



Kenna Cell Daily Cash Transaction Analysis System Using Machine Learning

Sistem Analisis Transaksi Tunai Harian Kenna Cell Menggunakan Machine Learning

Niken Ayu Ambarwati^{1*}, Andy Prasetyo Utomo², Supriyono³

^{1,2,3}Program Studi Sistem Informasi, Fakultas Teknik, Universitas Muria Kudus, Indonesia

E-Mail: ¹nikenayuu02@gmail.com, ²andy.prasetyo@umk.ac.id, ³supriyono.si@umk.ac.id

Received Jun 08th 2026; Revised Jul 21th 2026; Accepted Aug 10th 2026; Available Online Aug 16th 2026

Corresponding Author: Niken Ayu Ambarwati

Copyright © 2026 by Authors, Published by Institut Riset dan Publikasi Indonesia (IRPI)

Abstract

Daily cash transaction analysis is important for micro, small, and medium enterprises (MSMEs) that record transactions through multiple digital payment channels. Kenna Cell manages 13,289 transaction records across eight payment channels, creating an operational need for a structured daily analysis to anticipate nominal outflows and transaction density. This study aims to develop a machine learning-based system that cleans cash transaction data, constructs a daily panel, estimates next-day nominal outflow, and classifies transaction density into low, medium, and high categories. The workflow follows CRISP-DM through data understanding, data cleaning, feature engineering, time-based model training, evaluation, and prediction. Data preparation yields 13,289 clean transaction records and 3,904 daily records, each with 41 indicators. XGBoost, LightGBM, and CatBoost are compared for regression and classification using MAE, RMSE, MAPE, R2, accuracy, precision, recall, macro F1-score, and weighted F1-score. CatBoost Regressor achieves the lowest error with an RMSE of Rp 3,534,296.59 and an MAPE of 14.50%, while CatBoost Classifier provides the best class balance with an accuracy of 0.8066 and a macro F1-score of 0.7713. The novelty of this study lies in integrating daily panel construction, next-day nominal regression, transaction-density classification, and per-channel prediction into a single web-based operational workflow for MSMEs. The resulting information supports more targeted daily liquidity preparation, while low-confidence predictions remain subject to managerial verification.

Keywords: Cash Flow, CatBoost, CRISP-DM, Liquidity Prediction, Machine Learning.

Abstrak

Analisis transaksi tunai harian menjadi kebutuhan penting bagi UMKM yang mencatat transaksi melalui berbagai metode pembayaran digital. Kenna Cell mengelola 13.289 catatan transaksi pada delapan metode pembayaran, sehingga pemilik usaha membutuhkan analisis harian yang terstruktur untuk mengantisipasi arus keluar dan tingkat kepadatan transaksi. Penelitian ini bertujuan membangun sistem berbasis machine learning yang membersihkan data transaksi tunai, menyusun panel harian, memperkirakan nominal outflow pada hari berikutnya, dan mengelompokkan kepadatan transaksi ke dalam kategori rendah, sedang, dan tinggi. Alur penelitian mengikuti CRISP-DM melalui tahap pemahaman data, pembersihan data, feature engineering, pelatihan berbasis urutan waktu, evaluasi, dan prediksi. Tahap persiapan menghasilkan 13.289 transaksi rapi dan 3.904 data harian dengan 41 indikator. XGBoost, LightGBM, dan CatBoost dibandingkan pada tugas regresi dan klasifikasi menggunakan MAE, RMSE, MAPE, R2, akurasi, presisi, recall, F1-Score Macro, dan F1-Score Weighted. CatBoost Regressor menghasilkan kesalahan terendah dengan RMSE Rp 3.534.296,59 dan MAPE 14,50%, sedangkan CatBoost Classifier memberikan keseimbangan kelas terbaik dengan akurasi 0,8066 dan F1-Score Macro 0,7713. Kebaruan penelitian terletak pada integrasi pembentukan panel harian, regresi nominal hari berikutnya, klasifikasi kepadatan transaksi, dan prediksi berdasarkan metode pembayaran dalam satu workflow operasional berbasis web untuk UMKM. Informasi yang dihasilkan mendukung persiapan likuiditas harian secara lebih terarah, dengan tetap memerlukan verifikasi manajerial ketika probabilitas prediksi rendah.

Kata Kunci: Arus Kas, CatBoost, CRISP-DM, Machine Learning, Prediksi Likuiditas

1. PENDAHULUAN

Digitalisasi pencatatan transaksi membuat UMKM tidak lagi hanya mengandalkan rekam manual untuk memahami arus kas harian. Pada usaha ritel seperti Kenna Cell, aktivitas setor dan tarik tunai berlangsung melalui kanal perbankan, dompet digital, serta pembayaran berbasis QR. Dataset penelitian memuat 13.289 transaksi pada delapan metode pembayaran yang kemudian membentuk 3.904 observasi harian. Volume dan keragaman kanal tersebut menimbulkan persoalan operasional berupa kesulitan membaca perubahan nominal masuk, nominal keluar, fee, net flow, serta kepadatan transaksi secara cepat pada setiap kanal. Tanpa analisis harian yang konsisten, persiapan dana berpotensi hanya bergantung pada intuisi dan rekam historis sederhana, padahal digitalisasi keuangan menuntut informasi yang lebih terstruktur untuk mendukung keputusan UMKM [1]–[8].

Analisis transaksi setor dan tarik tunai berbeda dari laporan keuangan periodik karena fokusnya bukan hanya menghitung total transaksi, tetapi juga memperkirakan nominal outflow pada hari berikutnya dan memetakan kepadatan transaksi pada setiap metode pembayaran. Permasalahan utama Kenna Cell adalah fluktuasi antahari dan perbedaan skala nominal antarkanal, sehingga satu nilai rata-rata umum tidak cukup mewakili kebutuhan operasional. Output sistem diperlukan untuk membaca kecenderungan nominal, fee, net flow, serta kategori kepadatan transaksi agar pemilik usaha dapat menentukan kanal yang perlu diprioritaskan dalam persiapan dana harian [2], [9]–[15].

Penelitian terdahulu menunjukkan bahwa sistem keuangan cerdas dan model statistik mampu meningkatkan otomatisasi pencatatan serta penyajian informasi keuangan UMKM [1], [2]. Kajian digitalisasi, business intelligence, dan sistem informasi keuangan juga menegaskan keamanan data, dan NLP memperlihatkan luasnya penerapan komputasi cerdas pada sistem operasional [16]–[18]. Kelebihan studi-studi tersebut terletak pada otomatisasi proses, pemanfaatan data historis, dan penyediaan informasi yang lebih cepat. Namun, sebagian besar masih berfokus pada pelaporan keuangan, transformasi digital secara umum, atau satu tugas analitik tertentu. Belum banyak penelitian yang menyatukan pembersihan data transaksi, pembentukan panel harian per kanal, prediksi nominal hari berikutnya, klasifikasi kepadatan, evaluasi multi-model, dan penyajian hasil langsung pada aplikasi operasional UMKM. Kesenjangan inilah yang menjadi dasar penelitian ini. Manfaat teknologi bagi kualitas keputusan dan kinerja usaha, sedangkan studi IoT,

Beberapa artikel terbaru pada Jurnal Informatika: Jurnal Pengembangan IT menunjukkan bahwa riset sistem informasi keuangan, prediksi berbasis data historis, Internet of Things, keamanan data, dan pemodelan berbasis machine learning semakin banyak diterapkan pada konteks UMKM dan data operasional. Studi tersebut mencakup sistem keuangan cerdas untuk UMKM, sistem informasi keuangan berbasis model statistik, monitoring IoT, analisis keamanan, chatbot NLP, serta pemrosesan citra berbasis machine learning [1], [2], [16]–[18].

Machine learning digunakan karena hubungan antara lag transaksi, rata-rata bergerak, waktu, metode pembayaran, dan nominal outflow berpotensi non-linear serta mengandung interaksi antarfitur. XGBoost, LightGBM, dan CatBoost dipilih sebagai tiga representasi gradient boosting untuk memperoleh pembandingan empiris pada data tabular: XGBoost menyediakan regularisasi yang kuat sebagai baseline, LightGBM menekankan efisiensi pembentukan pohon, sedangkan CatBoost dirancang untuk menangani informasi kategorikal dan mengurangi bias estimasi selama boosting. Dibandingkan model linear, ketiganya lebih fleksibel dalam menangkap pola non-linear; dibandingkan pendekatan deep learning, model boosting lebih sesuai dengan skala data penelitian dan lebih ringan untuk diintegrasikan ke aplikasi web. Pemilihan model terbaik tidak ditetapkan secara apriori, tetapi ditentukan melalui evaluasi regresi dan klasifikasi pada data uji berbasis waktu. Dasar penggunaan supervised learning, pemisahan kronologis, fitur historis, serta evaluasi multi-metrik mengacu pada praktik machine learning dan forecasting [19]–[23].


Artikel ini berfokus pada sistem berjalan yang diimplementasikan dalam fitur Analisis Setor/Tarik Tunai. Sistem menjalankan lima tahap utama, yaitu Data Cleaning, Feature Engineering, Model Training, Model Evaluation, dan Prediction, dengan sumber data dari tabel transaksi_tunai atau berkas impor berkolom tgl, transaksi, dan metode_pembayaran. Kebaruan penelitian terletak pada integrasi end-to-end workflow machine learning ke dalam aplikasi web: transaksi mentah diubah menjadi panel harian per kanal, digunakan secara simultan untuk regresi nominal dan klasifikasi kepadatan, dibandingkan melalui beberapa algoritma boosting, kemudian disajikan kembali sebagai prediksi per metode pembayaran. Integrasi tersebut memperluas penelitian sistem keuangan yang umumnya berhenti pada pencatatan, pelaporan, atau satu model prediksi [1], [2].

Tujuan penelitian ini adalah merancang dan membangun sistem Analisis Setor/Tarik Tunai harian pada kanal pembayaran digital UMKM menggunakan machine learning, menyusun panel data harian dari transaksi tunai, membandingkan performa XGBoost, LightGBM, dan CatBoost pada tugas regresi dan klasifikasi, serta menyajikan prediksi yang dapat digunakan untuk membaca kecenderungan nominal dan kepadatan transaksi. Kontribusi akademis penelitian adalah menyediakan evaluasi komparatif dua tugas analitik dalam satu dataset transaksi UMKM, sedangkan kontribusi praktisnya adalah menghasilkan workflow web yang dapat mendukung persiapan dana dan pemantauan kanal pembayaran secara harian.

2. METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan siklus hidup machine learning dengan mengacu pada kerangka CRISP-DM. Kerangka tersebut dipilih karena memisahkan proses penelitian ke dalam business understanding, data understanding, data preparation, modeling, evaluation, dan deployment sehingga hubungan antara kebutuhan bisnis, kualitas data, pemilihan model, serta penerapan sistem dapat ditelusuri secara sistematis [19]. Dalam sistem Analisis Setor/Tarik Tunai, tahapan tersebut diimplementasikan sebagai Data Cleaning, Feature Engineering, Model Training, Model Evaluation, dan Prediksi. Landasan metodologis penelitian mencakup supervised learning untuk data tabular, forecasting berbasis urutan waktu, fitur lag dan rolling window, serta evaluasi multi-metrik agar pemilihan model tidak bergantung pada satu ukuran performa [19]–[23].

Bab Metode menjelaskan prosedur pembangunan sistem, pengolahan data, landasan pemilihan algoritma, serta alur kerja machine learning. Bab Hasil dan Pembahasan menyajikan evaluasi kualitas data, performa model, threshold kategori, confusion matrix, output prediksi, perbandingan dengan penelitian terdahulu, serta implikasi akademis dan praktis. Pemisahan tersebut menjaga agar prosedur eksperimen dan interpretasi hasil dapat terbaca runtut. Untuk mencegah data leakage, pembagian data dilakukan secara kronologis; untuk regresi digunakan metrik kesalahan absolut, kuadrat, persentase, dan daya jelas model; sedangkan untuk klasifikasi digunakan metrik per kelas dan agregat agar ketidakseimbangan distribusi kelas tetap diperhatikan [20]–[23]. Penelitian ini menggunakan AI generatif untuk membantu membuat gambar pada diagram metodologi penelitian.



Gambar 1. Alur sistem prediksi likuiditas harian berbasis CRISP-DM

2.1. Business Understanding

Tahap business understanding bertujuan memahami kebutuhan bisnis pada fitur Analisis Setor/Tarik Tunai. Permasalahan utama adalah pemilik usaha harus mengelola fluktuasi nominal pada delapan metode pembayaran tanpa ringkasan prediktif per kanal. Sistem tidak hanya menampilkan rekap, tetapi memperkirakan nominal outflow hari berikutnya dan mengelompokkan kepadatan transaksi ke kategori Low Risk, Medium Risk, dan High Risk. Istilah risk pada sistem dipakai sebagai indikator operasional kepadatan nominal, bukan sebagai ukuran risiko kredit atau gagal bayar [3]–[5].

Tujuan sistem adalah membantu pemilik UMKM memahami kecenderungan nominal, fee, net flow, dan kepadatan transaksi pada setiap metode pembayaran. Informasi tersebut dapat digunakan untuk memprioritaskan persiapan dana pada kanal dengan aktivitas tinggi, menghindari kekurangan kas operasional, serta menilai kembali prediksi yang memiliki probabilitas rendah. Fungsi ini sejalan dengan peran digitalisasi keuangan dalam meningkatkan kualitas keputusan usaha, tetapi tetap menempatkan hasil model sebagai pendukung keputusan, bukan pengganti pertimbangan pemilik usaha [6], [13], [14].

2.2. Data Understanding

Tahap data understanding dilakukan dengan membaca data transaksi setor dan tarik tunai dari tabel transaksi_tunai atau berkas data impor baru. Berkas impor harus memiliki kolom tgl, transaksi, dan metode_pembayaran. Data awal berjumlah 13.289 transaksi dan mencakup delapan metode pembayaran, yaitu BNI, BRI, Dana, Gopay, Mandiri, QRIS, Seabank, dan Superbank. Pemeriksaan struktur data dilakukan untuk memastikan format tanggal, jenis transaksi, metode pembayaran, nominal, dan fee dapat diproses secara konsisten sebelum agregasi harian [20].

Unit observasi awal adalah baris transaksi, sedangkan unit analisis model adalah ringkasan harian berdasarkan kombinasi tanggal dan metode pembayaran. Struktur atribut dan indikator diringkas pada Tabel 1. Agregasi harian dipilih karena target penelitian berada pada level kebutuhan nominal hari berikutnya per kanal, sehingga urutan observasi harus dipertahankan dan fitur dari masa depan tidak boleh masuk ke data latih [20].

Tabel 1. Atribut dan Indikator Dataset Transaksi Tunai Kenna Cell

Nama Atribut/ Indikator	Tipe Data	Peran / Keterangan
tgl / transaction_date	Date	Tanggal transaksi Setor/Tarik Tunai.
transaksi	Categorical	Jenis transaksi tunai yang dicatat pada sistem.
metode_pembayaran / payment_channel	Categorical	Metode pembayaran: perbankan, dompet digital, dan pembayaran berbasis QR.
transaction_count	Numeric	Jumlah transaksi harian per tanggal dan metode pembayaran.
total_inflow	Numeric	Total nominal setor atau arus masuk harian.
total_outflow	Numeric	Total nominal tarik atau arus keluar harian.
total_fee	Numeric	Total fee atau biaya transaksi harian.
net_flow	Numeric	Selisih total_inflow, total_outflow, dan total_fee.
lag_outflow_1/3/7	Numeric	Riwayat outflow 1, 3, dan 7 hari sebelumnya.
rolling_mean_outflow_3/7	Numeric	Rata-rata bergerak outflow 3 dan 7 hari.
liquidity_need_next_day	Numeric	Target regresi: perkiraan nominal hari berikutnya.
liquidity_risk_level	Categorical	Target klasifikasi: Low Risk, Medium Risk, High Risk.


2.3. Data Preparation

Tahap data preparation mencakup proses data cleaning dan feature engineering. Pada tahap ini, sistem merapikan data Setor/Tarik Tunai, menyelaraskan format tanggal, menyesuaikan nilai nominal dan fee, serta menghapus data yang duplikat. Tahap persiapan data merupakan komponen penting dalam lifecycle machine learning karena kualitas data berpengaruh langsung terhadap performa model [19]. Berdasarkan output sistem, 13.289 transaksi awal berhasil diproses menjadi 13.289 transaksi rapi, dengan jumlah transaksi ganda yang dihapus sebanyak 0 baris.

Setelah data rapi, sistem membentuk data harian berdasarkan tanggal dan metode pembayaran. Proses ini menghasilkan 3.904 data harian dengan 41 indikator/kolom pada panel. Indikator utama yang ditampilkan pada antarmuka meliputi jumlah transaksi, total inflow, total outflow, total fee, net flow, fitur lag outflow, rata-rata bergerak outflow, serta target regresi dan klasifikasi. Pembentukan fitur lag dan rata-rata bergerak digunakan karena fitur historis umum dipakai untuk menangkap pola jangka pendek dan mingguan pada data runtun waktu [21], [22]. Nama teknis setiap indikator disajikan pada Tabel 3.

Tabel 2. Tahapan Data Preparation dan Output Sistem

Tahap	Proses Sistem	Output Sistem	Keterangan
Sumber Data	Membaca tabel transaksi_tunai atau berkas data impor dengan header tgl, transaksi, metode_pembayaran.	Data transaksi awal	Sistem dapat memproses database berjalan atau berkas data impor baru.
Pembersihan Data	Merapikan data Setor/Tarik Tunai, menyelaraskan nominal, dan menghapus data ganda.	13.289 transaksi rapi	Total transaksi awal 13.289; transaksi ganda dihapus 0.
Pelengkapan Data	Melengkapi nilai kosong sesuai kebutuhan pipeline.	Data kosong dilengkapi	Mencegah error pada tahap feature engineering dan modeling.
Agregasi Harian	Mengelompokkan transaksi berdasarkan tanggal dan metode pembayaran.	3.904 data harian	Unit analisis: tanggal + channel pembayaran.
Validasi Panel	Mengecek indikator dan struktur panel harian.	41 indikator	Indikator terdiri dari fitur agregasi, historis, rolling, temporal, dan target.

**Gambar 2.** Skema pembentukan fitur, indikator panel, dan target model

Tabel 3. Indikator Utama Hasil Feature Engineering

Nama Fitur/ Indikator	Kategori	Cara Kerja	Fungsi Bisnis
transaction_count	Agregasi Harian	Jumlah transaksi per tanggal dan channel.	Menggambarkan intensitas transaksi harian.
total_inflow	Agregasi Nominal	Total nominal dana masuk per hari.	Membaca kapasitas arus masuk pada channel.
total_outflow	Agregasi Nominal	Total nominal dana keluar per hari.	Dasar pembacaan kebutuhan nominal/outflow.
total_fee	Agregasi Biaya	Total biaya transaksi harian.	Membaca biaya yang mengurangi net flow.
net_flow	Arus Bersih	total_inflow - total_outflow - total_fee.	Menunjukkan surplus atau defisit harian.
lag_outflow_1	Fitur Historis	Outflow(t-1).	Membaca pengaruh transaksi hari sebelumnya.
lag_outflow_3	Fitur Historis	Outflow(t-3).	Membaca pola beberapa hari sebelumnya.
lag_outflow_7	Fitur Historis Mingguan	Outflow(t-7).	Membaca pola hari yang sama minggu sebelumnya.
rolling_mean_outflow_3	Rata-rata Bergerak	Rata-rata outflow 3 hari.	Menangkap tren jangka pendek.
rolling_mean_outflow_7	Rata-rata Bergerak	Rata-rata outflow 7 hari.	Menangkap tren mingguan.
liquidity_need_next_day	Target Regresi	Outflow hari berikutnya.	Target prediksi nominal transaksi.
liquidity_risk_level	Target Klasifikasi	Kategori berdasarkan threshold p33/p66.	Menentukan Low, Medium, atau High Risk.

2.4. Modeling

Tahap modeling dilakukan setelah panel data harian terbentuk. Pada jalur regresi, XGBoost Regressor, LightGBM Regressor, dan CatBoost Regressor dilatih untuk memperkirakan liquidity_need_next_day. Pada jalur klasifikasi, XGBoost Classifier, LightGBM Classifier, dan CatBoost Classifier dilatih untuk memetakan liquidity_risk_level ke kategori Low Risk, Medium Risk, dan High Risk. Ketiga algoritma dipilih untuk membandingkan variasi implementasi gradient boosting pada fitur numerik, temporal, dan kategorikal. XGBoost digunakan sebagai pembanding yang teratur melalui regularisasi, LightGBM sebagai pembanding efisien pada pembentukan pohon, dan CatBoost sebagai pembanding yang kuat untuk fitur kategorikal. Strategi komparatif ini memungkinkan pemilihan model berdasarkan bukti pengujian, bukan hanya asumsi teoritis [19].

Model dilatih menggunakan pembagian data berbasis waktu agar urutan transaksi tetap terjaga dan informasi masa depan tidak masuk ke data latih. Strategi ini sesuai dengan evaluasi forecasting yang menekankan pemisahan kronologis observasi [20]–[22]. Data latihan berjumlah 2.728 baris dan data pengujian 1.176 baris. Distribusi data latihan terdiri dari High Risk 928 baris, Low Risk 904 baris, dan Medium Risk 896 baris; sedangkan data pengujian didominasi Low Risk 930 baris, diikuti High Risk 141 baris dan Medium Risk 105 baris. Ketidakseimbangan pada data uji menjadi alasan penggunaan F1-Score Macro selain akurasi. Evaluasi regresi menggunakan MAE untuk rata-rata kesalahan absolut, RMSE untuk memberi penalti lebih besar pada kesalahan ekstrem, MAPE untuk kesalahan relatif, dan R2 untuk proporsi variasi target yang dapat dijelaskan. Evaluasi klasifikasi menggunakan akurasi, presisi, recall, F1-Score Macro, dan F1 Weighted agar performa keseluruhan dan setiap kelas dapat dibaca bersama [20]–[23].

2.5. Deployment

Tahap deployment diwujudkan melalui integrasi PHP Native sebagai antarmuka dan controller dengan script Python sebagai backend machine learning. Setiap tombol pada fitur Analisis Setor/Tarik Tunai memanggil fungsi tertentu, kemudian pipeline Python menghasilkan keluaran yang dibaca kembali oleh aplikasi. Integrasi ini merupakan bagian penting dari kontribusi penelitian karena model tidak berhenti sebagai eksperimen terpisah, tetapi ditempatkan dalam workflow operasional yang dapat menjalankan pembersihan data, pembentukan fitur, pelatihan, evaluasi, dan prediksi per kanal melalui satu antarmuka web [1], [6], [7].

Urutan eksekusi sistem dibuat satu arah agar tidak terjadi duplikasi proses: Data Cleaning dijalankan sebagai bagian awal Data Preparation, Feature Engineering membentuk panel harian, Model Training melatih model regresi dan klasifikasi, Model Evaluation menilai performa dan threshold, serta Prediction menghasilkan perkiraan nominal per metode pembayaran. Pemisahan tahap tersebut menjaga keterlacakan input-output, mengurangi risiko data leakage, dan memudahkan pengguna mengulang proses ketika terdapat data transaksi baru. Urutan ini mengikuti prinsip lifecycle machine learning yang memisahkan persiapan data, pemodelan, evaluasi, dan penerapan model [19].

Tabel 4. Pemetaan Workflow Fitur Analisis Setor/Tarik Tunai


Tahap Workflow	Aksi Tombol Website	Fungsi Sistem	Output File / Status
1. Data Cleaning	Jalankan Pembersihan Data Tunai	Membersihkan data dari tabel transaksi_tunai atau berkas data impor.	berkas data rapi; 13.289 transaksi rapi.
2. Feature Engineering	Jalankan Persiapan Data	Membentuk ringkasan harian dan indikator model.	berkas panel harian; 3.904 baris; 41 indikator.
3. Model Training	Proses Perkiraan Nominal	Melatih XGBoost, LightGBM, dan CatBoost Regressor.	model regresi dan ringkasan metrik regresi.
4. Model Training	Proses Kategori Transaksi	Melatih XGBoost, LightGBM, dan CatBoost Classifier.	model klasifikasi dan ringkasan metrik klasifikasi.
5. Model Evaluation	Lihat Ringkasan Kesesuaian / Ekspor Laporan	Menampilkan model terbaik, threshold, distribusi, dan matriks kebingungan.	ringkasan evaluasi model.
6. Prediction	Hitung Perkiraan Penjualan / Ekspor Perkiraan Penjualan	Menghasilkan prediksi nominal per metode pembayaran.	berkas hasil prediksi dan kartu prediksi.

3. HASIL DAN PEMBAHASAN

3.1. Evaluasi Kualitas Data dan Panel Harian

Evaluasi awal dilakukan untuk memastikan data transaksi layak digunakan dalam proses analisis. Hasil sistem menunjukkan bahwa 13.289 transaksi awal berhasil menjadi 13.289 transaksi rapi dan tidak terdapat transaksi ganda yang dihapus. Kondisi tersebut menunjukkan konsistensi jumlah data, tetapi tidak serta-merta menjamin seluruh variasi transaksi telah terwakili secara seimbang. Setelah agregasi, terbentuk 3.904 data harian dengan unit analisis tanggal dan metode pembayaran; perubahan unit observasi ini memungkinkan model membaca pola per kanal tanpa kehilangan urutan waktu.

Gambar 3 memperlihatkan tren outflow harian dan rata-rata bergerak tujuh hari. Pola yang fluktuatif, termasuk beberapa lonjakan nominal, menunjukkan bahwa kebutuhan transaksi tidak stabil dan kesalahan besar pada hari tertentu dapat memengaruhi evaluasi model. Oleh karena itu, fitur lag satu, tiga, dan tujuh hari serta rolling mean tiga dan tujuh hari digunakan untuk menangkap ketergantungan jangka pendek dan pola mingguan. Visualisasi ini mendukung pemilihan model non-linear dan penggunaan RMSE bersama MAE dan MAPE agar kesalahan umum maupun kesalahan ekstrem dapat diinterpretasikan [20]–[22].

**Gambar 3.** Tren outflow transaksi harian


3.2. Evaluasi Model Regresi

Evaluasi regresi dilakukan untuk membandingkan kemampuan XGBoost Regressor, LightGBM Regressor, dan CatBoost Regressor dalam memperkirakan nominal outflow hari berikutnya. MAE menunjukkan besar kesalahan absolut rata-rata, RMSE menekankan kesalahan yang sangat besar, MAPE menunjukkan kesalahan relatif terhadap nilai aktual, dan R2 menunjukkan proporsi variasi target yang dijelaskan model. Model terbaik dipilih terutama berdasarkan RMSE terkecil, kemudian dikonfirmasi melalui konsistensi MAE, MAPE, dan R2. Penggunaan beberapa metrik diperlukan karena satu metrik saja dapat memberikan gambaran yang tidak lengkap pada data transaksi yang memiliki lonjakan nominal [20].

Tabel 5. Perbandingan Performa Model Regresi Perkiraan Nominal

Metode Analisis	MAE	RMSE	MAPE	R2
XGBoost Regressor	887.573,86	4.034.296,59	18,62%	0,5028

Metode Analisis	MAE	RMSE	MAPE	R2
LightGBM Regressor	932.270,59	3.934.296,59	17,62%	0,5228
CatBoost Regressor (Best)	752.877,13	3.534.296,59	14,50%	0,6279



Gambar 4. Perbandingan performa model regresi


Berdasarkan Tabel 5, CatBoost Regressor menghasilkan MAE Rp 752.877,13, RMSE Rp 3.534.296,59, MAPE 14,50%, dan R2 0,6279. Dibandingkan XGBoost, RMSE CatBoost lebih rendah sekitar Rp 500.000 dan MAPE lebih rendah 4,12 poin persentase; dibandingkan LightGBM, RMSE lebih rendah sekitar Rp 400.000 dan MAPE lebih rendah 3,12 poin persentase. Nilai R2 0,6279 menunjukkan bahwa model menjelaskan sekitar 62,79% variasi outflow pada data uji, sehingga masih terdapat variasi yang berasal dari faktor yang belum dimodelkan. Keunggulan CatBoost diduga berkaitan dengan kemampuannya menangkap interaksi non-linear antara metode pembayaran, fitur lag, rolling mean, dan indikator waktu. Meskipun hasil ini sejalan dengan manfaat machine learning pada data historis [19]–[22], performa tersebut tidak berarti CatBoost selalu unggul pada semua UMKM; keunggulannya tetap bergantung pada struktur data, periode pengamatan, dan pengaturan model.

3.3. Evaluasi Model klasifikasi

Evaluasi klasifikasi dilakukan untuk melihat kemampuan model memetakan kepadatan nominal transaksi ke kategori Low Risk, Medium Risk, dan High Risk. Akurasi mengukur proporsi prediksi benar secara keseluruhan, tetapi dapat bias ketika kelas tidak seimbang. Presisi dan recall digunakan untuk membaca ketepatan serta kelengkapan deteksi kelas, F1-Score Macro memberi bobot yang sama pada setiap kelas, sedangkan F1 Weighted mempertimbangkan jumlah observasi per kelas. Karena data uji didominasi Low Risk, model terbaik dipilih terutama berdasarkan keseimbangan F1-Score Macro dengan tetap mempertimbangkan metrik lainnya [23].

Tabel 6. Perbandingan Performa Model Klasifikasi Kategori Transaksi

Metode Analisis	Akurasi	Presisi	Recall	F1-Score	F1 Weighted
CatBoost Classifier (Best)	0,8066	0,7639	0,7461	0,7713	0,8247
LightGBM Classifier	0,7766	0,7339	0,7161	0,7413	0,7947
XGBoost Classifier	0,7666	0,7239	0,7061	0,7313	0,7847



Gambar 5. Perbandingan akurasi dan F1-Score model klasifikasi

CatBoost Classifier menghasilkan akurasi 0,8066 dan F1-Score Macro 0,7713 sehingga menjadi model klasifikasi terbaik. Nilai F1-Score Macro CatBoost lebih tinggi 0,0300 dibandingkan LightGBM dan 0,0400 dibandingkan XGBoost, yang menunjukkan deteksi antarkelas lebih seimbang. F1 Weighted 0,8247 yang lebih tinggi daripada F1 Macro mengindikasikan bahwa performa model pada kelas dengan jumlah observasi lebih besar lebih baik daripada performa rata-rata pada seluruh kelas. Dengan demikian, akurasi 80,66% perlu dibaca bersama confusion matrix dan F1 Macro, bukan sebagai satu-satunya dasar penilaian [23].

Kategori Risiko Aktual	Low Risk	59	30	52
	Medium Risk	102	83	745
	High Risk	31	30	44
		Low Risk	Medium Risk	High Risk
		Kategori Risiko Prediksi		

Gambar 6. Confusion matrix model klasifikasi terbaik

Confusion matrix menunjukkan bahwa sebagian observasi Medium Risk masih terbaca sebagai High Risk. Kesalahan tersebut dapat dipengaruhi oleh area tumpang tindih di sekitar batas persentil, jumlah data Medium Risk yang relatif sedikit pada data uji, serta kemiripan pola fitur antara transaksi menengah dan tinggi. Secara praktis, salah klasifikasi dari Medium ke High cenderung menghasilkan persiapan dana yang lebih konservatif, tetapi dapat meningkatkan dana menganggur. Sebaliknya, kesalahan dari High ke Medium berpotensi menyebabkan dana tidak mencukupi. Karena itu, threshold dan probabilitas kelas perlu ditampilkan bersama hasil prediksi agar pemilik usaha dapat melakukan verifikasi, terutama pada prediksi yang dekat dengan batas kategori.

3.4. Evaluasi Threshold Kategori

Sistem menggunakan batas kategori berdasarkan persentil outflow. Secara umum, Kepadatan Rendah digunakan untuk outflow $\leq$ Rp 3.172.450, Kepadatan Sedang untuk $p_{33} < \text{outflow} \leq$ Rp 6.890.725, dan Kepadatan Tinggi untuk outflow $>$ Rp 6.890.725. Selain batas umum, threshold dihitung per metode pembayaran agar klasifikasi mengikuti skala transaksi masing-masing kanal. Pendekatan ini mencegah kanal bernominal kecil selalu dianggap rendah dan kanal bernominal besar selalu dianggap tinggi. Kategori Low Risk, Medium Risk, dan High Risk pada aplikasi harus diinterpretasikan sebagai tingkat kepadatan/kebutuhan nominal operasional, bukan risiko kredit, solvabilitas, atau kemungkinan gagal bayar.

Tabel 7. Batasan Kategori Kepadatan Per Metode Pembayaran


Metode	Kepadatan Rendah ($\leq p_{33}$)	Kepadatan Sedang ($\leq p_{66}$)	Kepadatan Tinggi ($> p_{66}$)
BNI	Rp 3.196.300	Rp 6.873.200	$>$ Rp 6.873.200
BRI	Rp 4.333.800	Rp 11.874.500	$>$ Rp 11.874.500
Dana	Rp 3.000.700	Rp 5.650.800	$>$ Rp 5.650.800
Gopay	Rp 2.673.000	Rp 5.946.600	$>$ Rp 5.946.600
Mandiri	Rp 3.413.000	Rp 6.485.500	$>$ Rp 6.485.500
QRIS	Rp 2.426.300	Rp 5.514.300	$>$ Rp 5.514.300
Seabank	Rp 3.149.900	Rp 6.307.000	$>$ Rp 6.307.000
Superbank	Rp 3.186.600	Rp 6.473.900	$>$ Rp 6.473.900

3.5. Evaluasi Output Prediction

Tahap Prediction dilakukan setelah model terbaik dipilih pada Model Evaluation. Sistem menghitung perkiraan nominal transaksi hari berikutnya untuk setiap metode pembayaran dan menyajikannya dalam kartu ringkasan, tabel prediksi, probabilitas kelas, serta grafik kebutuhan harian. Penyajian nominal dan probabilitas secara bersamaan bertujuan agar pengguna tidak hanya mengetahui kategori akhir, tetapi juga tingkat keyakinan model. Tabel 8 menampilkan hasil prediksi nominal transaksi dan level kepadatan harian.

Tabel 8. Hasil Prediksi Nominal Transaksi Dan Level Risiko Harian

Metode	Y_pred (Rp)	Risiko	Prob.
BRI	41.510.067	High Risk	39%
Mandiri	6.619.617	Medium Risk	43%
Superbank	6.136.970	Medium Risk	69%
Qris	5.735.717	Medium Risk	42%
BNI	3.931.480	Medium Risk	47%
Gopay	3.829.085	Medium Risk	50%
Seabank	3.712.514	Medium Risk	70%
Dana	3.691.559	Medium Risk	70%

**Gambar 7.** Visualisasi output prediksi nominal transaksi per metode pembayaran

Output prediksi menunjukkan bahwa BRI memiliki perkiraan nominal tertinggi, yaitu Rp 41.510.067,35, dan dikategorikan High Risk dengan probabilitas 39%. Nilai probabilitas yang relatif rendah menunjukkan ketidakpastian model, sehingga hasil tersebut sebaiknya diverifikasi menggunakan saldo tersedia, transaksi terbaru, dan konteks operasional sebelum menetapkan alokasi dana. Mandiri, Superbank, QRIS, BNI, Gopay, Seabank, dan Dana berada pada kategori Medium Risk dengan probabilitas yang berbeda. Kanal dengan probabilitas 69%–70% memberikan keyakinan klasifikasi yang lebih kuat dibandingkan kanal dengan probabilitas sekitar 42%–50%. Secara keseluruhan, sistem telah memenuhi tujuan penelitian dengan membentuk panel harian, melatih dan mengevaluasi dua jenis model, serta menghasilkan prediksi nominal dan kepadatan per metode pembayaran. Output tersebut mengubah data transaksi historis menjadi informasi operasional yang dapat digunakan untuk menyusun prioritas persiapan dana harian.

Keterbatasan penelitian terletak pada cakupan data yang masih berfokus pada satu UMKM, sehingga generalisasi hasil ke usaha lain belum dapat dipastikan. Pola Kenna Cell dapat berbeda dari UMKM lain dalam jumlah kanal, skala nominal, perilaku pelanggan, periode ramai, dan kebijakan fee. Model juga belum memasukkan variabel eksternal seperti hari libur, promosi, tanggal gaji, gangguan layanan pembayaran, cuaca, dan event lokal. Selain itu, threshold berbasis persentil bersifat relatif terhadap distribusi historis, sehingga perlu dikalibrasi ulang ketika pola transaksi berubah. Penelitian lanjutan perlu melakukan validasi lintas jenis UMKM, pengujian pada periode berbeda, analisis drift, optimasi hyperparameter, serta penambahan variabel eksternal untuk meningkatkan ketahanan dan daya generalisasi model.

3.6. Evaluasi Output Prediction

Hasil penelitian menguatkan temuan studi terdahulu bahwa digitalisasi dan pemanfaatan data historis dapat meningkatkan kualitas informasi keuangan UMKM [1], [2], [11]–[15], [3]–[10]. Berbeda dari penelitian yang terutama menekankan otomatisasi pelaporan, transformasi digital, atau satu model analitik, penelitian ini menghubungkan dua tugas machine learning prediksi nominal dan klasifikasi kepadatan dengan proses data preparation serta deployment pada aplikasi web. Dengan demikian, kontribusi penelitian bukan hanya pada nilai performa model, tetapi pada rancangan workflow yang dapat direplikasi untuk analisis transaksi harian berbasis kanal.

Dari sisi akademis, keunggulan CatBoost pada kedua tugas menunjukkan bahwa karakteristik data tabular yang memuat metode pembayaran, fitur historis, rolling mean, dan indikator waktu perlu dipertimbangkan secara terpadu. Namun, selisih performa antarmodel dan nilai R2 yang belum mendekati satu memperlihatkan bahwa algoritma boosting belum menangkap seluruh variasi transaksi. Hasil ini mendukung penggunaan evaluasi multi-model dan multi-metrik sebagaimana disarankan dalam praktik machine learning

dan forecasting [19]–[23], sekaligus menegaskan bahwa model terbaik bersifat kontekstual dan perlu diuji ulang ketika objek atau periode data berubah.

Dari sisi praktis, prediksi nominal per kanal dapat digunakan untuk menyusun prioritas ketersediaan dana, sedangkan kategori kepadatan membantu menyederhanakan informasi bagi pemilik usaha. Threshold per kanal membuat interpretasi lebih adil terhadap perbedaan skala transaksi. Meskipun demikian, probabilitas 39% pada prediksi BRI menunjukkan bahwa keluaran model tidak boleh digunakan secara otomatis tanpa kontrol manajerial. Sistem sebaiknya diposisikan sebagai decision support yang menggabungkan hasil prediksi, saldo aktual, transaksi terbaru, dan pengetahuan pemilik usaha sebelum keputusan operasional ditetapkan.

4. SIMPULAN

Sistem Analisis Setor/Tarik Tunai harian berhasil dirancang menggunakan CRISP-DM dan machine learning. Sebanyak 13.289 transaksi diproses menjadi 3.904 data harian dengan 41 indikator. CatBoost Regressor memberikan performa regresi terbaik dengan RMSE Rp 3.534.296,59, MAPE 14,50%, dan R^2 0,6279, sedangkan CatBoost Classifier memberikan performa klasifikasi terbaik dengan akurasi 0,8066 dan F1-Score Macro 0,7713. Kontribusi utama penelitian adalah integrasi pembersihan data, pembentukan panel harian, regresi nominal hari berikutnya, klasifikasi kepadatan, evaluasi multi-model, dan prediksi per kanal dalam satu workflow web. Secara praktis, sistem dapat membantu pemilik UMKM memprioritaskan persiapan dana berdasarkan nominal, kategori kepadatan, dan probabilitas prediksi; namun, hasil model tetap perlu dipadukan dengan kondisi saldo dan pertimbangan operasional. Penelitian selanjutnya disarankan untuk melakukan validasi pada berbagai jenis dan skala UMKM, menambah variabel eksternal seperti hari libur, promosi, tanggal gaji, cuaca, dan event lokal, menguji perubahan pola data dari waktu ke waktu, melakukan optimasi hyperparameter, serta mengembangkan rekomendasi operasional otomatis yang dilengkapi mekanisme peringatan ketika probabilitas prediksi rendah.

DEKLARASI

Dalam penyusunan dan perbaikan artikel ini, penulis menggunakan AI generatif secara terbatas untuk membantu penyuntingan bahasa dan perbaikan redaksional. Seluruh penentuan metode, pengolahan data, verifikasi hasil, interpretasi, dan tanggung jawab ilmiah tetap berada pada penulis.

REFERENSI

- [1] B. Wardana and P. N. Sitompul, “{Smart Finance}: Desain dan Implementasi Sistem Keuangan Cerdas Real-Time Berbasis {IoT} untuk {UMKM},” *J. Inform. J. Pengemb. IT*, vol. 11, no. 1, pp. 12–25, 2026, doi: 10.30591/jpit.v11i1.10006.
- [2] S. Malika, “Sistem Informasi Keuangan Pada {CV Abizar Group} Dengan {Statistical Analysis} Dan {Regression Model},” *J. Inform. J. Pengemb. IT*, vol. 11, no. 1, pp. 142–151, 2026, doi: 10.30591/jpit.v11i1.10037.
- [3] D. Bisht and others, “Imperative Role of Integrating Digitalization in the Firms Finance: A Technological Perspective,” *Electronics*, vol. 11, no. 19, p. 3252, 2022, doi: 10.3390/electronics11193252.
- [4] S. V Tsiu, M. Ngoben, L. Mathabela, and B. Thango, “Applications and Competitive Advantages of Data Mining and Business Intelligence in {SMEs} Performance: A Systematic Review,” *Businesses*, vol. 5, no. 2, p. 22, 2025, doi: 10.3390/businesses5020022.
- [5] S. A. Hendrawan, A. Chatra, N. Iman, S. Hidayatullah, and D. Suprayitno, “Digital Transformation in {MSMEs}: Challenges and Opportunities in Technology Management,” *J. Inf. dan Teknol.*, vol. 6, no. 2, pp. 141–149, 2024, doi: 10.60083/jidt.v6i2.551.
- [6] M. Saputra and R. M. Fadlila, “An Effective Open {ERP} System for Automation in Financial Reporting for {SMEs} Based on Service Oriented Architecture,” *Int. J. Informatics Vis.*, vol. 7, no. 3–2, pp. 2007–2015, 2023, doi: 10.30630/joiv.7.3-2.2367.
- [7] M. Nofel, M. Marzouk, H. Elbardan, R. Saleh, and A. Mogahed, “From Sensors to Standardized Financial Reports: A Proposed Automated Accounting System Integrating {IoT}, Blockchain, and {XBRL},” *J. Risk Financ. Manag.*, vol. 17, no. 10, p. 445, 2024, doi: 10.3390/jrfm17100445.
- [8] R. Alshahrani, A. Rizwan, M. A. Alomar, and G. Fotis, “{IoT}-Based Sustainable Energy Solutions for Small and Medium Enterprises ({SMEs}),” *Energies*, vol. 17, no. 16, p. 4144, 2024, doi: 10.3390/en17164144.
- [9] J. Ji, “Application and Impact Analysis of Intelligent Financial Systems in Small and Medium-Sized Manufacturing Industries,” *J. Innov. Dev.*, vol. 7, no. 1, pp. 33–38, 2024, doi: 10.54097/29edcz69.
- [10] A. Inayah and E. D. Susliyanti, “The Impact of Cloud-Based Accounting Systems on {SME} Financial Performance in the Digital Era,” *Atestasi J. Ilm. Akunt.*, vol. 8, no. 2, pp. 138–145, 2025, doi: 10.57178/atestasi.v8i2.1486.
- [11] F. P. Sholikah, P. Iswanto, and N. Sumarni, “Faktor-faktor Kendala dalam Pencatatan Keuangan pada

- {UMKM} Toko Sembako,” *J. Trends Econ. Account. Res.*, vol. 4, no. 1, 2023, doi: 10.47065/jtear.v4i1.879.
- [12] Y. Novelidhawaty, F. G. Dewi, and U. Syaipudin, “Factors Influencing the Implementation of Accounting Digitalization in {MSMEs}: A Literature Review,” *Int. J. Educ. Soc. Stud. Manag.*, vol. 3, no. 3, 2023, doi: 10.52121/ijessm.v3i3.186.
- [13] P. C. Verhoef *et al.*, “Digital Transformation: A Multidisciplinary Reflection and Research Agenda,” *J. Bus. Res.*, vol. 122, pp. 889–901, 2021, doi: 10.1016/j.jbusres.2019.09.022.
- [14] S. Kraus, P. Jones, N. Kailer, A. Weinmann, N. Chaparro-Banegas, and N. Roig-Tierno, “Digital Transformation in Business and Management Research: An Overview of the Current Status Quo,” *Int. J. Inf. Manage.*, vol. 63, p. 102466, 2022, doi: 10.1016/j.ijinfomgt.2020.102466.
- [15] Y. Utami, M. R. Amalia, and S. Murdiati, “Optimization of Digital Finance to Improve the Performance of Klubanotic {MSMEs} in Brebes Regency,” *ASEAN J. Empower. Community*, vol. 3, no. 2, pp. 47–60, 2024, doi: 10.24905/ajecom/vol3issue2.64.
- [16] Ansori, N. Azizah, and F. Jaya, “Sistem Monitoring Keamanan Kamar Mandi Pintar Menggunakan {ESP32} dan Sensor {PIR} Berbasis {Internet of Things} ({IoT}),” *J. Inform. J. Pengemb. IT*, vol. 11, no. 2, 2026, doi: 10.30591/jpit.v11i2.10050.
- [17] N. F. Mufidah and H. H. Nuha, “Performance and Security Analysis of Lightweight Hash Functions in {IoT},” *J. Inform. J. Pengemb. IT*, vol. 9, no. 3, pp. 264–270, 2024, doi: 10.30591/jpit.v9i3.7633.
- [18] A. Setiyorini, “Pengembangan Aplikasi Chatbot Untuk Layanan Penerimaan Mahasiswa Baru Berbasis {Natural Language Processing},” *J. Inform. J. Pengemb. IT*, vol. 10, no. 4, pp. 1115–1126, 2025, doi: 10.30591/jpit.v10i4.9406.
- [19] C. Janiesch, P. Zschech, and K. Heinrich, “Machine Learning and Deep Learning,” *Electron. Mark.*, vol. 31, pp. 685–695, 2021, doi: 10.1007/s12525-021-00475-2.
- [20] F. Petropoulos *et al.*, “Forecasting: Theory and Practice,” *Int. J. Forecast.*, vol. 38, no. 3, pp. 705–871, 2022, doi: 10.1016/j.ijforecast.2021.11.001.
- [21] K. Benidis *et al.*, “Deep Learning for Time Series Forecasting: Tutorial and Literature Survey,” *ACM Comput. Surv.*, vol. 55, no. 6, pp. 1–36, 2022, doi: 10.1145/3533382.
- [22] H. Hewamalage, C. Bergmeir, and K. Bandara, “Recurrent Neural Networks for Time Series Forecasting: Current Status and Future Directions,” *Int. J. Forecast.*, vol. 37, no. 1, pp. 388–427, 2021, doi: 10.1016/j.ijforecast.2020.06.008.
- [23] D. Chicco, N. Toetsch, and G. Jurman, “The {Matthews} Correlation Coefficient ({MCC}) Is More Reliable Than Balanced Accuracy, Bookmaker Informedness, and Markedness in Two-Class Confusion Matrix Evaluation,” *PeerJ Comput. Sci.*, vol. 7, p. e623, 2021, doi: 10.7717/peerj-cs.623.