

BAB II

TINJAUAN PUSTAKA

2.1 Penelitian yang Relevan

Penelitian pertama berjudul “*Profit Prediction Using ARIMA, SARIMA and LSTM Models in Time series Forecasting: A Comparison*” membahas penerapan tiga model peramalan deret waktu, yaitu ARIMA (*Autoregressive Integrated Moving Average*), SARIMA (*Seasonal ARIMA*), dan LSTM (*Long Short-Term Memory*), dalam memprediksi profit berdasarkan data historis. Penelitian ini menekankan pentingnya analisis profit dalam berbagai bidang seperti keuangan, industri, kesehatan, dan meteorologi karena mampu membantu memahami pola penjualan, keuntungan, dan kerugian serta memproyeksikan nilai masa depan. *Dataset* yang digunakan diubah menjadi bentuk stasioner untuk model ARIMA, sementara model SARIMA dan LSTM tidak memerlukan transformasi tersebut. Ketiga model kemudian dibangun dan diuji untuk memprediksi profit, dan hasilnya menunjukkan bahwa LSTM memiliki tingkat akurasi tertinggi yaitu 97,01%, melampaui ARIMA sebesar 93,84% dan SARIMA sebesar 94,378%. Hasil ini membuktikan bahwa LSTM lebih unggul dalam membangun model prediksi profit, meskipun memerlukan waktu pelatihan dan sumber daya komputasi yang lebih besar (Sirisha et al., 2022).

Penelitian kedua berjudul “*A Comparative Study of ARIMA, Prophet, and LSTM for Time series Prediction*” bertujuan untuk membandingkan tiga model peramalan deret waktu yang populer, yaitu ARIMA, *Facebook Prophet*, dan *Long Short-Term Memory* (LSTM). Ketiga model ini mewakili pendekatan yang berbeda: ARIMA sebagai model statistik tradisional, Prophet sebagai model analisis tren otomatis, dan LSTM sebagai model *deep learning* yang mampu mempelajari pola non-linear dan ketergantungan jangka panjang dalam data deret waktu. Studi ini menggunakan *dataset* keuangan dan mengevaluasi kinerja setiap model dengan metrik *Mean Absolute Error (MAE)*, *Root Mean Squared Error (RMSE)*, dan *Mean Absolute Percentage Error (MAPE)*. Hasil penelitian menunjukkan bahwa ARIMA unggul untuk pola sederhana dan data yang

stasioner dengan efisiensi komputasi tinggi, sementara Prophet lebih baik untuk data yang memiliki pola musiman dan dapat menangani data hilang secara otomatis. Namun, LSTM menghasilkan akurasi tertinggi dalam memprediksi pola kompleks dan fluktuasi jangka panjang, meskipun memerlukan sumber daya komputasi yang lebih besar. Selain itu, penelitian ini menekankan pentingnya *feature engineering* seperti penambahan fitur *lagged*, statistik *rolling*, dan variabel berbasis waktu karena terbukti meningkatkan performa semua model secara signifikan, terutama LSTM. Dengan demikian, penelitian ini memberikan panduan praktis dalam pemilihan model prediksi berdasarkan kompleksitas data, kebutuhan komputasi, serta tujuan peramalan, di mana LSTM terbukti paling unggul dalam menangkap dinamika pasar keuangan yang bersifat non-linear (Yadav, 2023).

Penelitian ketiga berjudul “*A Comparative Analysis of Machine Learning Models for Time series Forecasting in Finance*” membahas secara mendalam perbandingan berbagai model *machine learning* yang digunakan untuk peramalan deret waktu pada data keuangan, dengan fokus utama pada model ARIMA, LSTM, dan GRU. Tujuan utama penelitian ini adalah untuk menilai tingkat akurasi, efisiensi komputasi, serta kemampuan adaptasi dari masing-masing model dalam memprediksi pergerakan harga saham yang sangat fluktuatif. Model ARIMA, sebagai metode statistik klasik, telah lama digunakan dalam analisis deret waktu karena kesederhanaan dan interpretasinya yang mudah. Namun, model ini memiliki keterbatasan dalam menangkap pola data yang bersifat non-linear dan kompleks, yang sering ditemukan pada data finansial modern. Sebaliknya, model *deep learning* seperti LSTM (*Long Short-Term Memory*) dan GRU (*Gated Recurrent Unit*) mampu mempelajari ketergantungan jangka panjang serta variasi dinamis dalam data, menjadikannya lebih unggul dalam menangkap pola temporal dan tren yang tidak dapat ditangani oleh pendekatan konvensional. Hasil penelitian menunjukkan bahwa model LSTM dan GRU memberikan performa prediksi yang lebih akurat dan stabil dibandingkan ARIMA, terutama ketika diterapkan pada *Dataset* dengan fluktuasi tinggi dan struktur data yang kompleks. Model LSTM unggul dalam memahami urutan waktu dengan interval panjang, sedangkan GRU menawarkan efisiensi komputasi

yang lebih baik karena arsitekturnya yang lebih sederhana namun tetap efektif. Penelitian ini juga menyoroti bahwa penerapan model *deep learning* di bidang keuangan membawa potensi besar bagi pengambil keputusan, analis pasar, dan investor untuk meningkatkan ketepatan peramalan, mengoptimalkan strategi investasi, dan mengurangi risiko yang disebabkan oleh ketidakpastian pasar (Talib et al., 2024).

Penelitian keempat berjudul “*Forecasting Bank Profitability Using Deep Learning and Macroeconomic Indicators: A Comparative Model Study*” mengusulkan kerangka kerja berbasis *deep learning* untuk memprediksi profitabilitas bank dengan mengintegrasikan indikator makroekonomi dan data keuangan internal bank. Dalam studi ini, beberapa model seperti LSTM, GRU, *Transformer*, dan TCN dibandingkan dengan pendekatan tradisional seperti *Linear Regression*, *Random Forest*, dan *XGBoost* untuk mengukur kinerja prediksi menggunakan metrik RMSE, MAE, R^2 , dan *Directional Accuracy (DA)*. Hasil penelitian menunjukkan bahwa model *Transformer* memberikan performa terbaik dengan nilai R^2 sebesar 0.95 dan akurasi arah sebesar 91%, namun model LSTM terbukti paling andal secara keseluruhan karena kemampuannya menangkap ketergantungan jangka panjang dan pola musiman dalam data berurutan. Dengan data pelatihan dari kuartal pertama 2010 hingga kuartal keempat 2022 dan pengujian pada data 2023–2024, model berbasis *deep learning* terbukti jauh lebih unggul dibanding model statistik tradisional dan *ensemble tree-based* karena dapat memahami hubungan non-linear dan dinamika temporal antar variabel keuangan dan makroekonomi. LSTM menonjol dengan nilai RMSE dan MAE terendah, R^2 tertinggi, serta prediksi arah yang paling akurat. Keunggulan ini disebabkan oleh kemampuannya mengatasi masalah *vanishing gradient*, mengenali tren makro-finansial jangka panjang, serta memberikan hasil prediksi yang stabil pada berbagai kondisi ekonomi, baik saat krisis maupun masa pemulihan. Dari sisi implementasi, hasil tersebut menunjukkan bahwa LSTM dapat berfungsi sebagai sistem peringatan dini (*early warning system*) yang membantu lembaga keuangan dalam pengelolaan risiko dan perencanaan strategis berbasis data yang lebih akurat dan responsif terhadap dinamika ekonomi global (Sajal et al., 2025).

Penelitian kelima berjudul “*Profit Prediction Optimization Using Financial Accounting Information System by Optimized DLSTM*”. Penelitian ini bertujuan mengembangkan model *Deep Long Short-Term Memory* (DLSTM) yang dioptimasi menggunakan algoritma *Twin Adjustable Reinforced Chimp Optimization Algorithm* (TAR-CHOA) untuk meningkatkan akurasi prediksi profit berbasis data *time series* keuangan. Hasil penelitian menunjukkan bahwa model DLSTM-TAR-CHOA mampu menghasilkan tingkat kesalahan prediksi yang lebih rendah dibandingkan DLSTM standar dan beberapa metode pembandingan lainnya, dengan nilai MAPE pengujian sebesar 0,568% serta nilai R^2 sebesar 0,97. Temuan ini membuktikan bahwa LSTM yang dimodifikasi atau dioptimasi mampu menangkap pola jangka panjang pada data runtun waktu secara lebih akurat dan stabil. Penggunaan arsitektur LSTM sebagai model utama untuk peramalan data *time series* memperkuat bahwa LSTM merupakan metode yang efektif dalam meningkatkan akurasi prediksi pada data runtun waktu, khususnya dalam menangkap pola jangka panjang dan dinamika data yang kompleks, sehingga relevan sebagai dasar pemilihan model dalam penelitian ini (Tang et al., 2023).

Penelitian terakhir berjudul “*Modification of the LSTM Model in Time series Data Prediction*”, yang membahas modifikasi arsitektur *Long Short-Term Memory* (LSTM) untuk meningkatkan akurasi prediksi data *time series* pada harga saham. Modifikasi dilakukan melalui penyederhanaan hyperparameter, pengurangan jumlah layer dan neuron, penambahan dua dense layer, serta penggunaan optimizer Adam dan *loss function* MAE. Hasil penelitian menunjukkan bahwa LSTM setelah modifikasi menghasilkan nilai *Mean Absolute Percentage Error* (MAPE) yang lebih rendah dibandingkan LSTM standar dan metode pembandingan lainnya seperti RNN, CNN, WMA, SES, dan Facebook Prophet. Nilai MAPE pengujian yang diperoleh berada di bawah 2% pada seluruh data saham yang diuji, sehingga model LSTM modifikasi terbukti lebih stabil dan akurat dalam menangkap pola kompleks data *time series* serta meningkatkan kinerja peramalan secara signifikan (Sanjaya et al., 2025).

Ringkasan dari tujuh penelitian tersebut beserta kontribusinya disajikan pada Tabel 2.1 berikut:

Tabel 2. 1 Penelitian yang Relevan

No	Judul	Peneliti	Tahun	Hasil	Dataset	Kontribusi Penelitian	Perbandingan Model
1	<i>Profit Prediction Using ARIMA, SARIMA and LSTM Models in Time series Forecasting: A Comparison</i>	Uppala Meena Sirisha, Manjula C. Belavagi, Girija Attigeri	2022	Model LSTM menghasilkan tingkat akurasi prediksi profit tertinggi sebesar 97,01%, melampaui model ARIMA (93,84%) dan SARIMA (94,378%).	Dataset penjualan (<i>sales dataset</i>) dari efor excel.com dengan sekitar 1 juta transaksi penjualan selama periode 1972–2017, yang mencakup variabel tanggal pesanan, harga unit, jumlah unit terjual, total revenue, total cost, dan gross profit.	Menunjukkan bahwa model deep learning berbasis LSTM lebih efektif dibandingkan metode statistik tradisional dalam peramalan profit jangka panjang.	ARIMA dan SARIMA efektif untuk data linear dan stasioner, namun kurang mampu menangani pola non-linear yang kompleks. LSTM lebih adaptif karena mampu menangkap dependensi jangka panjang tanpa memerlukan transformasi stasioneritas.
2	<i>A Comparative Study of ARIMA, Prophet,</i>	Sandeep Yadav	2023	LSTM menghasilkan performa prediksi paling akurat dalam menangkap pola non-linear dan fluktuasi	Dataset yang digunakan berupa data harga saham simulasi (<i>synthetic stock price</i>	Memberikan panduan praktis dalam pemilihan model peramalan berdasarkan kompleksitas data serta	ARIMA unggul pada pola linear, Prophet baik untuk musiman, namun keduanya kurang optimal pada

No	Judul	Peneliti	Tahun	Hasil	Dataset	Kontribusi Penelitian	Perbandingan Model
	<i>and LSTM for Time series Prediction</i>			jangka panjang dibandingkan ARIMA dan Facebook Prophet. Selain itu, <i>feature engineering</i> seperti penambahan <i>lagged features</i> dan statistik rolling terbukti meningkatkan kinerja seluruh model, terutama LSTM.	<i>dataset</i>) dengan 500 titik data.	menunjukkan bahwa kombinasi LSTM dan <i>feature engineering</i> dapat meningkatkan akurasi prediksi secara signifikan.	pola fluktuatif kompleks. LSTM lebih fleksibel dalam mempelajari hubungan jangka panjang.
3	<i>A Comparative Analysis of Machine Learning Models for Time series Forecasting in Finance</i>	Noraini Abu Talib, Rafiq Ahmad, Siti Norbaya Noor	2024	Model <i>deep learning</i> , khususnya LSTM dan GRU, memberikan performa prediksi yang lebih akurat dan stabil dibandingkan ARIMA pada data keuangan yang fluktuatif. LSTM unggul dalam	Dataset yang digunakan yaitu data harga saham historis perusahaan-perusahaan yang terdaftar di New York Stock Exchange (NYSE) dan NASDAQ. Penelitian memanfaatkan data saham perusahaan besar	Memperkuat temuan bahwa model deep learning lebih adaptif terhadap dinamika pasar keuangan modern dibandingkan pendekatan statistik tradisional.	ARIMA kurang efektif pada data yang sangat volatil. GRU lebih efisien dalam komputasi, namun LSTM lebih kuat dalam menangkap dependensi temporal jangka panjang.

No	Judul	Peneliti	Tahun	Hasil	Dataset	Kontribusi Penelitian	Perbandingan Model
				menangkap ketergantungan jangka panjang, sedangkan GRU menawarkan efisiensi komputasi lebih baik.	seperti Apple Inc. (AAPL) dan Tesla Inc. (TSLA). Data yang digunakan mencakup informasi tanggal perdagangan, harga pembukaan, harga tertinggi, harga terendah, harga penutupan, dan volume transaksi.		
4	<i>Forecasting Bank Profitability Using Deep Learning and Macroeconomic Indicators: A</i>	Ashadujjaman Sajal, Md Sajedul Karim Chy, Sakib Salam Jamee, Mohamm	2025	LSTM menjadi model paling andal dalam memprediksi profitabilitas bank dengan nilai RMSE dan MAE terendah serta R^2 tertinggi dibandingkan model lainnya.	Dataset yang digunakan yaitu multi-sumber yang menggabungkan data keuangan bank dan indikator makroekonomi. Data keuangan bank mencakup laba bersih, pendapatan operasional, total aset, rasio loan-to-	Memperkenalkan kerangka kerja <i>deep learning</i> berbasis indikator makroekonomi untuk prediksi profitabilitas bank serta membuktikan bahwa LSTM dapat berfungsi sebagai sistem	Model statistik (Linear Regression, ARIMA) dan ensemble (Random Forest, XGBoost) memiliki keterbatasan dalam menangkap dependensi temporal jangka panjang sedangkan model deep learning

No	Judul	Peneliti	Tahun	Hasil	Dataset	Kontribusi Penelitian	Perbandingan Model
	<i>Comparative Model Study</i>	ad Nasir Uddin, Md Sayem Khan, Arun Kumar Gharami, Shaidul Islam Suhan, Mousumi Ahmed			deposit, rasio kredit bermasalah, return on equity, dan rasio kecukupan modal. Sementara itu, indikator makroekonomi meliputi pertumbuhan GDP, inflasi, suku bunga, nilai tukar, tingkat pengangguran, jumlah uang beredar (M2), indeks produksi industri, dan indeks kepercayaan konsumen. Data dikumpulkan secara triwulanan selama periode 2010 hingga 2024 dari sumber seperti Bankscope, Bloomberg,	peringatan dini dalam pengambilan keputusan strategis lembaga keuangan.	seperti LSTM, GRU, Transformer, dan TCN lebih efektif dalam memodelkan pola non-linear dan dinamika makro-finansial.

No	Judul	Peneliti	Tahun	Hasil	Dataset	Kontribusi Penelitian	Perbandingan Model
					World Bank, IMF, dan FRED.		
5	<i>Profit Prediction Optimization Using Financial Accounting Information System by Optimized DLSTM</i>	Wei Tang, Shuili Yang, Mohammad Khishe	2023	Model DLSTM yang dioptimasi dengan algoritma TAR-CHOA menghasilkan nilai MAPE sangat rendah sebesar 0,568% dan R^2 sebesar 0,97, lebih baik dibandingkan DLSTM standar dan metode pembanding lainnya. Model ini mampu menangkap pola jangka panjang data keuangan secara lebih akurat dan stabil.	Penelitian ini menggunakan dataset saham China dari Kaggle yang terdiri dari 2350 perusahaan dengan 15 fitur fundamental keuangan seperti profit margin, ROA, ROE, debt ratio, dan cash flow untuk membentuk dataset profit prediction.	Mengembangkan pendekatan optimasi arsitektur LSTM berbasis algoritma metaheuristik untuk meningkatkan akurasi prediksi profit berbasis data akuntansi.	DLSTM standar mampu memodelkan pola jangka panjang namun performanya dipengaruhi oleh pemilihan hyperparameter. Optimasi dengan TAR-CHOA secara signifikan menurunkan error dan meningkatkan stabilitas dibandingkan DLSTM standar maupun metode konvensional.
6	<i>Modification of the LSTM Model in</i>	Daniel Robi Sanjaya,	2025	Modifikasi arsitektur LSTM melalui penyederhanaan	Harga saham harian periode 2019–2024 yang diperoleh dari	Memberikan pendekatan praktis dalam	Keterbatasan RNN dan CNN dalam memodelkan

No	Judul	Peneliti	Tahun	Hasil	Dataset	Kontribusi Penelitian	Perbandingan Model
	<i>Time series Data Prediction</i>	Bayu Surarso, Tamo		hyperparameter, penambahan dense layer, dan penggunaan <i>loss function</i> MAE menghasilkan nilai MAPE di bawah 2% serta mengungguli LSTM standar dan model lain seperti RNN dan CNN. Model LSTM modifikasi terbukti lebih stabil dalam memprediksi data saham.	Yahoo Finance untuk empat emiten, yaitu PT Aneka Tambang Tbk (ANTM.JK), PT Bank Rakyat Indonesia (Persero) Tbk (BBRI.JK), PT Bank Central Asia Tbk (BBCA.JK), dan PT Bank Negara Indonesia (Persero) Tbk (BBNI.JK). Dataset awal memiliki parameter Date, Open, High, Low, Close, Adj Close, dan Volume, namun penelitian ini menggunakan Date sebagai indeks waktu dan Close sebagai variabel target	menyederhanakan arsitektur LSTM agar lebih efisien namun tetap akurat dalam peramalan data <i>time series</i> .	dependensi temporal jangka panjang mendorong dilakukannya modifikasi pada arsitektur LSTM. Melalui penyederhanaan hyperparameter dan penyesuaian struktur jaringan, model LSTM yang dimodifikasi mampu meningkatkan efisiensi dan stabilitas pelatihan, sekaligus mempertahankan bahkan meningkatkan akurasi prediksi.

2.2 Landasan Teori

Landasan teori dalam penelitian ini berisi kumpulan teori yang relevan dengan topik yang dikaji. Teori-teori tersebut disajikan kembali melalui parafrase untuk mempermudah pemahaman serta menyampaikan informasi secara lebih jelas, sistematis, dan terstruktur.

2.2.1 Laba Bersih

Profitabilitas merupakan hasil akhir bersih dari berbagai kebijakan dan keputusan manajemen yang mencerminkan efektivitas pengelolaan perusahaan secara menyeluruh. Bank dengan profitabilitas tinggi dan pertumbuhan laba yang konsisten menunjukkan kinerja yang baik, yang pada akhirnya memberikan dampak positif terhadap stabilitas dan nilai perusahaan (Aulia & Avriyanti, 2024). Salah satu indikator utama dalam mengukur profitabilitas adalah laba bersih, yang menggambarkan kemampuan perusahaan menghasilkan keuntungan setelah dikurangi seluruh biaya operasional, beban bunga, depresiasi, dan pajak penghasilan.

Dalam konteks spesifik Bank Maluku, laba bersih dibentuk oleh interaksi kompleks antara beberapa komponen utama yang dirumuskan sebagai:

$$\text{Laba Bersih} = [(NII + PNO) - BOP] - \text{Pajak} \quad (2.1)$$

Komponen pertama adalah *Net Interest Income* (NII) yang bersumber dari selisih pendapatan bunga kredit dengan beban bunga simpanan, di mana kinerjanya sangat dipengaruhi oleh saldo kredit, tingkat suku bunga yang mengikuti BI Rate, serta efisiensi penyaluran dana yang tercermin dalam *Loan to Deposit Ratio* (LDR). Selain bunga, laba bersih juga didorong oleh Pendapatan Non Operasional (PNO) atau *fee-based income* yang dihasilkan dari frekuensi transaksi nasabah. Oleh karena itu, variabel Tabungan TRX, Deposito TRX, dan Kartu Kredit TRX merupakan representasi penting dari potensi peningkatan pendapatan non-bunga pada Bank Maluku. Pencapaian laba bersih tidak terlepas dari beban yang harus ditanggung bank, khususnya Beban Operasional (BOP). Selain itu, tingkat risiko kredit yang tercermin dalam rasio *Non-Performing Loan* (NPL) turut memengaruhi laba, karena kenaikan NPL mengharuskan bank membentuk cadangan kerugian penurunan nilai yang lebih besar sehingga dapat mengurangi keuntungan yang

diperoleh. Di samping faktor internal, kondisi makroekonomi seperti BI Rate dan inflasi juga memberikan pengaruh signifikan. Perubahan BI Rate berdampak pada kebijakan penetapan suku bunga kredit dan simpanan, sedangkan inflasi dapat meningkatkan biaya operasional serta memengaruhi kemampuan debitur dalam memenuhi kewajibannya.

2.2.2 Kinerja Keuangan Bank

Kinerja keuangan bank merupakan gambaran kondisi keuangan bank pada suatu periode tertentu yang mencerminkan prestasi kerja dalam mengelola sumber daya keuangannya. Penilaian kinerja keuangan bank sangat penting karena menunjukkan tingkat kesehatan bank yang memperlihatkan kondisi dan kemampuan bank dalam menjalankan operasionalnya secara efektif dan efisien. Kinerja keuangan bank dapat diukur menggunakan berbagai rasio keuangan yang tergabung dalam metode CAMEL (*Capital, Assets Quality, Management, Earning, Liquidity*) yang merupakan indikator standar dalam menilai tingkat kesehatan bank (Pattiruhu, 2020).

Rasio *Capital Adequacy Ratio* (CAR) merupakan indikator yang menunjukkan kecukupan modal yang dimiliki oleh suatu bank untuk mengatasi risiko saat ini dan mengantisipasi risiko di masa depan. CAR yang tinggi menunjukkan bahwa bank memiliki modal yang cukup untuk menyerap kerugian dan melindungi dana nasabah. Rasio ini termasuk dalam indikator CAMEL yang menjadi penilai tingkat kesehatan bank di mana tingkat kesehatan bank memperlihatkan kondisi kinerja keuangan suatu bank yang diporsikan melalui *Return on Assets* (ROA) (Pattiruhu, 2020).

Non-Performing Loan (NPL) atau kredit bermasalah merupakan rasio yang mengukur kualitas aset produktif bank dengan membandingkan jumlah kredit bermasalah terhadap total kredit yang disalurkan. NPL yang rendah menunjukkan bahwa bank memiliki kualitas kredit yang baik dan manajemen risiko yang efektif. *Loan to Deposit Ratio* (LDR) mengukur kemampuan bank dalam menyalurkan kredit dari dana pihak ketiga yang dihimpun, yang mencerminkan fungsi intermediasi bank. Variabel CAR, NPL, dan LDR merupakan indikator penting dalam CAMEL yang berpengaruh signifikan terhadap

profitabilitas bank yang diukur dengan ROA, di mana sekitar 76,9% variasi ROA dapat dijelaskan oleh ketiga variabel tersebut (Taufiqur Rahman et al., 2022).

Return on Assets (ROA) dan *Return on Equity* (ROE) merupakan rasio profitabilitas utama dalam mengukur kinerja keuangan bank. ROA mengukur kemampuan bank dalam menghasilkan laba dari pengelolaan total aset yang dimiliki, sedangkan ROE mengukur tingkat pengembalian atas modal sendiri atau ekuitas yang diinvestasikan pemegang saham. Kedua rasio ini menjadi indikator penting bagi investor dan regulator dalam menilai efektivitas manajemen bank dalam menghasilkan keuntungan (Nugroho & Yudiantoro, 2022).

Parameter yang digunakan untuk membandingkan kinerja keuangan perbankan adalah dengan menggunakan metode CAMEL yang terdiri dari rasio *Capital Asset Ratio* (CAR), *Non-Performing Financing* (NPF) atau *Non-Performing Loan* (NPL), *Return on Asset* (ROA), dan rasio keuangan lainnya yang secara komprehensif menggambarkan kondisi kesehatan dan kinerja keuangan bank (Banjarnahor, 2022).

2.2.3 Aktivitas Transaksi Perbankan

Aktivitas transaksi perbankan merupakan kegiatan operasional utama bank yang meliputi seluruh proses perpindahan dana, pencatatan keuangan, dan pemberian layanan jasa perbankan kepada nasabah. Aktivitas transaksi perbankan mencerminkan fungsi intermediasi keuangan bank dalam menghimpun dana dari masyarakat dan menyalurkannya kembali dalam bentuk kredit atau pembiayaan. Volume dan nilai aktivitas transaksi perbankan menjadi indikator penting dalam mengukur tingkat efektivitas operasional bank dan kontribusinya terhadap perekonomian secara makro.

Aktivitas transaksi perbankan memiliki peran penting dalam mempengaruhi profitabilitas bank. Kegiatan penghimpunan dana melalui tabungan dan deposito menjadi salah satu aktivitas utama bank dalam memperoleh dana murah. Semakin besar dana yang dihimpun, semakin besar pula potensi bank untuk menyalurkan kredit dan memperoleh pendapatan bunga, sehingga dapat meningkatkan laba bersih bank (Dewanti Eston et al., 2024). Selanjutnya, pemberian kredit juga merupakan aktivitas utama yang menghasilkan

keuntungan, di mana keberhasilan penyaluran kredit yang tepat sasaran akan meningkatkan pendapatan bunga dan *fee-based income*, sehingga berkontribusi positif terhadap profitabilitas bank (Dewanti Eston et al., 2024).

2.2.4 Forecasting

Forecasting atau peramalan merupakan teknik analisis yang digunakan untuk memperkirakan nilai atau kejadian di masa depan berdasarkan pola data historis (Muhtar et al., 2024). Peramalan banyak diterapkan dalam berbagai bidang, seperti ekonomi, keuangan, industri, dan manajemen, untuk membantu pengambilan keputusan yang lebih tepat dan terukur. Peramalan dapat digunakan untuk menganalisis pola dari data masa lalu dalam memprediksi kebutuhan yang diperlukan di masa yang akan datang, sehingga dapat memberikan proyeksi permintaan yang sistematis (Ningrum & Yonanda, 2016).

2.2.5 Long Short-Term Memory

Long Short-Term Memory (LSTM) adalah jenis jaringan saraf tiruan (*neural network*) berulang yang dirancang khusus untuk data deret waktu (*time series*), karena kemampuannya dalam menangkap ketergantungan jangka panjang (*long-term dependencies*) pada urutan data. Salah satu keunggulan LSTM dibanding RNN biasa adalah kemampuannya mengatasi masalah *vanishing gradient*, sehingga model tetap bisa belajar informasi dari langkah waktu yang jauh di masa lalu tanpa kehilangan sinyal penting (seperti dijelaskan dalam jurnal “*Journal for Research in Applied Sciences and Biotechnology*” yang menyatakan bahwa “*LSTM Networks overcame the vanishing gradient issue with memory cells together with gating mechanisms which allows effective long-term dependency processing*” yang artinya LSTM merupakan Jaringan mengatasi masalah gradien yang menghilang dengan sel memori bersama dengan mekanisme *gating* yang memungkinkan pemrosesan ketergantungan jangka panjang yang efektif (Bhatia & Bhatt, 2024).

Long-Short Term Memory (LSTM) merupakan tipe spesial dari neural network, dimana termasuk bagian dari *Recurrent Neural Network* (RNN) (Wisyaladin et al., 2020). LSTM dirancang untuk mengatasi permasalahan *vanishing gradient*, yaitu kondisi ketika

jaringan RNN kehilangan kemampuan untuk mengingat informasi jangka panjang karena gradien menjadi sangat kecil selama proses pelatihan. Secara arsitektur, LSTM memiliki struktur yang hampir mirip dengan RNN, namun perbedaannya terletak pada proses *hidden state* (Suyudi et al., 2019).

Proses *hidden state* pada LSTM terdiri dari empat gerbang utama (*4 gates*), yaitu *Forget Gate*, *Input Gate*, *Cell State*, dan *Output Gate* (Cahyani et al., 2023). Keempat gerbang ini berfungsi untuk mengatur informasi yang disimpan, diperbarui, dan dikeluarkan dari memori internal jaringan.

1. *Forget Gate*

Forget Gate merupakan gerbang pertama yang menentukan informasi apa yang perlu dilupakan dari *cell state* sebelumnya. Gerbang ini menggunakan fungsi *aktivasi sigmoid* untuk menghasilkan nilai antara 0 hingga 1, yang menunjukkan seberapa besar informasi dipertahankan atau dihapus. Secara matematis, *forget gate* dirumuskan sebagai:

$$f_t = \sigma (W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2.2)$$

Keterangan:

σ : fungsi sigmoid

W_f : bobot dari *forget gate*

h_{t-1} : *hidden state* sebelumnya

x_t : input saat waktu ke-t

b_f : bias *forget gate*

dengan:

Fungsi sigmoid σ

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2.3)$$

di mana f_t adalah forget gate, σ adalah fungsi aktivasi sigmoid, W_f bobot, h_{t-1} nilai *hidden state* sebelumnya, x_t masukan saat ini, dan b_f adalah bias.

Keterangan:

x : input fungsi sigmoid

e^{-x} : fungsi eksponensial negatif dari x

2. *Input Gate*

Input Gate menentukan informasi baru apa yang akan ditambahkan ke *cell state*.

Sama seperti *forget gate*, gerbang ini menggunakan fungsi aktivasi sigmoid untuk mengontrol seberapa besar informasi baru disimpan (Cahyani et al., 2023).

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2.4)$$

Keterangan:

σ : fungsi sigmoid

W_i : bobot dari *input gate*

h_{t-1} : *hidden state* sebelumnya

x_t : input saat waktu ke- t

b_i : bias *input gate*

3. *Call State* (Memori Utama)

Setelah *input gate* dihitung, jaringan menghitung nilai kandidat *cell state* baru menggunakan fungsi aktivasi *tanh*, yang akan menghasilkan nilai dalam rentang -1 hingga 1. Nilai ini mewakili informasi baru yang mungkin ditambahkan ke *cell state* (Cahyani et al., 2023).

$$\widetilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (2.5)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.6)$$

Keterangan:

$\tanh$: fungsi tanh

W_c : bobot (weight) pada kandidat *cell state*

h_{t-1} : *hidden state* pada waktu sebelumnya ($t-1$)

x_t : input pada waktu ke- t

b_c : bias kandidat *cell state*

4. Kandidat *Cell State* Baru

Nilai *cell state* diperbarui dengan menggabungkan hasil dari *forget gate* dan *input gate*. Proses ini menjaga keseimbangan antara informasi lama dan baru sehingga model dapat menyimpan konteks jangka panjang dengan stabil (Cahyani et al., 2023).

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (2.7)$$

Keterangan:

f_t : nilai forget gate pada waktu ke-t

C_{t-1} : cell state pada waktu sebelumnya (t-1)

i_t : nilai input gate pada waktu ke-t

$\tilde{C}_t$: kandidat cell state baru (candidate cell state)

5. *Output Gate* dan *Hidden State* Baru

Output gate mengatur informasi apa yang akan dikeluarkan sebagai hidden state pada langkah waktu berikutnya. Fungsi aktivasi sigmoid digunakan untuk menentukan proporsi informasi yang diteruskan, sedangkan *tanh* digunakan untuk menormalisasi nilai *cell state* (Cahyani et al., 2023).

Output Gate

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (2.8)$$

Keterangan:

σ : fungsi aktivasi sigmoid

W_o : bobot (weight) output gate

h_{t-1} : hidden state pada waktu sebelumnya (t-1)

x_t : input pada waktu ke-t

b_o : bias output gate

Hidden State Baru

$$h_t = o_t \times \tanh(C_t) \quad (2.9)$$

Keterangan:


h_t : hidden state pada waktu ke-t

o_t : output gate pada waktu ke-t

$\tanh$: fungsi $\tanh$

C_t : cell state pada waktu ke- t

Arsitektur LSTM dapat dilihat pada gambar 2.1, dibawah ini:



Gambar 2. 1 Arsitektur LSTM

Sumber : [Medium](#)

2.2.6 Cross-Industry Standard Process for Data Mining (CRISP-DM)

CRISP-DM adalah pendekatan yang umum digunakan oleh para ahli untuk menyelesaikan masalah menggunakan proses data mining (Yanti et al., 2024). Metodologi ini dikembangkan untuk membantu peneliti atau analis data dalam menjalankan proyek data mining secara sistematis, terstruktur, dan terukur. CRISP-DM juga menyediakan standar proses data mining sebagai strategi pemecahan masalah secara umum, baik dalam konteks bisnis maupun unit penelitian (Rifai et al., 2019). Kelebihan dari metodologi CRISP-DM antara lain adalah de-facto dan dapat dipercaya, mudah digunakan dan terstruktur, awalan yang benar, mengurangi biaya dan waktu, serta tahap deployment tidak wajib (Rianti et al., 2023). Tujuan utama CRISP-DM adalah memastikan bahwa proses pengembangan model analisis data tidak hanya berfokus pada pembuatan model, tetapi juga memahami kebutuhan penelitian, karakteristik data, serta interpretasi hasil yang diperoleh. Selain itu, CRISP-DM dianggap mampu menggabungkan berbagai keterampilan di bidang Teknologi Informasi (TI) (Siswipraptini et al., 2023), sehingga mendukung proses penelitian berbasis data secara menyeluruh dan terintegrasi.



Gambar 2. 2 CRISP-DM

Sumber : [Dicoding](#)

Pada Gambar 2.2, diperlihatkan tahapan utama CRISP-DM yang terdiri dari enam tahapan utama, yaitu *Business Understanding*, *Data Understanding*, *Data Preparation*, *Modeling*, *Evaluation*, dan *Deployment*.

1. *Bussines Understanding*

Tahap ini merupakan proses memahami tujuan penelitian atau permasalahan yang ingin diselesaikan. Pada tahap ini membutuhkan pengetahuan dari objek bisnis, bagaimana membangun atau mendapatkan data, dan bagaimana untuk mencocokkan tujuan pemodelan untuk tujuan bisnis sehingga model terbaik dapat dibangun (Asri et al., 2023).

2. *Data Understanding*

Tahap ini berfokus pada pengumpulan dan eksplorasi data awal. Aktivitas yang dilakukan meliputi identifikasi sumber data, analisis karakteristik data, pengecekan kelengkapan data, serta menemukan pola awal atau potensi masalah dalam data.

3. *Data Preparation*

Tahap persiapan data mencakup proses pembersihan data (*data cleaning*), penanganan data hilang, normalisasi atau standarisasi data, serta transformasi data ke format yang sesuai untuk proses pelatihan model.

4. *Modeling*

Pada tahap ini dilakukan pemilihan algoritma yang akan digunakan serta proses pelatihan model. Dalam penelitian berbasis *deep learning*, tahap ini mencakup perancangan arsitektur model, penentuan parameter, serta proses *training data*.

5. *Evaluation*

Tahap evaluasi bertujuan menilai performa model yang telah dibangun. Hasil model diuji menggunakan data uji, kemudian diukur menggunakan metrik evaluasi.


6. *Deployment*

Tahap terakhir adalah penerapan model ke dalam sistem atau penyajian hasil penelitian. Dalam konteks skripsi, *deployment* dapat berupa implementasi model dalam aplikasi atau penyusunan kesimpulan dan rekomendasi dari hasil penelitian.

2.2.7 Diagram *Fishbone*

Diagram *Fishbone* atau yang dikenal juga sebagai Diagram *Ishikawa* merupakan salah satu alat analisis yang digunakan untuk mengidentifikasi dan menganalisis berbagai penyebab yang berpotensi menimbulkan suatu permasalahan tertentu. Diagram ini dapat membantu melakukan uraian apa proses yang sebenarnya terjadi, seperti uraian memecah proses menjadi sejumlah kategori yang berkaitan dengan proses, kegiatan aktornya, sisi material, kinerja mesin dan aliran prosedur, pelaksanaan kebijakan (Malabay, 2016a).

Tujuan utama penggunaan *fishbone* diagram adalah untuk mengidentifikasi akar penyebab dari suatu permasalahan. Dalam konteks penelitian, *fishbone* diagram membantu peneliti dalam mengelompokkan faktor-faktor yang memengaruhi suatu masalah ke dalam kategori tertentu, sehingga memudahkan proses analisis dan pengambilan keputusan.



Gambar 2. 3 *Fishbone*

Sumber : [Ishikawa diagram](#)

Pada gambar 2.3 diatas dapat dilihat *Fishbone* diagram terdiri dari beberapa komponen utama, yaitu:

1. Masalah Utama (*Effect*)

Masalah utama merupakan fokus analisis yang ditempatkan pada bagian kepala ikan. Masalah ini biasanya dirumuskan secara spesifik dan jelas agar analisis penyebab dapat dilakukan secara tepat sasaran.

2. Tulang Utama (*Major Categories*)

Tulang utama merupakan kategori besar penyebab yang berkontribusi terhadap terjadinya masalah. Kategori ini sering dikelompokkan menggunakan pendekatan 6M, yaitu *Man*, *Machine*, *Method*, *Material*, *Measurement*, dan *Environment* (Malabay, 2016a).

a. *Man*

Sumber daya manusia berperan penting dalam mendukung proses kerja dan perlu dikelola agar menghasilkan kinerja yang positif.

b. *Machine*

Mesin merupakan alat yang digunakan untuk menghasilkan produk atau layanan.

c. *Method*

Metode kerja merupakan prosedur yang digunakan untuk menjalankan proses secara efektif dan efisien.

d. *Material*

Material adalah bahan yang diperlukan agar proses operasional dapat berjalan secara berkelanjutan.

e. *Measurement*

Measurement adakah alat dan metode pengukuran yang digunakan.

f. *Environmet*

Lingkungan mencakup kondisi kerja, suhu, dan kebisingan.

3. Tulang Minor (*Sub-Categories*)

Tulang minor merupakan penyebab yang lebih spesifik dan detail yang berada di bawah setiap kategori utama. Tulang minor ini menggambarkan faktor-faktor rinci yang secara langsung maupun tidak langsung memengaruhi terjadinya masalah utama.

2.2.8 Evaluasi Kinerja Model

Proses evaluasi dilakukan dengan membandingkan nilai hasil prediksi model terhadap data aktual. Evaluasi model dilakukan untuk mengevaluasi efektivitas dan perfoma model sehingga dapat diketahui tingkat kesalahan (error) yang dihasilkan oleh model (Sitorus et al., 2025). Evaluasi dilakukan setelah proses pelatihan (*training*) dan pengujian (*testing*) selesai, dengan membandingkan hasil prediksi model terhadap data aktual.

1. *Root Mean Square Error (RMSE)*

RMSE digunakan untuk mengukur rata-rata kesalahan kuadrat antara nilai prediksi dan nilai aktual. Nilai RMSE yang kecil menunjukkan kesalahan prediksi yang rendah (Terven et al., 2025).

$$RMSE = \sqrt{\left((1/n) \sum_{i=1}^n (y_i - \hat{y}_i)^2 \right)} \quad (2.10)$$

2. Mean Absolute Error (MAE)

MAE menunjukkan rata-rata dari selisih absolut antara nilai prediksi dan nilai aktual. Semakin kecil nilai MAE, semakin baik performa model (Terven et al., 2025).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2.11)$$

3. Mean Absolute Percentage Error (MAPE)

MAPE digunakan untuk mengukur tingkat kesalahan dalam bentuk persentase, sehingga memudahkan interpretasi dalam konteks bisnis atau ekonomi (Terven et al., 2025).

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (2.12)$$

Selanjutnya, nilai MAPE dapat diinterpretasikan untuk menilai tingkat akurasi model peramalan. Semakin kecil nilai MAPE yang dihasilkan, maka semakin baik kinerja model dalam memprediksi data aktual. Klasifikasi tingkat akurasi model berdasarkan nilai MAPE dapat dilihat pada Tabel 2.2 berikut.

Tabel 2. 2 Tingkat Akurasi Model MAPE

<i>MAPE Value Model Accuracy</i>	<i>MAPE Value Model Accuracy</i>
<i>Less than 10%</i>	<i>Highly Accurate</i>
<i>11% to 20%</i>	<i>Good</i>
<i>21% to 50%</i>	<i>Reasonable</i>

<i>More than 51%</i>	<i>Inaccurate</i>
----------------------	-------------------

Sumber : (Kasemset et al., 2014)

4. *Coefficient of Determination (R² Score)*

R² digunakan untuk mengukur seberapa baik model dapat menjelaskan variasi dalam data aktual. Nilai R² yang mendekati 1 menandakan bahwa model mampu memprediksi dengan akurasi tinggi (Terven et al., 2025).

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2.13)$$

Keterangan

y_i : Nilai Aktual

$\hat{y}_i$: Nilai Prediksi

$\bar{y}$: Rata – Rata Nilai Aktual

n : Jumlah Data

2.2.9 Adaptive Moment Estimation (ADAM) dan Adaptive Moment Estimation with decoupled Weight decay (AdamW)

Adaptive Moment Estimation (Adam) merupakan salah satu algoritma optimisasi yang paling banyak digunakan dalam pelatihan model *deep learning*. Adam dirancang dengan menggabungkan keunggulan dua optimizer sebelumnya, yaitu AdaGrad yang dikenal efektif dalam menangani gradien jarang (*sparse gradients*) karena menyesuaikan *learning rate* dan RMSProp menggunakan rata-rata bergerak dari kuadrat gradien, sehingga cocok digunakan pada lingkungan pembelajaran yang bersifat online dan data non-stasioner (Kingma & Ba, 2017). Optimizer ini menghitung estimasi momen pertama (rata-rata gradien) dan momen kedua (rata-rata kuadrat gradien) untuk setiap parameter model, sehingga nilai *learning rate* dapat disesuaikan secara adaptif pada masing-masing parameter. Namun demikian, Adam masih memiliki keterbatasan dalam penerapan regularisasi, khususnya pada mekanisme *weight decay* (Loshchilov & Hutter, 2019). Oleh

karena itu, diperkenalkan optimizer AdamW (*Adaptive Moment Estimation with decoupled Weight Decay*) sebagai pengembangan dari Adam.


AdamW (*Adaptive Moment Estimation with decoupled Weight Decay*) merupakan pengembangan dari optimizer Adam yang banyak digunakan dalam pelatihan model *deep learning*. Optimizer ini diperkenalkan untuk mengatasi kelemahan Adam dalam penerapan regularisasi, khususnya pada mekanisme *weight decay*. Dalam riset “*Decoupled Weight Decay Regularization*” oleh (Loshchilov & Hutter, 2019) menyatakan bahwa “*Our version of Adam with discrete weight decay yields significantly better generalization performance than the common implementation of Adam*” yang berarti versi Adam yang mereka kembangkan dengan mekanisme *decoupled weight decay* menghasilkan kinerja generalisasi yang secara signifikan lebih baik dibandingkan dengan implementasi Adam konvensional. Dengan demikian, AdamW mampu meningkatkan kemampuan generalisasi model serta mengurangi risiko *overfitting*, terutama pada pelatihan model *deep learning* yang kompleks (Loshchilov & Hutter, 2019).

2.2.10 Koreksi Linear

Kalibrasi merupakan proses penyesuaian hasil prediksi model agar lebih sesuai dengan data aktual yang diamati. Dalam konteks pemodelan dan peramalan deret waktu, kalibrasi digunakan untuk mengurangi bias sistematis yang sering muncul pada hasil prediksi, seperti kecenderungan model menghasilkan nilai yang terlalu tinggi atau terlalu rendah dibandingkan data sebenarnya. Oleh karena itu, kalibrasi menjadi tahap penting dalam memastikan bahwa model tidak hanya akurat pada data latih, tetapi juga memiliki kesesuaian yang baik ketika diterapkan pada data uji.

Kalibrasi linear sering digunakan sebagai tahap *post-processing* karena tidak mengubah arsitektur maupun proses pelatihan model utama. Model yang terkalibrasi dengan baik adalah model yang mampu meminimalkan nilai residual, yaitu selisih antara hasil prediksi dan data aktual. Kondisi ini setara dengan menyatakan bahwa model memiliki tingkat kesesuaian yang baik terhadap data uji, sehingga hasil prediksi yang dihasilkan dapat merepresentasikan pola dan karakteristik data secara lebih akurat (Huang et al., 2021).

2.2.11 Deep Learning



Gambar 2. 4 Deep Learning

Sumber : [Builtin Deep Learning](#)

Deep learning adalah cabang dari *machine learning* yang menggunakan jaringan saraf tiruan dengan banyak lapisan (*deep neural networks*) untuk mempelajari representasi fitur yang kompleks dan hierarkis dari data. *Deep learning* memungkinkan model untuk melakukan *feature learning* secara otomatis, di mana lapisan-lapisan tersembunyi akan mengubah *input* mentah menjadi representasi yang semakin abstrak dan relevan untuk tugas prediksi atau klasifikasi. Keunggulan utama dari *deep learning* dibanding teknik tradisional adalah kemampuannya menangani data yang besar dan kompleks, serta menemukan pola non-linier yang sulit diidentifikasi secara manual. Dalam konteks keuangan dan perbankan, *deep learning* telah diterapkan untuk memprediksi harga aset, mendeteksi penipuan, mengukur risiko kredit, serta memodelkan kinerja keuangan bank dalam penelitian yang berjudul “*Deep Learning in Finance*” mendemonstrasikan bahwa penerapan *deep learning* mampu mengeksplorasi interaksi kompleks dalam data keuangan yang tidak dapat ditangkap oleh model ekonomi standar (Heaton et al., 2018). Python mendukung paradigma pemrograman prosedural dan berorientasi objek, serta dilengkapi dengan pustaka standar yang lengkap sehingga memudahkan pengguna dalam mengimplementasikan berbagai fungsi tanpa menulis kode dari awal.

2.2.12 Phyton

Python merupakan bahasa pemrograman berbasis teks yang memungkinkan peneliti menuliskan instruksi komputer menggunakan kombinasi kata kunci, angka, dan

simbol. Instruksi tersebut diketik melalui perangkat input dan dieksekusi oleh sistem untuk menghasilkan keluaran sesuai dengan tujuan yang ditetapkan. Python dikenal sebagai salah satu bahasa pemrograman yang paling banyak digunakan secara global. Bahasa ini pertama kali diperkenalkan pada awal tahun 1990-an dan hingga saat ini telah dimanfaatkan secara luas dalam pengembangan berbagai aplikasi, permainan, serta situs web (Santoso, 2022). Python mendukung paradigma pemrograman prosedural dan berorientasi objek, serta dilengkapi dengan pustaka standar yang lengkap sehingga memudahkan pengguna dalam mengimplementasikan berbagai fungsi tanpa menulis kode dari awal (Mulana, 2024).


Dalam bidang komputasi ilmiah dan analisis data, Python memiliki peran penting karena didukung oleh berbagai pustaka (*library*) yang dirancang khusus untuk pengolahan data dan pengembangan model kecerdasan buatan. Beberapa pustaka yang umum digunakan antara lain NumPy untuk komputasi numerik, Pandas untuk manipulasi dan analisis data, Matplotlib untuk visualisasi data, serta Scikit-learn untuk implementasi algoritma *machine learning*. Selain itu, TensorFlow dan Keras digunakan untuk membangun model *deep learning*. Keberadaan pustaka-pustaka tersebut menjadikan Python sebagai bahasa yang efektif dan efisien dalam proses pre-processing data, pelatihan model, serta evaluasi performa sistem prediksi.

2.2.13 *Flow Chart*

Flowchart merupakan representasi grafis yang menggambarkan langkah-langkah dan urutan suatu prosedur dalam program atau sistem. *Flowchart* berfungsi sebagai alat bantu dalam proses analisis, perancangan, dan pengkodean, dengan memecah permasalahan ke dalam bagian-bagian yang lebih kecil sehingga lebih mudah dipahami dan dioperasikan. Selain itu, *flowchart* juga mempermudah proses evaluasi sistem pada tahap pengembangan selanjutnya. Secara umum, *flowchart* dapat diartikan sebagai diagram yang menggunakan simbol-simbol grafis untuk menunjukkan aliran proses, di mana setiap simbol merepresentasikan tahapan atau urutan aktivitas dari suatu prosedur yang memiliki fungsi tertentu. Penggunaan *flowchart* bertujuan untuk memberikan gambaran yang jelas mengenai suatu proses agar mudah dipahami, serta membantu melihat

keterkaitan antar langkah dari awal hingga akhir proses. Dengan adanya *flowchart*, rangkaian proses dapat disederhanakan sehingga memudahkan pengguna dalam memahami informasi yang dibutuhkan.


Dalam pembuatannya, *flowchart* digambarkan dari arah atas ke bawah dan dari kiri ke kanan. Setiap aktivitas yang ditampilkan harus dapat dipahami oleh pengguna, memiliki penjelasan awal dan akhir yang jelas, serta tahapan proses yang diuraikan menggunakan deskripsi kata kerja. Urutan langkah harus disusun secara tepat sesuai alur kegiatan yang berjalan, dengan ruang lingkup proses ditelusuri secara menyeluruh. Selain itu, disarankan menggunakan simbol-simbol *flowchart* yang baku agar diagram mudah dibaca dan dipahami (Malabay, 2016b). Simbol – simbol *Flowchart* yang biasa dipakai disajikan pada gambar 2.5 Berikut:

	Flow Simbol yang digunakan untuk menggabungkan antara simbol yang satu dengan simbol yang lain. Simbol ini disebut juga dengan Connecting Line.		Input/output Simbol yang menyatakan proses input atau output tanpa tergantung peralatan.
	On-Page Reference Simbol untuk keluar - masuk atau penyambungan proses dalam lembar kerja yang sama.		Manual Operation Simbol yang menyatakan suatu proses yang tidak dilakukan oleh komputer.
	Off-Page Reference Simbol untuk keluar - masuk atau penyambungan proses dalam lembar kerja yang berbeda.		Document Simbol yang menyatakan bahwa input berasal dari dokumen dalam bentuk fisik, atau output yang perlu dicetak.
	Terminator Simbol yang menyatakan awal atau akhir suatu program.		Predefine Proses Simbol untuk pelaksanaan suatu bagian (sub-program) atau prosedur.
	Process Simbol yang menyatakan suatu proses yang dilakukan komputer.		Display Simbol yang menyatakan peralatan output yang digunakan.
	Decision Simbol yang menunjukan kondisi tertentu yang akan menghasilkan dua kemungkinan jawaban, yaitu ya dan tidak.		Preparation Simbol yang menyatakan penyediaan tempat penyimpanan suatu pengolahan untuk memberikan nilai awal.

Gambar 2. 5 *Flow Chart*

Sumber : [Medium](#)

2.3 Kerangka Pemikiran



Gambar 2. 6 Kerangka Pemikiran

1. *Proposed Method*

Penelitian ini menggunakan *dataset* yang berisi aktivitas transaksi di bank maluku malut cabang Jakarta (Seperti saldo tabungan , saldo deposito, laba bersih, dsb.) pada periode 2022 – 2024. Dataset diproses menggunakan *Long Short-Term Memory* (LSTM) untuk melakukan prediksi. LSTM dipilih karena memiliki kemampuan dalam mempelajari pola urutan waktu.

2. *Indicators*

Pada arsitektur LSTM indikator yang digunakan terdiri dari 4 komponen utama yaitu *forget gate*, *input gate*, *cell gate*, dan juga *output gate*. Keempat indikator ini bekerja bersama untuk mengatur aliran informasi di dalam sel LSTM, yaitu menentukan informasi mana yang perlu diingat, diperbaharui, atau dibuang, sehingga model mampu menangkap pola data pada data deret waktu.

3. *Objectives*

Model Performance atau kinerja model dalam melakukan *Prediction Accuracy*. Tujuan utama penelitian ini adalah untuk mengukur seberapa baik model LSTM mampu memprediksi laba bersih bank berdasarkan variabel transaksi bank. Dengan

demikian, model yang dikembangkan diharapkan dapat memberikan hasil prediksi yang akurat dan relevan dalam mendukung analisis kinerja keuangan perbankan.

4. *Measurment*

Evaluasi model dilakukan menggunakan metrik, yaitu *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), *Mean Absolute Percentage Error* (MAPE), dan *Coefficient of Determination* (R^2). Keempat ukuran ini digunakan untuk menilai ketetapan dan konsistensi hasil prediksi. Nilai RMSE dan MAE yang kecil menunjukkan kesalahan prediksi yang rendah, MAPE memberikan interpretasi kesalahan dalam bentuk persentase, sedangkan nilai R^2 yang mendekati menandakan bahwa model mampu menjelaskan variasi data aktual dengan sangat baik.