

# Pengelolaan Portofolio Investasi dengan Penerapan LSTM pada Sektor Strategis Indonesia dengan Evaluasi Sharpe Ratio dan Mean Variance

1<sup>st</sup> Daniel Pratama Manurung  
Fakultas Informatika  
Universitas Telkom  
Bandung, Indonesia

[danielman@student.telkomuniversity.ac.id](mailto:danielman@student.telkomuniversity.ac.id)

2<sup>nd</sup> Irma Palupi  
Fakultas Informatika  
Universitas Telkom  
Bandung, Indonesia

[irmapalupi@telkomuniversity.ac.id](mailto:irmapalupi@telkomuniversity.ac.id)

**Abstrak** — Dalam teori portofolio modern, pemilih dan diversifikasi portofolio dilakukan dengan asumsi investor rasional tanpa mempertimbangkan pandangan subjektif terhadap investasi. Perkembangan teknologi *machine learning* dan kecerdasan buatan memungkinkan analisis kondisi pasar secara lebih adaptif, sehingga mendukung pengambilan keputusan investasi yang selaras dengan preferensi investor. Penelitian ini membahas penerapan metode Long Short-Term Memory (LSTM) untuk menentukan alokasi portofolio saham di Bursa Efek Indonesia (IDX) yang mencakup berbagai sektor, berdasarkan ukuran Sharpe ratio dan mean-variance portofolio. Dua pendekatan LSTM digunakan: LSTM single input yang hanya memanfaatkan data historis harga aset, dan LSTM dengan faktor eksogen yang menggabungkan variabel eksternal sebagai prediktor tambahan. Kinerja keduanya dibandingkan dengan model Autoregressive Integrated Moving Average (ARIMA) sebagai representasi model deret waktu murni. Evaluasi dilakukan menggunakan metrik prediksi dan hasil simulasi portofolio investasi melalui nilai return dan risiko portofolio. Hasil penelitian menunjukkan bahwa, berdasarkan prediksi rasio Sharpe untuk setiap komponen portofolio, LSTM single input memiliki kinerja lebih baik dibandingkan LSTM dengan faktor eksogen maupun model ARIMA. Kedua pendekatan LSTM secara konsisten menunjukkan bahwa pengambilan keputusan investasi yang lebih sering (periode pendek) menghasilkan akumulasi return lebih tinggi dibandingkan strategi jangka panjang. Secara khusus, LSTM single input memberikan performa prediksi yang baik serta pembobotan portofolio optimal untuk investasi bulanan dan jangka pendek.

**Kata kunci**— LSTM (Long-Short Term Memory), Diversifikasi Portofolio, Faktor Eksogen, ARIMA

## I. PENDAHULUAN

Portofolio investasi merupakan manajemen aset portofolio terhadap beberapa aset yang ingin diinvestasikan di beberapa bidang tertentu [1]. Dalam hal ini kegiatan investasi merupakan kegiatan yang sangat berisiko tetapi memiliki

pengembalian hasil yang cukup tinggi berdasarkan waktu investasi yang dipakai [2]. Pembobotan dalam portofolio digunakan untuk menentukan alokasi dana pada tiap aset, berdasarkan besarnya risiko yang siap ditanggung. Selain itu, investasi juga berperan penting dalam menjaga daya beli uang terhadap inflasi. Berdasarkan data Badan Pusat Statistik, tingkat inflasi di Indonesia mencapai puncaknya pada Desember 2022 (5,51%) dan terendah pada Januari 2024 (0,04%).

Aset yang digunakan dalam portofolio mencakup saham dari sektor keuangan, pertambangan, infrastruktur, dan properti, serta deposito yang beracuan pada suku bunga Bank Indonesia sebagai instrumen safe-haven. Suku bunga Bank Indonesia sendiri digunakan karena pengambilan hasil yang relatif aman dan stabil di berbagai kondisi keuangan yang dialami serta menghindari kerugian yang cukup signifikan dalam melakukan investasi. Penelitian ini menawarkan penggunaan metode LSTM untuk pengambilan keputusan diversifikasi portofolio secara dinamik terhadap waktu. Metode LSTM digunakan untuk memprediksi komponen portofolio terbaik di masa depan. Untuk membantu pengambilan keputusan investasi, metode Long Short-Term Memory (LSTM) diterapkan sebagai alat prediksi harga aset, sinyal jual/beli, serta penyusunan pembobotan portofolio. Beberapa studi terdahulu telah menerapkan metode ini dalam prediksi harga aset, lihat [3] dan [4]. Pada penelitian lain, metode LSTM digunakan untuk menyelesaikan problem klasifikasi aset untuk komponen optimasi portofolio dengan nilai koefisien 0,9980 beserta persentase akurasi 97,05% [5].

Penerapan model machine learning seperti LSTM memberikan hasil yang lebih optimal dibanding metode konvensional dalam membangun strategi investasi [6]. Salah satu pendekatan konvensional adalah Modern Portfolio Theory (MPT), yang menekankan diversifikasi aset guna mengurangi risiko tanpa harus mengorbankan potensi keuntungan [7]. Berdasarkan MPT untuk aset yang sudah

diinvestasikan tidak melihat aset tersebut berkembang maupun tidak berkembang melainkan lebih mementingkan hasil akhir yang diinginkan dari keseluruhan aset investasi yang diinvestasikan[8]. Di sisi lain, model ARIMA digunakan untuk memprediksi data deret waktu yang bersifat stasioner, meskipun memiliki keterbatasan dalam menangani data dengan volatilitas tinggi dan ketidakaturan struktural [9][10]. Untuk menilai kinerja portofolio, digunakan dua indikator utama yaitu Sharpe Ratio dan Mean Variance. Sharpe Ratio mengukur rasio pengembalian terhadap risiko yang ditanggung, dan terbukti dapat ditingkatkan melalui integrasi dengan LSTM [11][12]. Mean Variance akan digunakan untuk sebagai cara dalam alokasi dana yang optimal untuk portofolio dengan mempertimbangkan hasil pengembalian dan jangka waktu investasi[13][14]. Kombinasi ketiga metode ini yaitu LSTM, Sharpe Ratio, dan Mean Variance memberikan pengoptimalan yang sangat baik dalam membangun suatu portofolio investasi yang efisien, bertahan terhadap risiko tertentu, dan juga menyesuaikan dengan tujuan investasi baik itu jangka pendek maupun jangka panjang.

## II. KAJIAN TEORI

Pada penelitian yang terdahulu sudah dilakukan analisis prediksi tren harga saham selama 4 tahun dari 2018-2022 menggunakan deep LSTM. Dari hasil tersebut dapat ditentukan saham yang dapat dijual, dibeli, dan dipertahankan dalam jangka waktu yang lama maupun jangka waktu yang cepat [2]. Di dalam penelitian lain membahas tentang metode LSTM dapat dilihat bahwa rata-rata dari matriks evaluasi uji menggunakan RMSE yaitu dengan 0,044 yang dimana hasilnya sangat kecil dan bagus [1]. Di waktu yang akan datang LSTM-DNN sangat mudah dalam memprediksi hasil dari suatu aset dan mengoptimalkan dalam portofolio berbagai aset untuk mendapatkan hasil yang terbaik [3].

### A. Penentuan Sektor Strategis Indonesia dan Seleksi Komponen Saham dalam Portofolio

Bursa Efek Indonesia melalui klasifikasi IDX-IC (Indonesia Stock Exchange Industrial Classification) membagi saham ke dalam 11 sektor utama, yaitu: Energi; Barang Baku; Perindustrian; Barang Konsumen Primer; Barang Konsumen Non-Primer; Kesehatan; Keuangan; Properti & Real Estat; Teknologi; Infrastruktur; serta Transportasi & Logistik. Dari seluruh sektor tersebut, beberapa ditetapkan sebagai sektor strategis perekonomian nasional, yaitu Keuangan, Pertambangan (termasuk komoditas energi dan mineral pada sektor Energi serta Barang Baku), Infrastruktur, dan Properti dan Real Estate. Sektor keuangan berperan sebagai penggerak pembiayaan dan likuiditas ekonomi, sedangkan sektor pertambangan menjadi penopang ekspor, sumber devisa, dan pendukung hilirisasi industri. Infrastruktur memegang peran vital dalam konektivitas nasional serta kelancaran distribusi barang dan jasa, sementara sektor properti mencerminkan pertumbuhan urbanisasi dan investasi domestik. Sehingga, penetapan keempat sektor penting dalam kajian penelitian ini, sejalan dengan arah pembangunan jangka panjang serta prioritas investasi yang ditekankan oleh pemerintah dan lembaga pengelola investasi negara.

Adapun bagaimana tentang pemilihan komponen aset/saham yang membentuk portofolio investasi, terdapat beberapa pendekatan. Seleksi aset merupakan tahap penting dalam pembentukan portofolio, di mana tujuan utamanya adalah memilih kombinasi instrumen investasi yang optimal dari sekian banyak pilihan yang tersedia di pasar. Pendekatan untuk pemilihan aset yang dapat digunakan, mulai dari analisis konvensional berbasis indikator teknis seperti moving average, relative strength index (RSI), dan volume perdagangan, hingga metode berbasis teknologi seperti machine learning yang mampu mengolah data dalam jumlah besar dan menemukan pola tersembunyi yang sulit terdeteksi secara manual. Dalam penelitian ini, proses seleksi aset dilakukan secara data-driven dengan mempertimbangkan dua kriteria utama: (1) nilai korelasi terkecil antar aset untuk memaksimalkan diversifikasi, dan (2) return tertinggi selama periode waktu terakhir yang ditentukan. Pendekatan ini diharapkan menghasilkan portofolio dengan risiko lebih rendah namun tetap memberikan potensi imbal hasil yang optimal.

Misal, untuk suatu aset- $i$  pada waktu  $t$  dengan harga penutupan  $C_{i,t}$ . Maka return untuk suatu periode diskrit  $t$  dapat dihitung sebagai berikut.

$$R_{i,t} = \frac{C_{i,t} - C_{i,t-1}}{C_{i,t-1}} \approx \ln \left( \frac{C_{i,t}}{C_{i,t-1}} \right)$$

(dalam bentuk log return)

Adapun untuk rata-rata return untuk suatu periode waktu tertentu selama kurun waktu  $T$ , dan korelasi antar aset  $i$  dan  $j$  dapat dihitung dengan menggunakan formula (1) dan (2).

$$\bar{R}_i = \frac{1}{T} \sum_{t=1}^T R_{i,t} \quad (1)$$

$$\rho_{i,j} = \frac{\sum_{t=1}^T (R_{i,t} - \bar{R}_i)(R_{j,t} - \bar{R}_j)}{\sqrt{\sum_{t=1}^T (R_{i,t} - \bar{R}_i)^2} \sqrt{\sum_{t=1}^T (R_{j,t} - \bar{R}_j)^2}} \quad (2)$$

Dalam penelitian ini, pemilihan aset dilakukan dengan pendekatan data-driven berdasarkan dua kriteria utama, pertama berdasarkan korelasi historis minimal antar aset, untuk meningkatkan potensi diversifikasi dan mengurangi risiko sistemik. Kemudian kriteria berikutnya adalah return rata-rata maksimum selama periode waktu tertentu, untuk memaksimalkan potensi keuntungan. Secara matematis, seleksi aset  $S$  dapat ditentukan dengan formulasi berikut.

$$S := \{a_i \in A \mid \rho_{i,j} \text{ minimum untuk } i \neq j \wedge \bar{R}_i = \max(\bar{R})\} \quad (3)$$

Dimana,  $A$  adalah himpunan semua aset yang menjadi kandidat,  $\rho_{i,j}$  merupakan korelasi historis antara aset- $i$  dan aset- $j$ , dan  $\bar{R}_i$  merupakan return rata-rata aset- $i$  untuk suatu periode pengamatan terkait.

## B. Optimasi Portfolio Investasi

Optimasi portofolio investasi adalah proses menentukan pembobotan alokasi dana pada berbagai aset investasi dengan tujuan memperoleh tingkat pengembalian (return) yang optimal sekaligus meminimalkan risiko yang dihadapi. Prinsip dasar optimasi portofolio adalah diversifikasi, yaitu menyebar investasi ke berbagai aset sehingga tidak bergantung pada satu instrumen saja, sehingga dapat mengurangi potensi kerugian besar [6].

### 1. Return dan Risk dalam Portfolio

Return merupakan tingkat pengembalian dari suatu aset yang dihitung berdasarkan perubahan harga penutupan. Dalam penelitian ini, return yang digunakan adalah return mingguan, dihitung dari selisih harga penutupan akhir minggu terhadap harga penutupan awal minggu. Perhitungan ini bertujuan untuk mengidentifikasi aset dengan performa pengembalian terbaik sebagai kandidat investasi [3]. Untuk return portfolio menggunakan rumus (4).

$$R_p = \sum_{i=1}^n R_i \omega_i \quad (4)$$

Dengan  $R_p$  (return dari portfolio),  $R_i$  (return dari aset  $i$ ),  $\omega_i$  (bobot aset  $i$  dalam portfolio), dan  $n$  (jumlah total aset dalam portfolio). Sedangkan ekspektasi return portfolio dihitung sebagai

$$E(R_p) = \sum_{i=1}^n \omega_i E(R_i) \quad (5)$$

dengan  $E(R_p)$  (ekspektasi dari return portfolio),  $\omega_i$  (bobot alokasi dana pada aset  $i$ ),  $E(R_i)$  (ekspektasi return pada aset  $i$ ), dan  $n$  (jumlah total aset dalam portfolio). Sehingga dalam menghitung resiko dalam portfolio investasi menggunakan variansi dari return portfolio maupun mean-variance tersebut dengan rumus berikut (6)

$$\sigma_{R_p}^2 := Var(R_p) = \sum_{i=1}^n \sum_{j=1}^n \omega_i \omega_j Cov(R_i, R_j) \quad (6)$$

$Var(R_p)$  merupakan variansi return portfolio untuk menghitung risiko portfolio, lalu  $\omega_i, \omega_j$  masing-masing

adalah bobot masing-masing aset),  $Cov(R_i, R_j)$  adalah kovariansi antara return aset  $i$  dan aset  $j$ , dan  $n$  sebagai jumlah asetnya.

### 2. Optimasi Portfolio dan Memaksimalkan Sharpe Ratio

Dalam optimasi portofolio, investor harus mempertimbangkan keseimbangan antara risiko dan return. Keputusan investasi dapat cenderung pada risiko tinggi dengan potensi return tinggi atau risiko rendah dengan return yang lebih stabil. Sharpe Ratio digunakan sebagai indikator untuk menilai performa portofolio dibandingkan aset bebas risiko (risk-free asset), seperti obligasi pemerintah atau deposito. Formula Sharpe Ratio adalah seperti pada (7).

$$SR = \frac{R_p - R_f}{\sigma} \quad (7)$$

dimana  $SR$  adalah nilai sharpe ratio portfolio saham,  $R_p$  return portofolio saham,  $R_f$  adalah risk-free rate yang merupakan tingkat imbal hasil deposito, dan  $\sigma$  adalah risiko portfolio. Sharpe ratio digunakan untuk pembuatan portofolio investasi dan menentukan return aset yang terbaik. Nilai  $SR$  yang lebih tinggi menunjukkan portofolio memberikan imbal hasil lebih baik per unit risiko yang diambil.

### 3. Pembobotan dan Normalisasi Bobot

Dalam pembobotan portofolio digunakan menggunakan Modern Portfolio Theory (MPT). MPT merupakan portofolio investasi yang membuat pembobotan lebih optimal dan alokasi aset yang sesuai. MPT dibuat oleh Markowitz untuk membuat portofolio investasi yang tahan akan segala fluktuasi di pasar investasi. Total bobot investasi harus dipenuhi kondisi berikut.

$$\sum_{i=1}^n \omega_i = 1, \wedge \omega_i \geq 0 \forall i \quad (8)$$

Pada penelitian ini, penentuan bobot komponen portofolio ditentukan secara urutan waktu, berdasarkan nilai sharp-ratio yang diprediksi. Misal untuk portofolio yang terdiri dari  $n$  komponen saham,  $SR_i(t)$  merupakan nilai sharp ratio untuk komponen saham- $i$  pada waktu  $t$ . Maka bobot portofolio untuk saham- $i$  pada saat  $t$  dapat ditentukan dengan formula (9).

$$\omega_i(t) = \frac{SR_i(t) - \min\{SR_i(t)\}_i^n}{\sum_{i=1}^n (SR_i(t) - \min\{SR_i(t)\}_i^n)} \quad (9)$$

Formula bobot (9) memastikan nilai bobot yang diperoleh sesuai dengan kondisi (8). Semakin rendah nilai sharp-ratio suatu komponen saham, maka nilai bobot saham tersebut pada portofolio akan rendah, dan porsi investasi akan lebih besar untuk saham yang memiliki nilai prediksi sharp-ratio lebih besar pula.

### C. Model Prediksi ARIMA

Model ARIMA adalah Auto-Regressive Integrated Moving Average model. Model ini merupakan model yang dapat memprediksi data masa depan dengan cara menggunakan data historis yang didapatkan. Model ARIMA bisa digunakan untuk data yang mempunyai volatilitas tinggi seperti data saham maupun data deret waktu. Model ARIMA digunakan untuk memprediksi penghitungan dari sharpe

ratio. Untuk memprediksi model ARIMA menggunakan rolling window dan orde (p,d,q) untuk menilai data-data historis yang akan digunakan dalam perhitungan. Dalam model ARIMA juga menggunakan data 60 pertama untuk memprediksi data baru dan data hasil yang baru diprediksi menggantikan data awal sampai semua data digunakan terisi dengan lengkap [6]. Dengan rumus sebagai berikut ini (10) :

$$(1 - \sum_{i=1}^p \phi_i L^i)(1 - L)^d r_t = \delta + (1 - \sum_{i=1}^q \theta_i L^i) \varepsilon_t \quad (10)$$

dengan  $L$  (operator lag),  $p$  (orde dari Autoregressive),  $d$  (orde dari differencing untuk membuat data stasioner),  $q$  (orde dari moving average),  $\phi_i$  (koefisien AutoReggressive),  $\theta_i$  (koefisien moving average),  $r_t$  (nilai return saham dalam waktu),  $\varepsilon_t$  (nilai error) dan  $\delta$  (konstanta intercept) dan digunakan sebagai pembanding antara model single LSTM dan model LSTM dengan faktor eksternal.

#### D. Model Prediksi LSTM

Model prediksi LSTM merupakan model prediksi yang bisa memprediksi data masa depan dengan menggunakan data historis. Data yang digunakan pada model LSTM adalah setiap data yang memiliki tingkat perubahan tinggi maupun rendah. Model LSTM dapat membuat prediksi yang cukup akurat serta adanya faktor-faktor lain yang ada pada data dapat digunakan dalam model LSTM [1].

##### 1. Single Time Series Model

Single Time series Model adalah metode pengembangan dari Recurrent Neural Network yang dapat memproses data sekuensial seperti data dalam waktu tertentu, data keuangan, dan data dalam bentuk teks. LSTM memiliki sel yang terdiri dari input layer, hidden layer, output layer, dan sel state. LSTM juga memiliki gate didalam setiap sel yaitu input gate, output gate, forget gate, dan memori sel hal ini dilakukan agar hasil prediksi menjadi lebih akurat [2]. Untuk pembuatan single time series model sebagai berikut :

- Input Gate: mengontrol alur masuknya data ke dalam memori sel dengan rumus (11).

$$inputgate = \sigma(\omega_i \cdot [h_t - 1, x_t] + b_i) \quad (11)$$

- Forget Gate: mengontrol alur keluarnya data dari dalam memori sel dengan rumus (12).

$$forgetgate = \sigma(\omega_f \cdot [h_t - 1, x_t] + b_f) \quad (12)$$

dengan  $w_f$  (bobot dari forget gatenya) dan setiap parameter sesuai dengan masing-masing proses.

- Output Gate: mengontrol hasil dari memori sel kedalam jaringan dengan rumus (13).

$$outputgate = \sigma(\omega_o \cdot [h_t - 1, x_t] + b_o) \quad (13)$$

- Cell State : menyimpan data memori sel dengan rumus (14)

$$memorycell = f_t \cdot c_t - 1 + i_t \cdot \tanh(\omega_c \cdot [h_t - 1, x_t] + b_c) \quad (14)$$

- Hidden State : hasil prediksi dari model LSTM dan ditambahkan faktor eksternal dengan rumus (15).

$$hiddenstate = o_t \cdot \tanh(c_t) \quad (15)$$

##### 2. Time Series Dengan Eksogeneus Variabel

LSTM dalam time series menggunakan eksogoneus variabel adalah memasukkan faktor-faktor eksternal dalam melakukan prediksi. Eksogoneus variabel yang dimasukkan yaitu Technical Analysis (TA) untuk Membuat prediksi semakin akurat. TA yang digunakan terdiri dari bollinger bands, simple moving average, relative strength index, dan moving average convergence divergence [1]. Dengan rumus sebagai berikut :

- Simple Moving Average (SMA 9 dan 20) untuk mengurangi noise (16) :

$$SMA = \frac{1}{T} \sum_{i=1}^n C_i \quad (16)$$

SMA sebagai rata-rata,  $T$  sebagai jumlah periode, dan  $C_i$  yaitu harga penutupan hari ke-i.

- Relative Strength Index (RSI) untuk oscilator dari 1- 100 (17):

$$RSI = 100 - \frac{100}{1 + \frac{AverageGain}{AverageLoss}} \quad (17)$$

Average gain dan loss untuk menghitung rata-rata penurunan dan kenaikan.

- Bollinger Bands (BB) sebagai potensi jenuh jual dan beli (18) (19) (20):

$$Middle\ Band = SMA(n) \quad (18)$$

$$Upper\ Band = SMA(n) + k \cdot \sigma \quad (19)$$

$$Lower\ Band = SMA(n) - k \cdot \sigma \quad (20)$$

SMA(n) sebagai rata-rata pada hari ke berapa,  $\sigma$  sebagai standar deviasi, dan  $k$  jumlah standar deviasi.

- Moving Average Convergence Divergence (MACD) sebagai penentu tren dan arah jual maupun beli (21) (22) (23):

$$MACD\ Line = EMA_{short} - EMA_{long} = EMA_{12} - EMA_{26} \quad (21)$$

$$Signal\ Line = EMA_9\ \text{dari}\ MACD\ Line \quad (22)$$


$$Histogram = MACD\ Line - Signal\ Line \quad (23)$$

EMA 12 hari yaitu cepat, EMA 26 hari yaitu lambat, dan Signal line EMA 9 hari dari MACD.

### III. METODE

Di dalam sistem yang dibangun dilakukan pembuatan alur untuk melakukan proses pengerjaan. Analisa dibuat dari pengambilan data-data yang diambil sampai pembuatan


portfolio investasi yang sangat baik. Untuk pembuatan sistem dapat digunakan melalui diagram dalam setiap proses yang dilakukan menggunakan Gambar 1.



Gambar 1 Flowchart sistem yang dibangun

#### A. Data Collection dan Preproccession

Data collection adalah pemrosesan untuk mengambil data-data saham yang diperlukan di dalam analisa saham. Data saham yang diambil adalah data-data saham dari mulai 1 Desember 2014 – 1 Desember 2024 yaitu 10 tahun terakhir yang terdapat di yahoo finance. Pada saat data preprocessing dilakukan penghilangan nilai yang kosong, menghitung return dalam setiap emiten, dan indikator TA. Untuk nama-nama setiap emiten ada di Gambar 2 sebagai berikut :




Gambar 2 Daftar emiten saham untuk setiap sektor dan sebaran return.

#### B. Prediksi dengan LSTM

Pada bagian model LSTM dilakukan prediksi atas harga saham yang digunakan dalam waktu 10 tahun terakhir. Pada model LSTM sendiri dilakukan pengoptimalan pengembalian hasil di dalam sharpe ratio. Mean Variance digunakan untuk menentukan alokasi dana dalam setiap aset yang ingin diinvestasikan dan mengukur resiko investor dalam berinvestasi. Model LSTM digunakan untuk memprediksi nilai dari sharpe ratio dari setiap emiten yang telah dihitung. Nilai sharperatio yang digunakan adalah nilai dari sharpe ratio setiap emiten selama 60 hari terakhir. Pada saat memprediksi nilai sharpe ratio menggunakan model LSTM, 60 data tersebut digunakan untuk memprediksi 1 data baru. Model LSTM digunakan teknik pergeseran data dalam memprediksi dengan cara data yang baru diprediksi dimasukkan ke dalam model LSTM menggantikan data awal dalam proses prediksi sampai semua data yang diperlukan terkumpul. Fine tuning yaitu pemodelan agar model LSTM sesuai dengan saham-saham yang ingin diinvestasikan. Pada proses fine tuning nantinya akan melihat saham-saham

mana yang memiliki performa terbaik di dalam 10 tahun terakhir tersebut dengan Gambar 3 maupun prosedur dan arsitektur terdapat pada Tabel 1 dan Tabel 2.



Gambar 3 Flowchart model LSTM

Tabel 1. Prosedur pelatihan dan prediki LSTM


| Langkah          | Deskripsi                                                                                                                    |
|------------------|------------------------------------------------------------------------------------------------------------------------------|
| 1. Input         | Dataset multivariat yang berisi variabel-variabel eksternal (exogenous) dan target (return <i>saham</i> )                    |
| 2. Preprocessing | Dataset dikonstruksi dalam bentuk <i>sekuens waktu</i> dengan <i>time_step</i> = 60 menggunakan fungsi <i>create_dataset</i> |
| 3. Normalisasi   | Data diubah ke skala 0–1 menggunakan <i>MinMaxScaler</i>                                                                     |
| 4. Reshape       | Data diubah menjadi bentuk 3D: (samples, <i>time_steps</i> , features) agar sesuai input LSTM                                |
| 5. Model pertama | LSTM model pertama dilatih dengan data <i>X_scaled</i> dan <i>y</i>                                                          |
| 6. Skala target  | Target <i>y</i> dinormalisasi menggunakan <i>MinMaxScaler</i>                                                                |
| 7. Model kedua   | LSTM model kedua dilatih ulang dengan <i>X_scaled</i> dan <i>y_scaled</i>                                                    |
| 8. Prediksi      | Model memprediksi target dalam bentuk scaled, lalu di-inverse transform ke skala asli                                        |
| 9. Evaluasi      | Dilakukan evaluasi terhadap hasil prediksi menggunakan MAE, MSE, dan RMSE                                                    |

Tabel 2. Arsitektur LSTM

| Layer         | Jenis Layer | Jumlah Unit | Output Shape   | Keterangan                                           |
|---------------|-------------|-------------|----------------|------------------------------------------------------|
| 1             | LSTM        | 50          | (None, 60, 50) | Mengembalikan <i>sekuens</i> (return_sequences=True) |
| 2             | LSTM        | 50          | (None, 50)     | Tanpa return_sequences                               |
| 3             | Dense       | 1           | (None, 1)      | Output akhir berupa 1 nilai prediksi                 |
| Optimizer     | —           | Adam        | —              | Digunakan untuk optimasi training                    |
| Loss Function | —           | MSE         | —              | Mean Squared Error sebagai fungsi loss               |

#### C. Simulasi Nilai Portfolio

Simulasi nilai portfolio dilakukan untuk penghitungan dalam hasil dari investasi yang dilakukan. Hasil-hasil yang dilakukan dalam simulasi portfolio merupakan hasil dari prediksi model LSTM. Pada saat dilakukan pembuatan portfolio akan disesuaikan dengan profil resiko masing-masing investor. Portfolio investasi tersebut bisa memaksimalkan hasil pengembalian aset dengan resiko cukup besar maupun resiko yang minimal. Portfolio investasi terdapat pengalokasian aset-aset yang diinvestasikan dan jumlah dana yang diinvestasikan dalam aset tersebut seperti Gambar 4.




Gambar 4 Flowchart simulasi portfolio

#### IV. HASIL DAN PEMBAHASAN

Hasil dan analisis yang dilakukan adalah pemodelan dari prediksi return saham, risk saham, dan bobot dari portfolio investasi. Hasil yang dibuat yaitu sebaran saham-saham yang bagus untuk diinvestasikan dengan dana siap diinvestasikan. Pada model LSTM akan melihat saham-saham dengan prediksi sharpe ratio yang sangat cocok untuk diinvestasikan. Di dalam pembobotan akan digunakan dengan profil resiko investor dalam berinvestasi dan membuat portfolio investasi yang memaksimalkan return maupun mengurangi resiko.

##### A. Penelitian Saham Berdasarkan Nilai Korelasi Terkecil

Dalam membentuk portfolio investasi, penting untuk memilih saham yang tidak bergerak terlalu mirip. Hal ini bertujuan agar saat satu saham turun, saham lain tidak ikut turun, sehingga risiko portofolio lebih kecil. Untuk itu, kita bisa menggunakan matriks korelasi. Matriks korelasi menunjukkan seberapa mirip pergerakan harga antar saham. Nilai korelasi berkisar antara -1 hingga 1. Jika nilainya mendekati 1, berarti dua saham bergerak hampir sama. Jika mendekati 0, gerakannya tidak saling terkait. Jika negatif, mereka cenderung bergerak berlawanan. Untuk portofolio yang lebih aman dan terdiversifikasi, pilihlah saham-saham dengan korelasi rendah (misalnya di bawah 0.3). Gambar 5 menunjukkan matriks korelasi dari return antar emiten saham



**Gambar 5 Korelasi dari return setiap emiten saham.**


Setelah itu, dari saham-saham tersebut, dipilih yang memiliki rata-rata return tinggi. Portofolio yang baik dibentuk dari saham-saham dengan korelasi rendah untuk mengurangi risiko, serta return tinggi untuk menjaga potensi keuntungan. Jumlah saham yang dipilih bergantung pada preferensi investor, yang salah satunya dipengaruhi oleh besarnya budget. Dalam studi ini, dipilih 10 emiten (Tabel 3) dari daftar saham berkorelasi rendah, yaitu sepuluh dengan rata-rata return tertinggi selama satu tahun terakhir. Dalam hal ini Dengan teknik ini, diharapkan memberikan portofolio yang lebih stabil karena risiko tersebar dan peluang imbal hasil tetap optimal.

**Tabel 3. Daftar emiten yang terpilih dalam portfolio dengan rata-rata return terbesar dan minimum korelasi**

| Kode Emiten | Asal Sektor   | Return rata-rata | Kode Emiten | Asal Sektor   | Return rata-rata |
|-------------|---------------|------------------|-------------|---------------|------------------|
| DART.JK     | Properti      | 0.017            | SSIA.JK     | Infrastruktur | 0.021            |
| BALI.JK     | Infrastruktur | 0.019            | TPIA.JK     | Tambang       | 0.025            |
| DNET.JK     | Keuangan      | 0.019            | GMTD.JK     | Properti      | 0.027            |
| BRMS.JK     | Tambang       | 0.02             | FMII.JK     | Properti      | 0.028            |
| CASS.JK     | Infrastruktur | 0.02             | PSAB.JK     | Tambang       | 0.03             |

##### B. Prediksi Sharpe Ratio dengan ARIMA

Untuk memprediksi performa portfolio secara lebih realistis, pendekatan moving window atau jendela geser digunakan dengan memanfaatkan model ARIMA. Teknik ini meniru kondisi nyata di mana prediksi hanya menggunakan data historis sebelum titik waktu tertentu, tanpa melihat informasi masa depan. Proses dimulai dengan menghitung return harian dari saham-saham terpilih. Selanjutnya, untuk setiap saham, diterapkan jendela data historis, misalnya dalam hal ini untuk 60 hari ke depan, secara bergeser digunakan untuk melatih model ARIMA dan memprediksi return harian berikutnya. Hasil prediksi return dari seluruh saham kemudian digabungkan dengan asumsi bobot sama untuk membentuk return portofolio yang diproyeksikan. Berdasarkan return portofolio ini, Sharpe ratio diprediksi dengan menghitung rata-rata return dibagi dengan volatilitas (standar deviasi) dari return yang diprediksi. Proses ini diulang sepanjang periode waktu sehingga dihasilkan deret waktu rolling Sharpe ratio yang mencerminkan dinamika risiko dan potensi imbal hasil dari portofolio. Hasil ini memberikan gambaran yang lebih adaptif terhadap perubahan pasar dan dapat digunakan sebagai acuan dalam pengambilan keputusan investasi berbasis proyeksi.



**Gambar 6 Prediksi nilai sharpe ratio pada komponen portfolio untuk ARIMA**

Dalam metode prediksi ARIMA yang ada pada gambar 6, dapat dilihat bahwa ARIMA dapat memprediksi sharpe ratio dari saham-saham yang diinvestasikan. Dalam ARIMA sendiri membutuhkan data-data historis yang banyak agar dapat memprediksi data masa depan, sehingga dapat dilihat bahwa prediksi ARIMA baru muncul pada saat di pertengahan hasil.


##### C. Hasil Prediksi LSTM

Pada saat prediksi LSTM dilakukan untuk menghitung harga masa depan dari aset-aset yang diinvestasikan. Model LSTM melakukan penghitungan prediksi dari return, risk,

maupun bobot untuk melakukan pembuat portfolio investasi. Untuk metrik evaluasi menggunakan rmse untuk menghitung seberapa bagus model LSTM dapat melakukan proses prediksi. Untuk hasil dapat dilihat sebagai berikut :

## 1. Single Input LSTM


Gambar 7 menampilkan hasil prediksi nilai Sharpe Ratio dari masing-masing komponen saham dalam portofolio menggunakan model single-input LSTM. Model ini hanya mempelajari pola historis return dari setiap saham secara individual tanpa mempertimbangkan faktor eksternal. Nilai Sharpe Ratio yang diprediksi merepresentasikan rasio antara return yang diharapkan dengan volatilitas (risiko) berdasarkan hasil prediksi return harian. Dari visualisasi ini, dapat diamati variasi performa risiko relatif antar saham di dalam portofolio. Saham-saham dengan nilai Sharpe Ratio lebih tinggi menunjukkan potensi return yang lebih besar relatif terhadap risiko, sedangkan nilai yang lebih rendah mengindikasikan performa risiko-return yang kurang optimal.



**Gambar 7** Prediksi nilai sharpe ratio pada komponen portofolio untuk single-input LSTM.

## 2. Exogenous LSTM

Pada gambar 8 ditampilkan hasil prediksi nilai Sharpe Ratio dari setiap saham yang ada dalam portofolio dengan menggunakan model Exogenous LSTM. Model ini melakukan pembelajaran dalam pola historis return dari setiap saham secara individual serta mempertimbangkan faktor eksternal yaitu technical analysis. Nilai Sharpe Ratio yang diprediksi merepresentasikan rasio antara return yang diharapkan dengan volatilitas (risiko) berdasarkan hasil prediksi return harian dan adanya faktor eksternal seperti technical analysis digunakan untuk membuat prediksi yang lebih sensitif. Dari visualisasi ini, dapat diamati variasi performa risiko relatif antar saham di dalam portofolio. Saham-saham dengan nilai Sharpe Ratio lebih tinggi menunjukkan potensi return yang lebih besar relatif terhadap risiko, sedangkan nilai yang lebih rendah mengindikasikan performa risiko-return yang kurang optimal.




**Gambar 8** Prediksi nilai sharpe ratio pada komponen portofolio untuk Exogenous LSTM

**Tabel 4.** Metrik exaluasi setiap model

| No | Model             | MSE   | SMAPE(%) | R2 Score | Waktu Komputasi         |
|----|-------------------|-------|----------|----------|-------------------------|
| 1  | ARIMA             | 1,063 | 56,651   | 0,687    | 46 Menit 32 Detik       |
| 2  | LSTM Single Input | 1,992 | 58,508   | 0,593    | 17 Menit 10 Detik       |
| 3  | LSTM Exogenous    | 2,535 | 61,596   | 0,482    | 3 Jam 54 Menit 49 detik |

Dalam tabel 4 dapat dilihat bahwa ARIMA memiliki nilai MSE yang paling kecil diantar metode yang lain dengan ukuran data yang diprediksi adalah 8100 data . Hal ini disebabkan bahwa model ARIMA seharusnya membutuhkan data yang lebih banyak dibandingkan LSTM. Pada saat ini model terbaik tetap dengan model LSTM karena memiliki sensitifitas yang tinggi dalam memprediksi harga serta dari grafiknya model tersebut dapat memprediksi arah pasar masa depan yang lebih optimal.




**Gambar 9** Distribusi galat mutlak dari hasil prediksi sharp ratio dengan ARIMA, Single LSTM, dan Exogenous LSTM

Sesuai pada Gambar 9 diperlihatkan distribusi galat mutlak antara hasil prediksi dan nilai aktual Sharpe Ratio, dalam bentuk boxplot, untuk seluruh saham dalam portofolio. Distribusi galat ini memberikan gambaran seberapa baik model ARIMA, LSTM single input, dan Exogenous LSTM mampu memprediksi nilai Sharpe Ratio. Galat yang sempit dan terpusat menunjukkan akurasi prediksi yang baik, sementara penyebaran galat yang lebar atau memiliki banyak outlier yang mengindikasikan juga adanya ketidaksesuaian

antara pola historis dan realisasi kinerja portofolio. Untuk jumlah data yang di prediksi untuk model ARIMA adalah 8.100 data, model LSTM single input adalah 23.820 data, dan Exogenous LSTM adalah 23.820 sehingga nilai persebaran galat dari model ARIMA sangat sedikit dibandingkan model yang lain.

#### D. Simulasi Portfolio


Hasil dalam pembuatan portfolio investasi terdiri dari periode, emiten portfolio, bobot portfolio, return portfolio, dan risk portfolio tersebut. Hal ini dilakukan agar mempermudah dalam melakukan investasi. Hasil dari simulasi portfolio investasi disesuaikan dengan setiap profil resiko investor. Simulasi porfolio dilakukan untuk Dalam simulasi portfolio yang sesuai dapat dilihat sebagai berikut :




**Gambar 10 Performa portofolio yang disimulasikan dalam bulanan**



**Gambar 11 Performa portofolio yang disimulasikan dalam kuartal**



**Gambar 12 Performa portofolio yang disimulasikan dalam Bi annual**



**Gambar 13 Performa portofolio yang disimulasikan dalam Tahunan**

Pada gambar diatas terdapat grafik performa portofolio saham dari emiten terpilih, yang dipresentasikan dengan nilai bobot portofolio, return portofolio dan resiko porofolio. Gambar 10-13 berturut-turut merupakan simulasi portofolio untuk periode bulanan, kuartal, biannual, dan annual. Terlihat bahwa risiko dari setiap portofolio investasi berkorelasi dengan return dari portofolio yang ada. Dengan model LSTM dengan single input dapat meprediksi cukup akurat dengan mean error adalah 0.9305 yang cukup baik dalam memprediksi.

**Tabel 5. Simulasi Portfolio Selama 9 Tahun**

| Periode   | Return Portfolio (rata-rata) | Return Portfolio (akumulasi) | Risk Portfolio (rata-rata) |
|-----------|------------------------------|------------------------------|----------------------------|
| Bulanan   | 3,1%                         | 296%                         | 0,0629                     |
| Kuartal   | 2,7%                         | 86,4%                        | 0,0651                     |
| Bi annual | 1,3%                         | 27,6%                        | 0,0491                     |
| Tahunan   | 0,16%                        | 1,5%                         | 0,0475                     |

Tabel 5 memperlihatkan hasil simulasi portofolio selama beberapa skenario periode yaitu bulanan, kuartal, per 6 bulan, dan per tahun. Berdasarkan nilai rata-rata return portofolio dan akumulasinya, portofolio dengan keputusan di periode pendek memberikan kemungkinan imbal hasil yang lebih besar dibandingkan periode yang lebih lama. Hal ini berbanding sebaliknya dengan resiko portofolio, yang memberikan nilai resiko lebih rendah untuk periode portofolio yang panjang.

#### V. KESIMPULAN

Metode prediksi dalam penelitian ini terdiri dari ARIMA, LSTM single input, dan LSTM dengan faktor eksternal. Metode yang memiliki prediksi terbaik terdapat pada LSTM dengan single input karena dalam memprediksi return dalam 9 tahun mempunyai return rata-rata dan akumulasi yang positif. Dalam return investasi yang diperoleh, return optimal terdapat pada return investasi bulanan sedangkan dalam waktu yang lebih lama return investasi tersebut semakin menurun. Pada metode prediksi LSTM dengan single input mempunyai waktu komputasi yang cepat untuk memprediksi setiap data yang ada. Untuk penentuan aset investasi juga diambil 10 saham dengan return terbaik dan tidak berkorelasi dalam fluktuasi harga sehingga dapat meminumkan resiko dan memperoleh return yang besar. Dengan investasi menggunakan portofolio investasi 1 tahun memiliki return yang paling sedikit dibanding dengan portofolio investasi yang lain. Pada model LSTM single input memiliki nilai mse dengan 1,992 dalam penilaiannya, waktu komputasi yang cepat yaitu 17 menit 10 detik, dan mampu memprediksi 23.820 data sehingga hasil dari metode ini yang sangat dipilih dalam pembuatan portofolio investasi.

Saran untuk penelitian selanjutnya untuk metode ini adalah melakukan pemilihan aset secara dinamik. Pemilihan aset investasi secara dinamik dilakukan agar tidak hanya bergantung pada aset yang tetap saja. Pada peneltian kedepan dapat menambah aset-aset lain yang memiliki return yang sangat besar agar dapat membuat portofolio investasi yang lebih optimal.

#### REFERENSI

- [1] P. Singh, M. Jha, M. Sharaf, M. A. El-Meligy, and T. R. Gadekallu, "Harnessing a Hybrid CNN-LSTM Model for Portfolio Performance: A Case Study on Stock Selection and Optimization," *IEEE Access*, vol. 11, pp. 104000–104015, 2023, doi: 10.1109/ACCESS.2023.3317953.
- [2] B. Gülmez, "Stock price prediction with optimized deep LSTM network with artificial rabbits optimization algorithm," *Expert Syst Appl*, vol. 227, Oct. 2023, doi: 10.1016/j.eswa.2023.120346.

- [3] A. M. Rather, "LSTM-based Deep Learning Model for Stock Prediction and Predictive Optimization Model," *EURO Journal on Decision Processes*, vol. 9, Jan. 2021, doi: 10.1016/j.ejdp.2021.100001.
- [4] J. Michańków, P. Sakowski, and R. Ślepaczuk, "LSTM in Algorithmic Investment Strategies on BTC and S&P500 Index," *Sensors*, vol. 22, no. 3, Feb. 2022, doi: 10.3390/s22030917.
- [5] C. H. Wang, Y. Zeng, and J. Yuan, "Two-stage stock portfolio optimization based on AI-powered price prediction and mean-CVaR models," *Expert Syst Appl*, vol. 255, Dec. 2024, doi: 10.1016/j.eswa.2024.124555.
- [6] Y. Ma, R. Han, and W. Wang, "Portfolio optimization with return prediction using deep learning and machine learning," *Expert Syst Appl*, vol. 165, Mar. 2021, doi: 10.1016/j.eswa.2020.113973.
- [7] P. Koratamaddi, K. Wadhwani, M. Gupta, and S. G. Sanjeevi, "Market sentiment-aware deep reinforcement learning approach for stock portfolio allocation," *Engineering Science and Technology, an International Journal*, vol. 24, no. 4, pp. 848–859, Aug. 2021, doi: 10.1016/j.jestech.2021.01.007.
- [8] G. W. Shin and H. M. Gordon, "Toward a portfolio theory of talent development: Insights from financial theory, illustrations from the Asia-Pacific," *World Dev*, vol. 184, Dec. 2024, doi: 10.1016/j.worlddev.2024.106755.
- [9] H. Alabdulrazzaq, M. N. Alenezi, Y. Rawajfih, B. A. Alghannam, A. A. Al-Hassan, and F. S. Al-Anzi, "On the accuracy of ARIMA based prediction of COVID-19 spread," *Results Phys*, vol. 27, Aug. 2021, doi: 10.1016/j.rinp.2021.104509.
- [10] A. Swaraj, K. Verma, A. Kaur, G. Singh, A. Kumar, and L. Melo de Sales, "Implementation of stacking based ARIMA model for prediction of Covid-19 cases in India," *J Biomed Inform*, vol. 121, Sep. 2021, doi: 10.1016/j.jbi.2021.103887.
- [11] S. Faridi, M. Madanchi Zaj, A. Daneshvar, S. Shahverdiani, and F. Rahnamay Roodposhti, "Portfolio rebalancing based on a combined method of ensemble machine learning and genetic algorithm," *Journal of Financial Reporting and Accounting*, vol. 21, no. 1, pp. 105–125, Mar. 2023, doi: 10.1108/JFRA-11-2021-0413.
- [12] T. Salsabila, D. Saepudin, and A. A. Rohmawati, "Optimizing LQ45 Stock Portfolio To Maximize Sharpe Ratio Value Using LSTM," *Journal of Computer System and Informatics (JoSYC)*, vol. 4, no. 2, pp. 339–347, Feb. 2023, doi: 10.47065/josyc.v4i2.3065.
- [13] W. Febrianti, K. A. Sidarto, and N. Sumarti, "Solving Constrained Mean-Variance Portfolio Optimization Problems Using Spiral Optimization Algorithm," *International Journal of Financial Studies*, vol. 11, no. 1, Mar. 2023, doi: 10.3390/ijfs11010001.
- [14] J. Du, "Mean-variance portfolio optimization with deep learning based-forecasts for cointegrated stocks," *Expert Syst Appl*, vol. 201, Sep. 2022, doi: 10.1016/j.eswa.2022.117005.