



## Analisis Prediktif Arus Kas Bersih Perusahaan *Multifinance* Menggunakan *Machine Learning Linear Regression*

Amalia<sup>1\*</sup>, Lulu Aprilia Wijayanti<sup>2</sup>, Rusmanto<sup>3</sup>

<sup>1-3</sup>Program Studi Sistem Informasi, Sekolah Tinggi Teknologi Terpadu Nurul Fikri, Indonesia

\*Penulis Korespondensi: [lulu22003si@student.nurulfikri.ac.id](mailto:lulu22003si@student.nurulfikri.ac.id)

**Abstract.** Cash flow forecasting is important because changes in cash availability can affect liquidity management, funding decisions, and operational stability. This study aims to develop and evaluate an interpretable predictive model for next-period Net Cash Flow using machine learning Linear Regression. Quarterly panel data were collected from 11 multifinance issuers listed on the Indonesia Stock Exchange during 2021–2025. The predictors include Operating Cash Flow, Investing Cash Flow, Financing Cash Flow, and company identity, while the target is next-period Net Cash Flow. Microsoft Excel was used for initial data preparation, checking, and verification, while Google Colab with Python, Pandas, NumPy, scikit-learn, and Matplotlib was used for data processing, modeling, evaluation, charts, and dashboard visualization. From 220 raw observations, 209 model-ready observations were obtained, consisting of 176 training and 33 testing observations. Linear Regression produced MAE of 5,175,010,760.53 and RMSE of 11,439,892,766.99, lower than naive forecasting with MAE of 7,569,470,101.77 and RMSE of 16,555,565,343.09. However, the negative testing *R-squared* indicates limited performance under heterogeneous and extreme cash-flow movements. These findings show that Linear Regression can provide a measurable and interpretable initial basis for cash flow prediction, although broader data, additional variables, and stronger models are still required.

**Keywords:** Cash Flow Forecasting; Linear Regression; Machine Learning; Multifinance; Net Cash Flow.

**Abstrak.** Prediksi arus kas penting karena perubahan ketersediaan kas dapat memengaruhi pengelolaan likuiditas, keputusan pendanaan, dan stabilitas operasional perusahaan. Penelitian ini bertujuan membangun dan mengevaluasi model prediksi arus kas bersih periode berikutnya menggunakan pendekatan *machine learning Linear Regression* yang bersifat interpretatif. Data yang digunakan berupa panel kuartalan dari 11 emiten *multifinance* yang terdaftar di Bursa Efek Indonesia selama periode 2021–2025. Variabel masukan meliputi *Operating Cash Flow*, *Investing Cash Flow*, *Financing Cash Flow*, dan identitas perusahaan, sedangkan target prediksi adalah arus kas bersih periode berikutnya. Microsoft Excel digunakan pada tahap awal untuk penyusunan, pengecekan, dan verifikasi data mentah, sedangkan Google Colab dengan Python, Pandas, NumPy, *scikit-learn*, dan Matplotlib digunakan untuk pengolahan data, pemodelan, evaluasi, grafik, dan visualisasi *dashboard*. Dari 220 observasi mentah, diperoleh 209 observasi siap model yang terdiri atas 176 data latih dan 33 data uji. Hasil penelitian menunjukkan bahwa *Linear Regression* menghasilkan MAE sebesar 5.175.010.760,53 dan RMSE sebesar 11.439.892.766,99, lebih rendah dibandingkan *naive forecasting* dengan MAE sebesar 7.569.470.101,77 dan RMSE sebesar 16.555.565.343,09. Namun, nilai *R-squared* pada data uji yang masih negatif menunjukkan bahwa performa model masih terbatas pada data heterogen dan pergerakan arus kas ekstrem. Temuan ini menegaskan bahwa *Linear Regression* dapat menjadi dasar prediksi awal yang terukur dan mudah diinterpretasikan, meskipun perluasan data, penambahan variabel, dan pengujian model yang lebih kuat tetap diperlukan.

**Kata kunci:** Arus Kas Bersih; *Linear Regression*; *Machine Learning*; *Multifinance*; Prediksi Arus Kas.

### 1. LATAR BELAKANG

Pemanfaatan analisis data dan *machine learning* dalam bidang akuntansi dan keuangan semakin berkembang karena data keuangan tidak lagi hanya digunakan untuk menggambarkan kondisi historis, tetapi juga untuk membangun prediksi kondisi keuangan masa depan. Perkembangan ini mendorong penggunaan pendekatan prediktif dalam membaca pola keuangan, termasuk arus kas, yang menjadi salah satu informasi penting dalam menilai likuiditas, aktivitas operasional, investasi, dan pendanaan perusahaan (Chakri et al., 2023; OECD, 2021). Dalam konteks tersebut, prediksi arus kas menjadi penting karena perubahan

ketersediaan kas dapat memengaruhi pengelolaan likuiditas, keputusan pendanaan, dan stabilitas operasional perusahaan (Roy et al., 2025).

Penelitian ini berfokus pada arus kas bersih atau *Net Cash Flow* karena variabel tersebut merepresentasikan hasil akhir dari seluruh arus kas masuk dan arus kas keluar dalam satu periode. Laporan arus kas secara konseptual dikelompokkan ke dalam aktivitas operasi, investasi, dan pendanaan, sehingga perubahan kas bersih perlu dibaca sebagai hasil dari keseluruhan aktivitas tersebut (IFRS Foundation, 2026). Berbeda dari *Operating Cash Flow* yang hanya menggambarkan arus kas dari aktivitas operasional, arus kas bersih mencerminkan perubahan kas yang berasal dari aktivitas operasi, investasi, dan pendanaan secara menyeluruh. Oleh karena itu, prediksi arus kas bersih periode berikutnya dapat digunakan sebagai indikator awal untuk membaca potensi tekanan likuiditas, ketidakseimbangan kas, dan kebutuhan tindakan antisipatif pada periode mendatang (Apriyanti et al., 2023; Wasalwa & Putra, 2024). Prediksi arus kas juga menjadi relevan karena ketidakstabilan kas dapat meningkatkan risiko kesulitan keuangan apabila tidak dianalisis secara sistematis (Puspitaningtyas, 2022).

Sektor *multifinance* dipilih karena memiliki peran penting dalam mendukung pembiayaan masyarakat dan aktivitas ekonomi di Indonesia. Industri perusahaan pembiayaan mengelola nilai piutang dan aset yang besar, sehingga pengelolaan arus kas menjadi aspek penting dalam menjaga keberlanjutan operasional, kemampuan pendanaan, dan stabilitas likuiditas. *Roadmap* pengembangan perusahaan pembiayaan menekankan pentingnya penguatan industri pembiayaan agar lebih sehat, kuat, berintegritas, inklusif, adaptif terhadap perkembangan teknologi, dan berkontribusi terhadap pertumbuhan ekonomi berkelanjutan (Otoritas Jasa Keuangan [OJK], 2024). Selain itu, penguatan sektor jasa keuangan juga perlu diarahkan untuk menjaga ketahanan, integritas, dan stabilitas sistem keuangan di tengah dinamika ekonomi (OJK, 2026). Dalam konteks yang lebih luas, pendalaman sektor keuangan menjadi salah satu aspek penting untuk mendukung pertumbuhan dan pemulihan ekonomi yang berkelanjutan (World Bank, 2022).

Meskipun penelitian terdahulu telah membahas prediksi arus kas, penggunaan informasi arus kas dalam mendeteksi *financial distress*, serta penerapan *machine learning* dalam analisis keuangan, kajian yang secara khusus membangun model prediksi arus kas bersih periode berikutnya pada perusahaan *multifinance* Indonesia masih terbatas. Beberapa penelitian sebelumnya lebih banyak berfokus pada prediksi *Operating Cash Flow*, *financial distress*, atau penggunaan informasi arus kas pada konteks perusahaan non-*multifinance* (Apriyani et al., 2024; Efriyenty & Purba, 2022). Kajian lain menunjukkan bahwa pendekatan regresi dan *predictive analytics* dapat digunakan untuk memprediksi luaran keuangan, tetapi penerapannya

tetap perlu disesuaikan dengan karakteristik data dan tujuan prediksi yang spesifik (Elbatal et al., 2025). Selain itu, beberapa studi telah menggunakan pendekatan *machine learning* yang lebih kompleks, seperti *neural network*, *deep learning*, atau *probabilistic forecasting*, tetapi belum secara khusus menempatkan arus kas bersih periode berikutnya sebagai target prediksi pada emiten *multifinance* Indonesia (Kotios et al., 2022; Zhu et al., 2022).

Berdasarkan kesenjangan tersebut, penelitian ini menawarkan kebaruan melalui pengembangan model prediksi arus kas bersih periode berikutnya pada perusahaan *multifinance* Indonesia menggunakan data panel kuartalan. Variabel masukan utama yang digunakan mencakup *Operating Cash Flow* ( $OCF_t$ ), *Investing Cash Flow* ( $ICF_t$ ), dan *Financing Cash Flow* ( $FCF_t$ ), sedangkan identitas perusahaan digunakan sebagai fitur kategorikal untuk merepresentasikan perbedaan karakteristik antarperusahaan. Target prediksi dibentuk sebagai arus kas bersih periode berikutnya pada perusahaan yang sama, sehingga rancangan penelitian ini tidak hanya membangun model prediksi, tetapi juga menjaga hubungan temporal antara data arus kas periode berjalan dan target periode berikutnya.

Model yang digunakan dalam penelitian ini adalah pendekatan *machine learning Linear Regression* karena model tersebut sederhana, terukur, dan mudah diinterpretasikan. Selain itu, penelitian ini menggunakan *naive forecasting* sebagai *baseline* pembanding agar performa *Linear Regression* tidak dinilai secara tunggal. Pendekatan tersebut penting karena model utama perlu dibandingkan dengan metode sederhana yang objektif untuk melihat apakah model benar-benar memberikan nilai tambah prediktif. Seluruh proses pemodelan dan evaluasi dilakukan secara sistematis melalui pengolahan data berbasis Python di Google Colab, sedangkan Microsoft Excel digunakan pada tahap awal untuk penyusunan, pengecekan, dan verifikasi data mentah sebelum diproses lebih lanjut.

Evaluasi model dalam penelitian ini tidak hanya berfokus pada galat prediksi utama, tetapi juga mencakup evaluasi per perusahaan, analisis residual, *outlier*, uji sensitivitas, dan validasi temporal. Evaluasi yang lebih luas diperlukan karena prediksi keuangan sering dipengaruhi oleh ketidakpastian, variasi karakteristik antarperusahaan, dan potensi kesalahan prediksi yang besar pada kondisi ekstrem (Adebayo et al., 2025; Safitri et al., 2025). Dengan evaluasi tersebut, hasil penelitian diharapkan tidak hanya menunjukkan perbandingan performa model secara agregat, tetapi juga menjelaskan keterbatasan model dalam menghadapi data arus kas yang heterogen dan memiliki pergerakan ekstrem.

Oleh karena itu, penelitian ini bertujuan membangun dan mengevaluasi model prediksi arus kas bersih periode berikutnya pada perusahaan *multifinance* Indonesia menggunakan pendekatan *machine learning Linear Regression*. Kontribusi penelitian ini terletak pada

penyediaan bukti empiris mengenai kelayakan *Linear Regression* sebagai dasar prediksi awal yang terukur dan mudah diinterpretasikan, perluasan kajian prediksi arus kas menuju target arus kas bersih, penggunaan data panel kuartalan, serta penerapan kerangka evaluasi yang lebih lengkap. Dengan demikian, penelitian ini diharapkan dapat memperkaya kajian prediksi arus kas berbasis *machine learning* dan menjadi dasar awal bagi pengembangan model prediksi keuangan yang lebih kuat pada sektor *multifinance*.

## 2. KAJIAN TEORITIS

Arus kas merupakan informasi keuangan yang menggambarkan aliran kas masuk dan kas keluar perusahaan dalam suatu periode. Dalam laporan arus kas, aktivitas perusahaan dikelompokkan ke dalam aktivitas operasi, investasi, dan pendanaan. Pengelompokan tersebut menjadi dasar dalam memahami perubahan kas bersih karena arus kas bersih atau *Net Cash Flow* merepresentasikan hasil akhir dari seluruh arus kas masuk dan arus kas keluar perusahaan (IFRS Foundation, 2026; Seretidou et al., 2025). Berbeda dari *Operating Cash Flow* yang hanya menggambarkan arus kas dari aktivitas operasional, arus kas bersih mencerminkan perubahan kas yang berasal dari aktivitas operasi, investasi, dan pendanaan secara menyeluruh. Oleh karena itu, prediksi arus kas bersih periode berikutnya relevan digunakan sebagai dasar awal untuk membaca potensi tekanan likuiditas, ketidakseimbangan kas, kebutuhan pendanaan, dan stabilitas operasional perusahaan.

Penggunaan informasi arus kas sebagai dasar prediksi telah didukung oleh penelitian terdahulu yang menunjukkan bahwa komponen arus kas dan informasi historis memiliki kandungan prediktif terhadap arus kas masa depan (Apriyanti et al., 2023; Wasalwa & Putra, 2024). Selain itu, ketidakstabilan arus kas dapat menjadi sinyal awal adanya tekanan keuangan karena berkaitan dengan potensi kesulitan keuangan perusahaan (Puspitaningtyas, 2022). Informasi laba dan arus kas juga telah digunakan dalam pendeteksian *financial distress* pada penelitian sebelumnya (Apriyani et al., 2024; Efriyenty & Purba, 2022). Namun, sebagian besar penelitian tersebut masih berfokus pada *Operating Cash Flow*, *financial distress*, atau perusahaan non-*multifinance*. Dengan demikian, penelitian mengenai prediksi arus kas bersih periode berikutnya pada emiten *multifinance* Indonesia masih memiliki ruang kajian yang relevan.

Perkembangan analisis data dan *machine learning* dalam bidang akuntansi dan keuangan memperkuat kebutuhan terhadap model prediktif yang mampu mengolah data historis menjadi informasi yang lebih berguna. Kecerdasan buatan, *machine learning*, dan *big data* semakin berperan dalam sektor keuangan karena dapat membantu pembacaan data, risiko, dan peluang

secara lebih sistematis (OECD, 2021). Pendekatan analisis data dan *machine learning* juga dapat digunakan untuk menganalisis data akuntansi keuangan secara lebih terstruktur (Chakri et al., 2023). Dalam penelitian ini, pendekatan *machine learning* digunakan melalui kerangka *supervised learning* karena model dilatih menggunakan variabel masukan dan target prediksi. Variabel masukan yang digunakan meliputi *Operating Cash Flow* ( $OCF_t$ ), *Investing Cash Flow* ( $ICF_t$ ), *Financing Cash Flow* ( $FCF_t$ ), dan identitas perusahaan, sedangkan target prediksi adalah arus kas bersih periode berikutnya ( $Target\_NCF_{t+1}$ ).

Model utama yang digunakan dalam penelitian ini adalah *Linear Regression* karena model tersebut sederhana, terukur, dan mudah diinterpretasikan. Dalam konteks analisis keuangan, model yang interpretatif penting karena hasil prediksi tidak hanya menghasilkan nilai estimasi, tetapi juga perlu dapat dijelaskan berdasarkan variabel yang digunakan. Pendekatan regresi relevan dalam *predictive analytics* karena mampu membangun hubungan kuantitatif antara variabel masukan dan target prediksi (Elbatal et al., 2025). Meskipun beberapa penelitian telah menggunakan model yang lebih kompleks, seperti *deep learning*, *neural network*, dan *probabilistic forecasting* untuk prediksi arus kas atau luaran keuangan (Kotios et al., 2022; Lu & Zhao, 2025; Zhu et al., 2022), penelitian ini memilih *Linear Regression* karena fokus utamanya adalah membangun model prediktif awal yang lebih sederhana, terukur, dan dapat dibandingkan secara objektif dengan *naive forecasting*.

Penggunaan *naive forecasting* sebagai *baseline* diperlukan agar performa *Linear Regression* tidak dinilai secara tunggal. *Naive forecasting* memprediksi nilai periode berikutnya berdasarkan nilai periode berjalan, sehingga dapat menjadi pembanding sederhana untuk melihat apakah model utama benar-benar memberikan nilai tambah prediktif. Pendekatan pembanding ini penting karena data keuangan, termasuk arus kas, sering memiliki skala berbeda, volatilitas tinggi, dan potensi nilai ekstrem (Msawil et al., 2021; Safitri et al., 2025). Oleh karena itu, evaluasi model dalam penelitian ini tidak hanya menggunakan *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), dan koefisien determinasi ( $R^2$ ), tetapi juga diperkuat dengan evaluasi per perusahaan, analisis residual, analisis *outlier*, uji sensitivitas, dan validasi temporal agar hasil model dapat dibaca secara lebih hati-hati dan komprehensif (Adebayo et al., 2025; Safitri et al., 2025).

Sektor *multifinance* memiliki karakteristik khusus karena berkaitan dengan aktivitas pembiayaan, pengelolaan piutang, kebutuhan pendanaan, dan stabilitas kas. Penguatan perusahaan pembiayaan diperlukan agar industri ini semakin sehat, kuat, adaptif, berkelanjutan, serta mampu mendukung stabilitas sektor jasa keuangan (OJK, 2024, 2026).

Dalam konteks yang lebih luas, pendalaman sektor keuangan juga penting untuk mendukung pertumbuhan ekonomi yang berkelanjutan (World Bank, 2022). Pemodelan dan pengelolaan arus kas perlu disesuaikan dengan karakteristik sektor serta kebutuhan manajemen perusahaan (Pyatkina et al., 2021). Selain itu, penyajian informasi melalui *dashboard* arus kas dapat membantu penyampaian informasi keuangan secara lebih komunikatif dan berorientasi pada kebutuhan pengguna (Amalia et al., 2026). Berdasarkan sintesis tersebut, penelitian ini menempatkan *Linear Regression* sebagai model prediktif awal yang interpretatif dan *naive forecasting* sebagai *baseline* untuk menguji apakah komponen arus kas periode berjalan dapat memberikan nilai tambah prediktif dalam memprediksi arus kas bersih periode berikutnya pada data panel kuartalan emiten *multifinance* Indonesia.

### 3. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan desain eksperimen prediktif berbasis data sekunder. Desain ini dipilih karena penelitian bertujuan membangun dan mengevaluasi model prediksi arus kas bersih periode berikutnya berdasarkan data historis arus kas perusahaan. Objek penelitian adalah emiten *multifinance* yang terdaftar di Bursa Efek Indonesia (BEI) selama periode 2021–2025. Populasi penelitian mencakup seluruh emiten *multifinance* yang terdaftar di BEI, sedangkan sampel ditentukan menggunakan teknik *purposive sampling* berdasarkan kelengkapan data, keterurutan periode pelaporan, dan konsistensi komponen arus kas kuartalan. Teknik *purposive sampling* digunakan karena penelitian membutuhkan sampel dengan karakteristik tertentu yang sesuai dengan tujuan analisis prediktif (Ahmad & Wilkins, 2024).

Teknik pengumpulan data dilakukan melalui studi dokumentasi terhadap laporan arus kas kuartalan perusahaan sampel. Instrumen pengumpulan data berupa lembar tabulasi dataset yang memuat identitas perusahaan, kode saham, tahun, kuartal, *Operating Cash Flow* ( $OCF_t$ ), *Investing Cash Flow* ( $ICF_t$ ), *Financing Cash Flow* ( $FCF_t$ ), arus kas bersih atau *Net Cash Flow* ( $NCF_t$ ), dan target prediksi arus kas bersih periode berikutnya ( $Target\_NCF_{t+1}$ ). Data arus kas yang masih berbentuk kumulatif disesuaikan menjadi data kuartalan murni agar setiap observasi merepresentasikan nilai arus kas pada kuartal terkait. Validasi data dilakukan melalui pemeriksaan kelengkapan kolom, kesesuaian format angka, duplikasi kombinasi Code-Year-Quarter, serta keterurutan data pada setiap perusahaan. Karena penelitian ini menggunakan data sekunder berbasis laporan keuangan, pengujian validitas dan reliabilitas instrumen kuesioner tidak dilakukan. Validitas data dijaga melalui konsistensi sumber dokumen, keterurutan periode, pemeriksaan struktur dataset, dan validasi jumlah observasi sebelum pemodelan.

Analisis data dilakukan menggunakan Google Colab dengan bahasa pemrograman Python. Pustaka Pandas digunakan untuk pengolahan dan penyusunan data panel, NumPy untuk operasi numerik, *scikit-learn* untuk pembangunan model dan evaluasi performa, serta Matplotlib untuk pembuatan grafik dan visualisasi *dashboard* hasil penelitian. Microsoft Excel digunakan pada tahap awal untuk penyusunan, pengecekan, dan verifikasi data mentah sebelum diproses lebih lanjut. Dengan demikian, proses awal penataan data dilakukan melalui Excel, sedangkan proses pengolahan data, pembentukan target, pelatihan model, evaluasi, pembuatan grafik, dan visualisasi *dashboard* dilakukan secara terintegrasi melalui Google Colab agar alur penelitian lebih sistematis, transparan, dan dapat direplikasi.

Tabel 1 menyajikan tahapan penelitian secara ringkas mulai dari pengumpulan data hingga evaluasi model. Tabel ini digunakan untuk memperjelas alur kerja penelitian agar proses analisis dapat dipahami secara sistematis.

**Tabel 1.** Tahapan Penelitian.

| Tahap              | Aktivitas Utama                                                                                       | Output                                       |
|--------------------|-------------------------------------------------------------------------------------------------------|----------------------------------------------|
| Pengumpulan data   | Mengumpulkan laporan arus kas kuartalan emiten <i>multifinance</i> periode 2021–2025                  | Data mentah arus kas                         |
| Penyusunan dataset | Menyusun data panel berdasarkan Code, Year, dan Quarter                                               | Dataset panel kuartalan                      |
| Prapemrosesan data | Membersihkan format angka, memvalidasi duplikasi, dan membentuk $Target\_NCF_{t+1}$                   | Dataset siap model                           |
| Pemodelan          | Melatih model <i>Linear Regression</i> dan membangun <i>naive forecasting</i> sebagai <i>baseline</i> | Hasil prediksi model utama dan pembanding    |
| Evaluasi model     | Menghitung MAE, MSE, RMSE, $R^2$ , residual, <i>outlier</i> , uji sensitivitas, dan validasi temporal | Tabel, grafik, dan <i>dashboard</i> evaluasi |

Berdasarkan Tabel 1, penelitian diawali dengan pengumpulan laporan arus kas kuartalan perusahaan *multifinance*, kemudian dilanjutkan dengan penyusunan dataset panel berdasarkan identitas perusahaan dan periode pengamatan. Setelah itu, data dibersihkan, divalidasi, dan dibentuk menjadi dataset *supervised learning* melalui pembuatan  $Target\_NCF_{t+1}$ . Berdasarkan hasil pengolahan data, dari 220 observasi mentah diperoleh 209 observasi siap model. Pengurangan 11 observasi terjadi karena setiap perusahaan memiliki satu observasi terminal yang tidak memiliki nilai target pada periode berikutnya. Data siap model kemudian dibagi menggunakan *time-based split* menjadi 176 data latih dan 33 data uji dari 11 perusahaan.

Target prediksi dibentuk dengan menggeser nilai  $NCF_t$  satu periode ke depan pada perusahaan yang sama. Dengan demikian, model menggunakan informasi arus kas periode berjalan untuk memprediksi arus kas bersih periode berikutnya. Secara sederhana, pembentukan target dinyatakan sebagai berikut.

$$Target\_NCF_{t+1} = NCF_{t+1} \quad (i)$$

Dalam rumus tersebut,  $Target\_NCF_{t+1}$  menunjukkan target prediksi arus kas bersih periode berikutnya, sedangkan  $NCF_{t+1}$  menunjukkan nilai arus kas bersih aktual pada periode berikutnya. Observasi terakhir pada setiap perusahaan tidak digunakan dalam pemodelan karena tidak memiliki nilai target pada periode berikutnya.

Model utama yang digunakan adalah *Linear Regression*. Variabel input utama terdiri atas  $OCF_t$ ,  $ICF_t$ , dan  $FCF_t$ , sedangkan variabel Code digunakan sebagai fitur kategorikal untuk merepresentasikan identitas perusahaan. Pada tahap implementasi, fitur numerik distandardisasi menggunakan *StandardScaler*, sedangkan fitur kategorikal Code dikodekan menggunakan *OneHotEncoder* agar dapat diproses oleh model. Secara fungsional, model yang digunakan dalam penelitian ini dinyatakan sebagai berikut.

$$\widehat{NCF}_{t+1} = f_{LR}(Z(OCF_t), Z(ICF_t), Z(FCF_t), Code_{enc}) \quad (ii)$$

Dalam rumus tersebut,  $\widehat{NCF}_{t+1}$  menunjukkan prediksi arus kas bersih periode berikutnya,  $f_{LR}$  menunjukkan fungsi model *Linear Regression*,  $Z(OCF_t)$ ,  $Z(ICF_t)$ , dan  $Z(FCF_t)$  menunjukkan fitur arus kas yang telah distandardisasi, sedangkan  $Code_{enc}$  menunjukkan identitas perusahaan yang telah dikodekan sebagai fitur kategorikal. Bentuk fungsional ini digunakan agar penulisan model tetap sesuai dengan implementasi kode, tetapi tidak terlalu teknis untuk pembaca artikel jurnal.

Model pembanding yang digunakan adalah *naive forecasting*. Model ini memprediksi arus kas bersih periode berikutnya menggunakan nilai arus kas bersih periode berjalan. Secara sederhana, model pembanding tersebut dinyatakan sebagai berikut.

$$\widehat{NCF}_{t+1}^{naive} = NCF_t \quad (iii)$$

Dalam rumus tersebut,  $\widehat{NCF}_{t+1}^{naive}$  menunjukkan prediksi arus kas bersih periode berikutnya menggunakan *naive forecasting*, sedangkan  $NCF_t$  menunjukkan nilai arus kas bersih pada periode berjalan. Model ini digunakan sebagai *baseline* agar performa *Linear Regression* tidak dinilai secara berdiri sendiri, tetapi dibandingkan dengan pendekatan sederhana yang objektif.

Kinerja model dievaluasi menggunakan *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), dan  $R^2$ . MAE digunakan untuk membaca rata-rata galat absolut, MSE digunakan untuk melihat rata-rata kuadrat galat, RMSE digunakan untuk mengukur galat dalam satuan target, sedangkan  $R^2$  digunakan untuk melihat kemampuan model dalam menjelaskan variasi target. Rumus metrik tersebut tidak dijabarkan secara panjang karena termasuk ukuran evaluasi umum dalam pemodelan prediktif. Penggunaan

beberapa metrik diperlukan agar evaluasi model tidak hanya bergantung pada satu ukuran performa, terutama karena data arus kas perusahaan memiliki skala yang berbeda dan dapat mengandung nilai ekstrem (Elbatal et al., 2025; Safitri et al., 2025).

Selain evaluasi agregat, penelitian ini juga melakukan evaluasi per perusahaan, analisis residual, analisis *outlier*, uji sensitivitas, dan validasi temporal. Evaluasi per perusahaan digunakan untuk melihat konsistensi performa model pada setiap emiten sampel. Analisis residual dan *outlier* digunakan untuk membaca pola kesalahan prediksi serta mengidentifikasi observasi dengan galat terbesar. Uji sensitivitas digunakan untuk melihat pengaruh perusahaan dengan nilai ekstrem terhadap performa agregat model, sedangkan validasi temporal digunakan untuk menguji konsistensi model pada skenario waktu yang berbeda. Dengan rancangan tersebut, metode penelitian ini tidak hanya menilai performa model secara agregat, tetapi juga menilai kestabilan, keterbatasan, dan potensi pengembangan model secara lebih menyeluruh.

#### 4. HASIL DAN PEMBAHASAN

##### Kesiapan Data dan Implementasi Model

Pengumpulan data dilakukan terhadap laporan arus kas kuartalan emiten *multifinance* yang terdaftar di Bursa Efek Indonesia (BEI) selama periode 2021–2025. Data yang digunakan telah melalui proses seleksi berdasarkan kelengkapan laporan, keterurutan periode pelaporan, dan konsistensi komponen arus kas kuartalan sebagaimana dijelaskan pada bagian metode penelitian. Berdasarkan proses tersebut, diperoleh 220 observasi mentah dari 11 perusahaan. Setelah target prediksi dibentuk melalui pergeseran nilai arus kas bersih satu periode ke depan pada perusahaan yang sama, jumlah data siap model menjadi 209 observasi. Pengurangan 11 observasi terjadi karena setiap perusahaan memiliki satu observasi terminal yang tidak memiliki nilai  $Target\_NCF_{t+1}$ . Data siap model kemudian dibagi menggunakan *time-based split* menjadi 176 data latih dan 33 data uji. Ringkasan dataset penelitian disajikan pada Tabel 2.

**Tabel 2.** Ringkasan Dataset Penelitian.

| Komponen                               | Nilai                      |
|----------------------------------------|----------------------------|
| Jumlah perusahaan sampel               | 11                         |
| Periode pengamatan                     | 2021–2025                  |
| Jumlah data mentah                     | 220                        |
| Jumlah observasi terminal tanpa target | 11                         |
| Jumlah data siap model                 | 209                        |
| Jumlah data latih                      | 176                        |
| Jumlah data uji                        | 33                         |
| Variabel input utama                   | $OCF_t, ICF_t,$<br>$FCF_t$ |
| Variabel kategorikal                   | Code                       |
| Variabel target                        | $Target\_NCF_{t+1}$        |

Tabel 2 menunjukkan bahwa struktur dataset telah sesuai dengan rancangan penelitian, yaitu data panel kuartalan yang digunakan untuk membangun model prediktif berbasis *supervised learning*. Variabel  $OCF_t$ ,  $ICF_t$ , dan  $FCF_t$  digunakan sebagai fitur numerik karena ketiganya merepresentasikan komponen arus kas periode berjalan. Variabel Code digunakan sebagai fitur kategorikal untuk merepresentasikan identitas perusahaan, sehingga model dapat mempertimbangkan perbedaan karakteristik antarperusahaan. Dengan demikian, model tidak hanya membaca hubungan antara komponen arus kas dan target prediksi, tetapi juga memperhitungkan heterogenitas emiten *multifinance* dalam dataset.


Validasi data dilakukan melalui pemeriksaan format angka, kelengkapan kolom, duplikasi kombinasi Code-Year-Quarter, serta keterurutan data pada setiap perusahaan. Hasil validasi menunjukkan bahwa dataset siap digunakan untuk pemodelan karena struktur data telah konsisten dan tidak ditemukan duplikasi pada kombinasi identitas perusahaan dan periode. Pada tahap implementasi, fitur numerik distandardisasi, fitur kategorikal Code dikodekan, kemudian model *Linear Regression* dilatih menggunakan data latih. Microsoft Excel digunakan pada tahap awal untuk penyusunan, pengecekan, dan verifikasi data mentah, sedangkan pengolahan data, pemodelan, evaluasi, pembuatan grafik, dan visualisasi *dashboard* dilakukan melalui Google Colab menggunakan Python, Pandas, NumPy, *scikit-learn*, dan Matplotlib.

### Evaluasi Model dan Hasil Prediksi

Evaluasi model dilakukan pada data uji untuk mengetahui kemampuan model dalam memprediksi arus kas bersih periode berikutnya. Model utama yang digunakan adalah *Linear Regression*, sedangkan model pembanding yang digunakan adalah *naive forecasting*. Hasil evaluasi menunjukkan bahwa *Linear Regression* menghasilkan galat yang lebih rendah dibandingkan *naive forecasting*. Secara agregat, *Linear Regression* mampu menurunkan MAE sebesar 31,63% dan RMSE sebesar 30,90% dibandingkan *baseline*. Perbandingan performa kedua model disajikan pada Tabel 3 dan Gambar 1.


**Tabel 3.** Hasil Evaluasi Model pada Data Uji.

| Model                    | MAE              | MSE                     | RMSE              | $R^2$     |
|--------------------------|------------------|-------------------------|-------------------|-----------|
| <i>Linear Regression</i> | 5.175.010.760,53 | $1,3087 \times 10^{20}$ | 11.439.892.766,99 | -0,149195 |
| <i>Naive Forecasting</i> | 7.569.470.101,77 | $2,7409 \times 10^{20}$ | 16.555.565.343,09 | -1,406790 |



**Gambar 1.** Grafik Perbandingan MAE dan RMSE.

Tabel 3 dan Gambar 1 menunjukkan bahwa *Linear Regression* memiliki nilai MAE dan RMSE yang lebih rendah dibandingkan *naive forecasting*. Nilai MAE yang lebih rendah menunjukkan bahwa rata-rata galat absolut model utama lebih kecil, sedangkan nilai RMSE yang lebih rendah menunjukkan bahwa model utama lebih baik dalam menekan galat besar. Temuan ini menunjukkan bahwa *Linear Regression* memberikan nilai tambah prediktif dibandingkan pendekatan sederhana. Namun, nilai  $R^2$  pada data uji masih negatif, sehingga model belum dapat dinyatakan optimal dalam menjelaskan variasi target pada data baru. Dengan demikian, hasil penelitian perlu dibaca secara hati-hati, yaitu *Linear Regression* lebih baik dari *baseline* berdasarkan MAE dan RMSE, tetapi performanya masih terbatas pada data yang heterogen dan memiliki pergerakan arus kas ekstrem.



**Gambar 2.** Grafik Aktual dan Prediksi pada Data Uji.

Gambar 2 memperlihatkan perbandingan antara nilai aktual, prediksi *Linear Regression*, dan prediksi *naive forecasting* pada 33 observasi data uji. Secara umum, *Linear Regression* mampu mengikuti sebagian pola nilai aktual dengan galat yang lebih rendah dibandingkan *baseline*. Namun, pada beberapa observasi yang mengalami lonjakan atau penurunan arus kas secara ekstrem, model masih menghasilkan selisih prediksi yang cukup besar. Kondisi ini menjelaskan mengapa MAE dan RMSE *Linear Regression* lebih baik dibandingkan *naive forecasting*, tetapi nilai  $R^2$  masih negatif.


### Evaluasi per Perusahaan, Residual, dan Outlier

Evaluasi per perusahaan dilakukan untuk mengetahui apakah performa model konsisten pada setiap emiten sampel. Hasil evaluasi menunjukkan bahwa performa model tidak seragam pada seluruh perusahaan. *Linear Regression* menjadi model terbaik pada enam perusahaan, yaitu BBLD, BPFI, DEFI, FUJI, HDFA, dan WOMF. Sebaliknya, *naive forecasting* memberikan hasil lebih baik pada ADMF, CFIN, POLA, TIFA, dan VRNA. Ringkasan hasil evaluasi per perusahaan disajikan pada Tabel 4.

**Tabel 4.** Evaluasi MAE per Perusahaan.

| Kode | MAE LR            | MAE Naive         | Model Terbaik            |
|------|-------------------|-------------------|--------------------------|
| ADMF | 106.613,47        | 488,46            | <i>Naive Forecasting</i> |
| BBLD | 271,38            | 349,90            | <i>Linear Regression</i> |
| BPFI | 7.695.634.981,52  | 19.161.188.933,67 | <i>Linear Regression</i> |
| CFIN | 80.631.519,98     | 11.687.209,00     | <i>Naive Forecasting</i> |
| DEFI | 729.651.126,71    | 1.320.764.586,00  | <i>Linear Regression</i> |
| FUJI | 23.744.327.109,67 | 43.980.171.768,67 | <i>Linear Regression</i> |
| HDFA | 40.019.844,49     | 80.329.301,00     | <i>Linear Regression</i> |
| POLA | 24.501.356.382,04 | 18.651.436.102,67 | <i>Naive Forecasting</i> |
| TIFA | 66.150.701,27     | 50.836.362,67     | <i>Naive Forecasting</i> |
| VRNA | 66.291.366,74     | 5.791.247,00      | <i>Naive Forecasting</i> |
| WOMF | 948.448,51        | 1.964.770,43      | <i>Linear Regression</i> |

Tabel 4 menunjukkan bahwa keunggulan *Linear Regression* secara agregat tidak berlaku merata pada seluruh perusahaan. Pada BPFI, FUJI, dan DEFI, model utama menghasilkan MAE yang lebih rendah dibandingkan *naive forecasting*. Namun, pada POLA, CFIN, TIFA, VRNA, dan ADMF, pendekatan *naive forecasting* masih memberikan hasil yang lebih baik. Hasil ini menunjukkan bahwa evaluasi model tidak cukup dilakukan hanya pada tingkat agregat, tetapi juga perlu dilihat pada tingkat perusahaan agar sumber kekuatan dan kelemahan model dapat diidentifikasi secara lebih jelas.



**Gambar 3.** Grafik MAE per Perusahaan.


Gambar 3 menunjukkan bahwa nilai galat terbesar terkonsentrasi pada perusahaan tertentu, terutama FUJI, POLA, dan BPFI. Temuan ini menunjukkan bahwa skala dan volatilitas arus kas sangat memengaruhi performa model. Perusahaan dengan pergerakan arus

kas ekstrem cenderung menghasilkan galat lebih besar sehingga dapat memengaruhi performa agregat. Oleh karena itu, model prediksi arus kas bersih pada sektor *multifinance* perlu mempertimbangkan heterogenitas karakteristik perusahaan, bukan hanya pola agregat seluruh sampel.

Selain evaluasi per perusahaan, penelitian ini juga melakukan analisis residual dan *outlier*. Analisis residual digunakan untuk melihat sebaran kesalahan prediksi, sedangkan analisis *outlier* digunakan untuk mengidentifikasi observasi dengan galat terbesar. Ringkasan residual dan *outlier* utama disajikan pada Tabel 5 dan Gambar 4.

**Tabel 5.** Ringkasan Residual dan *Outlier* Utama.

| Komponen                | <i>Linear Regression</i> | <i>Naive Forecasting</i> |
|-------------------------|--------------------------|--------------------------|
| Simpangan baku residual | 11.098.775.177,47        | 16.794.962.488,08        |
| Residual minimum        | -25.181.514.069,74       | -43.540.030.238,00       |
| Residual maksimum       | 36.792.201.938,20        | 66.684.836.926,00        |
| <i>Outlier</i> dominan  | POLA, FUJI, BPFI         | POLA, FUJI, BPFI         |



**Gambar 4.** Grafik Standar Deviasi Residual.

Tabel 5 dan Gambar 4 menunjukkan bahwa penyebaran galat *Linear Regression* lebih rendah dibandingkan *naive forecasting*. Simpangan baku residual model utama sebesar 11.098.775.177,47, lebih rendah dibandingkan *baseline* sebesar 16.794.962.488,08. Hal ini menunjukkan bahwa *Linear Regression* tidak hanya menghasilkan MAE dan RMSE yang lebih rendah, tetapi juga memiliki sebaran galat yang lebih terkendali. Meskipun demikian, analisis *outlier* menunjukkan bahwa observasi ekstrem masih memengaruhi hasil, terutama pada POLA, FUJI, dan BPFI. Observasi dengan galat terbesar muncul pada POLA tahun 2025 kuartal Q2. Temuan ini menjelaskan mengapa nilai  $R^2$  pada data uji masih negatif meskipun MAE dan RMSE model utama lebih rendah dibandingkan *baseline*.


### Uji Sensitivitas dan Validasi Temporal

Uji sensitivitas dilakukan untuk membaca pengaruh perusahaan dengan galat ekstrem terhadap performa agregat. Pengujian ini tidak digunakan untuk mengganti hasil utama, tetapi untuk memahami seberapa besar pengaruh perusahaan tertentu terhadap performa model. Hasil

uji sensitivitas menunjukkan bahwa ketika FUJI dan POLA dikeluarkan, performa *Linear Regression* meningkat secara signifikan. Namun, hasil utama tetap mempertahankan seluruh perusahaan karena FUJI dan POLA merupakan bagian dari sampel yang valid. Hasil uji sensitivitas disajikan pada Tabel 6 dan Gambar 5.

**Tabel 6.** Hasil Uji Sensitivitas.

| Skenario          | MAE LR           | MAE Naive        | RMSE LR           | $R^2$ LR |
|-------------------|------------------|------------------|-------------------|----------|
| Data utama        | 5.175.010.760,53 | 7.569.470.101,77 | 11.439.892.766,99 | -0,15    |
| Tanpa FUJI        | 3.328.618.977,39 | 3.928.399.935,08 | 8.946.751.248,56  | -0,75    |
| Tanpa POLA        | 3.181.012.090,59 | 6.461.273.501,68 | 8.566.667.599,22  | 0,21     |
| Tanpa FUJI + POLA | 680.867.536,79   | 2.292.507.027,57 | 2.860.737.100,09  | 0,35     |



**Gambar 5.** Grafik Uji Sensitivitas.

Tabel 6 dan Gambar 5 menunjukkan bahwa performa agregat model sangat dipengaruhi oleh FUJI dan POLA. Ketika kedua perusahaan tersebut dikeluarkan, MAE *Linear Regression* turun dari 5.175.010.760,53 menjadi 680.867.536,79, sedangkan nilai  $R^2$  meningkat dari -0,15 menjadi 0,35. Hasil ini menunjukkan bahwa keterbatasan model tidak hanya disebabkan oleh algoritma, tetapi juga oleh karakteristik data yang ekstrem. Namun, skenario tanpa FUJI dan POLA tidak dijadikan hasil utama karena pengeluaran sampel valid dapat menimbulkan bias interpretasi. Oleh karena itu, uji sensitivitas diposisikan sebagai analisis tambahan untuk memahami stabilitas model, bukan sebagai pengganti hasil utama.

Validasi temporal dilakukan untuk melihat konsistensi model ketika diterapkan pada periode waktu yang berbeda. Pengujian ini penting karena prediksi arus kas bersih dibangun dari data historis untuk memprediksi periode berikutnya. Hasil validasi temporal disajikan pada Tabel 7.

**Tabel 7.** Hasil Validasi Temporal.

| Skenario                          | MAE LR               | MAE Naive        | RMSE LR               | RMSE Naive            | $R^2$ LR |
|-----------------------------------|----------------------|------------------|-----------------------|-----------------------|----------|
| Train $\leq$ 2023,<br>Test = 2024 | 2.116.966.<br>203,36 | 2.843.999.013,94 | 4.275.825.6<br>32,92  | 7.761.609.34<br>8,96  | -1,70    |
| Train $\leq$ 2024,<br>Test = 2025 | 5.175.010.<br>760,53 | 7.569.470.101,77 | 11.439.892.<br>766,99 | 16.555.565.3<br>43,09 | -0,15    |

Tabel 7 menunjukkan bahwa *Linear Regression* tetap menghasilkan MAE dan RMSE yang lebih rendah dibandingkan *naive forecasting* pada skenario data uji tahun 2024 dan 2025. Namun, galat pada skenario data uji tahun 2025 lebih besar dibandingkan tahun 2024. Hal ini menunjukkan bahwa pola arus kas tahun 2025 lebih sulit diprediksi atau memiliki volatilitas lebih tinggi. Dengan demikian, model perlu diperbarui secara berkala apabila digunakan pada periode yang berbeda agar dapat menyesuaikan perubahan karakteristik data terbaru.

### Keterkaitan Hasil dengan Literatur dan Implikasi Penelitian


Hasil penelitian ini mendukung kajian yang menyatakan bahwa informasi arus kas historis memiliki kandungan prediktif terhadap arus kas masa depan (Apriyanti et al., 2023; Wasalwa & Putra, 2024). Temuan bahwa *Linear Regression* mampu menghasilkan MAE dan RMSE yang lebih rendah dibandingkan *naive forecasting* menunjukkan bahwa komponen arus kas periode berjalan dapat memberikan nilai tambah dalam memprediksi arus kas bersih periode berikutnya. Namun, nilai  $R^2$  yang masih negatif menunjukkan bahwa tiga komponen arus kas utama dan identitas perusahaan belum sepenuhnya mampu menjelaskan variasi target pada data uji.

Kondisi tersebut sejalan dengan literatur yang menekankan bahwa prediksi keuangan sering dipengaruhi oleh volatilitas, ketidakpastian, dan observasi ekstrem (Adebayo et al., 2025; Safitri et al., 2025). Dalam konteks penelitian ini, pengaruh tersebut terlihat dari dominasi galat pada POLA, FUJI, dan BPFI. Temuan ini memperkuat pentingnya evaluasi per perusahaan, analisis residual, dan uji sensitivitas agar model tidak hanya dinilai dari performa agregat, tetapi juga dari kestabilan prediksi pada perusahaan dengan karakteristik berbeda.

Dibandingkan dengan penelitian yang menggunakan model kompleks seperti *neural network*, *deep learning*, atau *probabilistic forecasting*, penelitian ini mengambil posisi metodologis yang lebih sederhana dan interpretatif (Kotios et al., 2022; Lu & Zhao, 2025; Zhu et al., 2022). Pendekatan ini tidak dimaksudkan untuk mengklaim bahwa *Linear Regression* merupakan model paling akurat, tetapi untuk menunjukkan bahwa model sederhana tetap dapat memberikan nilai tambah prediktif ketika dibandingkan dengan *baseline* yang objektif. Posisi ini juga berbeda dari studi *cash holding* yang berfokus pada prediksi kepemilikan kas

menggunakan *supervised machine learning*, sedangkan penelitian ini menempatkan arus kas bersih periode berikutnya sebagai target prediksi utama (Özlem & Tan, 2022).

#### Dashboard Model Prediksi NCF



**Gambar 6.** Dashboard Ringkasan Hasil Model.

Gambar 6 merangkum hasil utama penelitian dalam bentuk *dashboard*, meliputi informasi dataset, evaluasi model, grafik aktual dan prediksi, MAE per perusahaan, standar deviasi residual, serta uji sensitivitas. *Dashboard* digunakan sebagai ringkasan visual untuk memudahkan pembacaan hasil, sedangkan detail pengujian tetap dijelaskan melalui tabel, grafik, dan interpretasi naratif pada setiap subbagian. Implikasi teoritis dari penelitian ini adalah perluasan kajian prediksi arus kas dari fokus *Operating Cash Flow* menuju arus kas bersih periode berikutnya pada konteks *multifinance* Indonesia. Implikasi terapan dari penelitian ini adalah *Linear Regression* dapat digunakan sebagai dasar prediksi awal yang terukur dan mudah diinterpretasikan untuk mendukung analisis arus kas. Namun, hasil model tetap perlu dibaca secara hati-hati karena performanya masih terbatas pada data yang heterogen dan memiliki pergerakan arus kas ekstrem.

## 5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian, model *Linear Regression* berhasil dibangun dan dievaluasi untuk memprediksi arus kas bersih periode berikutnya pada perusahaan *multifinance* Indonesia dengan menggunakan data panel kuartalan periode 2021–2025. Model menggunakan komponen arus kas periode berjalan, yaitu *Operating Cash Flow* ( $OCF_t$ ), *Investing Cash Flow* ( $ICF_t$ ), dan *Financing Cash Flow* ( $FCF_t$ ), serta identitas perusahaan sebagai fitur kategorikal. Dari 220 observasi mentah, diperoleh 209 observasi siap model yang terdiri atas 176 data latih

dan 33 data uji. Hasil pengujian menunjukkan bahwa *Linear Regression* menghasilkan MAE sebesar 5.175.010.760,53 dan RMSE sebesar 11.439.892.766,99, lebih rendah dibandingkan *naive forecasting* yang menghasilkan MAE sebesar 7.569.470.101,77 dan RMSE sebesar 16.555.565.343,09. Dengan demikian, tujuan penelitian untuk membangun dan mengevaluasi model prediksi arus kas bersih periode berikutnya telah tercapai, serta menunjukkan bahwa model utama memiliki nilai tambah prediktif dibandingkan *baseline*.

Meskipun demikian, hasil penelitian juga menunjukkan bahwa *Linear Regression* belum dapat dinyatakan sebagai model yang sepenuhnya optimal. Nilai  $R^2$  pada data uji yang masih negatif menunjukkan bahwa kemampuan model dalam menjelaskan variasi arus kas bersih masih terbatas, terutama pada data yang heterogen dan memiliki pergerakan arus kas ekstrem. Evaluasi per perusahaan, analisis residual, analisis *outlier*, uji sensitivitas, dan validasi temporal menunjukkan bahwa performa model belum merata pada seluruh emiten. Galat terbesar masih dipengaruhi oleh perusahaan dengan pergerakan arus kas yang sangat besar atau tidak stabil, terutama POLA, FUJI, dan BPGF. Oleh karena itu, *Linear Regression* lebih tepat diposisikan sebagai dasar prediksi awal yang terukur dan mudah diinterpretasikan, bukan sebagai model final yang sepenuhnya mampu menggambarkan seluruh pola arus kas bersih pada perusahaan *multifinance*.

Secara terapan, hasil penelitian ini dapat digunakan sebagai dasar awal untuk mendukung analisis prediktif arus kas pada perusahaan *multifinance*. Model *Linear Regression* dapat membantu membaca potensi perubahan arus kas bersih periode berikutnya secara sederhana, terukur, dan mudah dijelaskan. Namun, hasil prediksi tetap perlu digunakan secara hati-hati dan tidak dijadikan satu-satunya dasar pengambilan keputusan, terutama pada perusahaan yang memiliki pola arus kas ekstrem atau sangat fluktuatif. Evaluasi tambahan seperti analisis residual, identifikasi *outlier*, evaluasi per perusahaan, dan validasi temporal tetap diperlukan agar pengguna model dapat memahami sumber kesalahan prediksi serta batas kemampuan model.

Penelitian selanjutnya disarankan untuk memperluas cakupan data, baik dari sisi jumlah perusahaan maupun periode pengamatan, agar model memiliki dasar pembelajaran yang lebih representatif. Variabel tambahan seperti total aset, liabilitas, pendapatan, laba bersih, rasio likuiditas, rasio leverage, ukuran perusahaan, serta indikator makroekonomi juga dapat dimasukkan agar variasi arus kas bersih dapat dijelaskan secara lebih komprehensif. Selain itu, penelitian mendatang dapat membandingkan *Linear Regression* dengan model non-linear seperti *Random Forest*, *Gradient Boosting*, *XGBoost*, *LightGBM*, *CatBoost*, *Support Vector Regression*, *neural network*, atau *deep learning*. Pengembangan *prediction interval*, validasi

temporal yang lebih panjang, dan *retraining* model secara berkala juga diperlukan agar hasil prediksi tidak hanya dinilai dari nilai galat, tetapi juga dari kestabilan model ketika digunakan pada periode data yang berbeda.

## DAFTAR REFERENSI

- Adebayo, O., Mensah, N., & Adukpo, T. K. (2025). Beyond traditional cash flow management: How machine learning and scenario planning drive financial resilience. *EPRA International Journal of Economics, Business and Management Studies*, 12(3), 81–89. <https://doi.org/10.36713/epra20503>
- Ahmad, M., & Wilkins, S. (2024). Purposive sampling in qualitative research: A framework for the entire journey. *Quality & Quantity*. <https://doi.org/10.1007/s11135-024-02022-5>
- Amalia, Izzati, R., Wiyono, B. H., Mahendra, R. A. C., & Amalia, B. (2026). Designing and evaluating a user-centered cash flow monitoring dashboard for higher education using design thinking and UEQ framework. *Journal of Computer Networks, Architecture and High Performance Computing*, 8(1), 133–148. <https://doi.org/10.47709/cnahpc.v8i1.7858>
- Apriyani, S., Sidik, S., & Hendriyani, R. M. (2024). Pengaruh arus kas, profitabilitas dan ukuran perusahaan terhadap financial distress: Studi kasus pada perusahaan real estate yang terdaftar di Bursa Efek Indonesia periode 2018–2020. *Journal Scientific of Mandalika*, 5(12), 562–570. <https://ojs.cahayamandalika.com/index.php/jomla/article/view/4039>
- Apriyanti, A., Sudiyanto, T., & Oktariansyah. (2023). Faktor-faktor yang mempengaruhi prediksi arus kas operasi masa depan pada perusahaan manufaktur subsektor food and beverages yang terdaftar di BEI. *Akuntoteknologi: Jurnal Ilmiah Akuntansi dan Teknologi*, 15(1), 21–31. <https://doi.org/10.31253/aktek.v15i1.1870>
- Chakri, P., Pratap, S., Lakshay, & Gouda, S. K. (2023). An exploratory data analysis approach for analyzing financial accounting data using machine learning. *Decision Analytics Journal*, 7, 100212. <https://doi.org/10.1016/j.dajour.2023.100212>
- Efriyenty, D., & Purba, N. M. B. (2022). Use of profit and cash flows in predicting financial distress food and beverage companies. *Owner: Riset & Jurnal Akuntansi*, 6(2). <https://doi.org/10.33395/owner.v6i2.544>
- Elbatal, I., Almetwally, E. M., Alaskar, M. Z., Alsaedi, B. S. O., Alzubaidi, S., & Yusuf, M. (2025). Predictive analytics in accounting: Using regression models to forecast financial outcomes. *Alexandria Engineering Journal*, 128, 484–492. <https://doi.org/10.1016/j.aej.2025.05.087>
- IFRS Foundation. (2026). *IAS 7 statement of cash flows*. IFRS Foundation. <https://www.ifrs.org/issued-standards/list-of-standards/ias-7-statement-of-cash-flows/>
- Kotios, D., Makridis, G., Fatouros, G., & Kyriazis, D. (2022). Deep learning enhancing banking services: A hybrid transaction classification and cash flow prediction approach. *Journal of Big Data*, 9, 100. <https://doi.org/10.1186/s40537-022-00651-x>

- Lu, T., & Zhao, Y. (2025). The machine learning-enhanced DCF model and probabilistic cash flow forecasting. In *Proceedings of the 2025 International Conference on Management Science and Computer Engineering* (pp. 126–133). <https://doi.org/10.1145/3760023.3760045>
- Msawil, M., Elghaish, F., Seneviratne, K., & McIlwaine, S. (2021). Developing a parametric cash flow forecasting model for complex infrastructure projects: A comparative study. *Sustainability*, 13(20), 11305. <https://doi.org/10.3390/su132011305>
- OECD. (2021). *Artificial intelligence, machine learning and big data in finance: Opportunities, challenges and implications for policy makers*. Paris: OECD Publishing. <https://doi.org/10.1787/98e761e7-en>
- Otoritas Jasa Keuangan. (2024). *Roadmap pengembangan dan penguatan perusahaan pembiayaan 2024–2028*. Otoritas Jasa Keuangan. <https://ojk.go.id/id/berita-dan-kegiatan/info-terkini/Pages/Roadmap-Pengembangan-dan-Penguatan-Perusahaan-Pembiayaan-2024-2028.aspx>
- Otoritas Jasa Keuangan. (2026, March 3). *Siaran pers: Penguatan ketahanan dan integritas sektor jasa keuangan mendukung stabilitas sistem keuangan*. Otoritas Jasa Keuangan. <https://ojk.go.id/id/berita-dan-kegiatan/siaran-pers/Pages/RDKB-Feb-2026.aspx>
- Özlem, Ş., & Tan, O. F. (2022). Predicting cash holdings using supervised machine learning algorithms. *Financial Innovation*, 8, 44. <https://doi.org/10.1186/s40854-022-00351-8>
- Puspitaningtyas, A. (2022). Arus kas dan kesulitan keuangan perusahaan: Studi empiris pada perusahaan subsektor coal mining yang terdaftar dalam IDX SCM liquid di Bursa Efek Indonesia periode 2017–2021. *Jurnal Akuntansi dan Bisnis Krisnadwipayana*, 9(3), 936–944. <https://jurnal.unkris.ac.id/index.php/jabk/article/view/308>
- Pyatkina, D., Shcherbina, T., Samusenkov, V., Razinkina, I., & Sroka, M. (2021). Modeling and management of power supply enterprises' cash flows. *Energies*, 14, 1181. <https://doi.org/10.3390/en14041181>
- Roy, S., Polley, S., De, S., Gangwal, C., & Mitra, C. (2025). Harnessing AI and machine learning for improved cash flow forecasting. *Proceedings of the 6th Doctoral Symposium on Intelligence Enabled Research, CEUR Workshop Proceedings*, 3900, 211–222. <https://ceur-ws.org/Vol-3900/Paper17.pdf>
- Safitri, W. O. R., Afendi, F. M., & Susetyo, B. (2025). Prediction intervals in machine learning: Residual bootstrap and quantile regression for cash flow analysis. *BAREKENG: Journal of Mathematics and Its Applications*, 19(3), 1625–1636. <https://doi.org/10.30598/barekengvol19iss3pp1625-1636>
- Seretidou, D., Billios, D., & Stavropoulos, A. (2025). Integrative analysis of traditional and cash flow financial ratios: Insights from a systematic comparative review. *Risks*, 13(4), 62. <https://doi.org/10.3390/risks13040062>
- Wasalwa, W., & Putra, D. M. (2024). Operating cash flow prediction: A comparative study of earnings and accruals. *Accounting Analysis Journal*, 13(3), 173–183. <https://doi.org/10.15294/aaaj.v13i3.13001>
- World Bank. (2022). *Indonesia economic prospects, June 2022: Financial deepening for stronger growth and sustainable recovery*. World Bank. <https://www.worldbank.org/en/country/indonesia/publication/indonesia-economic-prospects-iej-june-2022-financial-deepening-for-stronger-growth-and-sustainable-recovery>

Zhu, L., Yan, M., & Bai, L. (2022). Prediction of enterprise free cash flow based on a backpropagation neural network model of the improved genetic algorithm. *Information*, 13, 172. <https://doi.org/10.3390/info13040172>