

Pengelolaan *Portfolio* Investasi dengan Penerapan LSTM pada Sektor Strategis Indonesia dengan Evaluasi *Sharpe Ratio* dan *Mean Variance*

1st Daniel Pratama Manurung
Fakultas Informatika
Universitas Telkom
Bandung, Indonesia
danielman@student.telkomuniversity.ac.id

2nd Irma Palupi
Fakultas Informatika
Universitas Telkom
Bandung, Indonesia
irmapalupi@telkomuniversity.ac.id

Abstrak — Dalam teori *portfolio* modern, pemilihan dan diversifikasi *portfolio* 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 *portfolio* saham di Bursa Efek Indonesia (IDX) yang mencakup berbagai sektor, berdasarkan ukuran *Sharpe Ratio* dan *mean-variance portfolio*. 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 *portfolio* investasi melalui nilai *return* dan risiko *portfolio*. Hasil penelitian menunjukkan bahwa, berdasarkan prediksi rasio *Sharpe* untuk setiap komponen *portfolio*, 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 *portfolio* optimal untuk investasi bulanan dan jangka pendek.

Kata kunci— *long-short term memory*, diversifikasi *Portfolio*, faktor eksogen, ARIMA

I. PENDAHULUAN

Portfolio investasi merupakan manajemen aset *portfolio* 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 *portfolio* 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 *portfolio* 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 *portfolio* secara dinamik terhadap waktu. Metode LSTM digunakan untuk memprediksi komponen *portfolio* 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 *portfolio*. 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 *portfolio* 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 *portfolio*, 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 sebagai cara dalam alokasi dana yang optimal untuk *portfolio* 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 *portfolio* 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 hasilnya sangat kecil dan bagus [1]. Di waktu yang akan datang LSTM-DNN sangat mudah dalam memprediksi hasil dari suatu aset dan mengoptimasikan dalam *portfolio* berbagai aset untuk mendapatkan hasil yang terbaik [3].

A. Penentuan Sektor Strategis Indonesia dan Seleksi

Komponen Saham dalam *Portfolio*

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 *portfolio* investasi, terdapat beberapa pendekatan. Seleksi aset merupakan tahap penting dalam pembentukan *portfolio*, 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 *portfolio* 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 *portfolio* 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 *portfolio* 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), ω_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*), ω_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 risiko dalam *portfolio* investasi menggunakan variansi dari *return portfolio* maupun *mean-variance* tersebut dengan rumus berikut (6)

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

$\text{Var}(R_p)$ merupakan variansi *return portfolio* untuk menghitung risiko *portfolio*, lalu ω_i, ω_j masing-masing adalah bobot masing-masing aset), $\text{Cov}(R_i, R_j)$ adalah kovariansi antara *return* aset i dan aset j , dan n sebagai jumlah asetnya.

2. Optimasi Portfolio dan Memaksimalkan Sharpe Ratio

Dalam optimasi *portfolio*, 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 *portfolio* dibandingkan aset bebas risiko (*risk-free asset*), seperti obligasi pemerintah atau deposito. Formula *Sharpe Ratio* adalah seperti pada (7).

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

SR adalah nilai *Sharpe Ratio portfolio* saham, R_p *return portfolio* saham, R_f adalah *risk-free rate* yang merupakan tingkat imbal hasil deposito, dan σ adalah risiko *portfolio*. *Sharpe Ratio* digunakan untuk pembuatan *portfolio* investasi dan menentukan *return* aset yang terbaik. Nilai SR yang

lebih tinggi menunjukkan *portfolio* memberikan imbal hasil lebih baik per unit risiko yang diambil.

3. Pembobotan dan Normalisasi Bobot

Dalam pembobotan *portfolio* digunakan menggunakan *Modern Portfolio Theory* (MPT). MPT merupakan *portfolio* investasi yang membuat pembobotan lebih optimal dan alokasi aset yang sesuai. MPT dibuat oleh Markowitz untuk membuat *portfolio* 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 *portfolio* ditentukan secara urutan waktu, berdasarkan nilai sharp-ratio yang diprediksi. Misal untuk *portfolio* yang terdiri dari n komponen saham, $SR_i(t)$ merupakan nilai sharp ratio untuk komponen saham- i pada waktu t . Maka bobot *portfolio* 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 *portfolio* 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*), ϕ_i (koefisien *autoregressive*), θ_i (koefisien *moving average*), r_t (nilai *return* saham dalam waktu t), ε_t (nilai error) dan δ (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)

- *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 Eksogoneus 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 :

- i. *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-1.

- ii. *Relative Strength Index* (RSI) untuk *oscillator* 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.

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

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

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

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

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

- iv. *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 Preproession


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. Gambar 2 menunjukan nama-nama setiap emiten



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 risiko investor dalam berinvestasi. Model LSTM digunakan untuk memprediksi nilai dari *Sharpe Ratio* disetiap emiten yang telah dihitung. Nilai *Sharpe Ratio* 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 pergesaran 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 PREDIKSI LSTM)


Langkah	Deskripsi
1. Input	Dataset <i>multivariat</i> yang berisi variabel-variabel eksternal (exogenous) dan target (return saham)
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, time_steps, 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 <i>scaled</i> , lalu di- <i>inverse transform</i> 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 <i>return_sequences</i>
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 risiko masing-masing investor. *Portfolio* investasi tersebut bisa memaksimalkan hasil pengembalian aset dengan risiko cukup besar maupun risiko 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 risiko investor dalam berinvestasi dan membuat *portfolio* investasi yang memaksimalkan *return* maupun mengurangi risiko.

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 *portfolio* 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 *portfolio* 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. *Portfolio* 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 *portfolio* 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	FMIJ.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 portfolio* yang diproyeksikan. Berdasarkan *return portfolio* 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 *portfolio*. 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 *portfolio* 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 *portfolio*. 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 *PORTFOLIO* UNTUK *SINGLE-INPUT LSTM*)

2. Exogenous LSTM

Pada gambar 8 ditampilkan hasil prediksi nilai *Sharpe Ratio* dari setiap saham yang ada dalam *portfolio* 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 *portfolio*. 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 *PORTFOLIO* UNTUK *EXOGENOUS LSTM*)

TABEL 4.

(METRIK EVALUASI 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 *SHARPE 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 *portfolio*. 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 *portfolio*. 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 risiko investor. Simulasi porfolio dilakukan untuk Dalam simulasi *portfolio* yang sesuai dapat dilihat sebagai berikut :



GAMBAR 10.


(PERFORMA *PORTFOLIO* YANG DISIMULASIKAN)



GAMBAR 11.
(PERFORMA *PORTFOLIO* YANG DISIMULASIKAN
DALAM KUARTAL)



GAMBAR 12.
(PERFORMA *PORTFOLIO* YANG DISIMULASIKAN
DALAM BIANNUAL)



GAMBAR 13.
(PERFORMA *PORTFOLIO* YANG DISIMULASIKAN DALAM
TAHUNAN)

Pada gambar diatas, terdapat grafik performa *portfolio* saham dari emiten terpilih, yang dipresentasikan dengan nilai bobot *portfolio*, *return portfolio* dan risiko *portfolio*. Gambar 10-13 berturut-turut merupakan simulasi *portfolio* untuk periode bulanan, kuartal, *biannual*, dan *annual*. Terlihat bahwa risiko dari setiap *portfolio* investasi berkorelasi dengan *return* dari *portfolio* 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 *portfolio* selama beberapa skenario periode yaitu bulanan, kuartal, per 6 bulan, dan per tahun. Berdasarkan nilai rata-rata *return portfolio* dan akumulasinya, *portfolio* dengan keputusan di periode pendek memberikan kemungkinan imbal hasil yang lebih besar dibandingkan periode yang lebih lama. Hal ini berbanding sebaliknya dengan risiko *portfolio*, yang memberikan nilai risiko lebih rendah untuk periode *portfolio* 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 risiko dan memperoleh *return* yang besar. Dengan investasi menggunakan *portfolio* investasi 1 tahun memiliki *return* yang paling sedikit dibanding dengan *portfolio* 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 *portfolio* 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 *portfolio* 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 portofolio 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.