L., Chen, X., & Wang, M. (2022). Interpretable credit scoring model using XGBoost and SHAP in peer-to-peer lending. *Decision Support Systems*, 158, Article 113780.
- Zhang, R., & Tan, K. (2023). Stock market prediction using Temporal Fusion Transformers: An empirical study on high-frequency time series. *Neural Computing and Applications*, 35(14), 10425–10440.
- Zhao, X., Lin, Y., & Chen, H. (2025). Multi-modal Large Language Models for automated customer service in commercial banks. *Computers in Industry*, 164, Article 104180.
- Zheng, P., Yuan, S., & Wu, X. (2024). Graph attention networks for fraud detection in online banking session logs. *ACM Transactions on Knowledge Discovery from Data*, 18(2), 1–19.