

Optimalisasi Portofolio Saham Syariah Berbasis Prediksi Menggunakan Long Short-Term Memory (LSTM)

(Studi Kasus: Saham-saham pada Indeks JII)

Erna Nurmawati¹, Rayhan Abaysa², Raditya Amanta Putra³

^{1,2,3} Program Studi Komputasi Statistik, Politeknik Statistika STIS Jl. Otto Iskandardinata No.64C, Jakarta 13330

Info Artikel

Riwayat Artikel:

Received 2025-02-06

Revised 2025-04-29

Accepted 2025-05-15

Abstract – Sharia stocks are one of the investment instruments that are increasingly in demand, especially by Muslim investors, as they adhere to Islamic financial principles. However, the challenge of selecting quality stocks to form an optimal portfolio is still an obstacle for many investors. Stock investors always want maximum return with minimum risk. This can be achieved by selecting quality stocks and forming an optimal stock portfolio. One approach to stock selection can be done is by predicting stock prices with the LSTM model. Stocks with the largest predicted return will be included in the portfolio optimized by the Mean-Variance (MV) method. As a comparison, the performance of the LSTM prediction-based portfolio is compared with a randomly selected stock portfolio and Equal Weight (EW) optimization. The results showed that the LSTM prediction-based portfolio optimized with the MV method showed the most optimal performance with a mean return and Sharpe ratio that was much higher than the random portfolio, as well as a relatively lower risk. This research is expected to contribute in helping investors build more effective investment strategies in Islamic stocks.

Keywords: LSTM; Optimization; Prediction; Stock; Shariah

Corresponding Author:

Erna Nurmawati

Email: erna.nurmawati@stis.ac.id




This is an open access article under the [CC BY 4.0](https://creativecommons.org/licenses/by/4.0/) license.

Abstrak – Saham syariah menjadi salah satu instrumen investasi yang semakin diminati, terutama oleh investor muslim karena menawarkan prinsip keuangan Islam. Namun, tantangan dalam memilih saham berkualitas untuk membentuk portofolio optimal masih menjadi kendala bagi banyak investor. Investor saham selalu menginginkan imbal balik yang maksimal dengan risiko seminimal mungkin. Hal tersebut dapat tercapai dengan menyeleksi saham yang berkualitas dan membentuk portofolio saham yang optimal. Salah satu pendekatan seleksi saham dapat dilakukan adalah dengan memprediksi harga saham dengan model LSTM. Saham dengan prediksi return terbesar akan dimasukkan ke dalam portofolio yang dioptimalisasi dengan metode Mean-Variance (MV). Sebagai pembandingan, kinerja portofolio berbasis prediksi LSTM dibandingkan dengan portofolio saham yang dipilih secara acak dan optimalisasi Equal Weight (EW). Hasil penelitian menunjukkan portofolio berbasis prediksi LSTM yang dioptimalkan dengan metode MV menunjukkan kinerja paling optimal dengan mean return dan Sharpe ratio yang jauh lebih tinggi dibandingkan portofolio acak, serta risiko yang relatif lebih rendah. Penelitian ini diharapkan dapat memberikan kontribusi dalam membantu investor membangun strategi investasi yang lebih efektif pada saham-saham syariah.

Kata Kunci: LSTM, Optimalisasi, Prediksi, Saham, Syariah.

I. PENDAHULUAN

Alokasi sumber daya atau kekayaan pada saat ini yang ditujukan untuk mendapat keuntungan pada masa yang akan datang dapat disebut investasi [1]. Saham merupakan salah satu jenis sektor finansial yang termasuk dalam investasi aset finansial. Saham berpotensi untuk memberikan tingkat imbal balik hasil yang tinggi sehingga menjadi salah satu instrumen investasi yang populer. Namun, timbal balik hasil (*return*) yang tinggi yang diperoleh dari saham diiringi dengan tingkat risiko yang tinggi pula [2]. Saham syariah merupakan salah satu jenis saham yang populer di Indonesia. Hal ini didukung kuat dengan pengaruh ajaran agama Islam (*sharia compliant*) [3]. Pertumbuhan investasi saham syariah juga didorong dengan peningkatan permintaan (*demand*) investor muslim. Investor muslim membutuhkan produk keuangan atau investasi yang sejalan dengan ajaran agama Islam [4]. Saham syariah mempunyai kinerja yang lebih baik dibandingkan dengan saham non-syariah ketika terjadi krisis keuangan [5]–[7]. Hal tersebut membuat kinerja saham syariah dapat dijadikan instrumen *hedging* pada saat terjadi krisis [6]. Selain dapat bekerja lebih baik di bawah krisis keuangan, risiko indeks syariah lebih kecil dibandingkan dengan indeks non-syariah terutama pada saat terjadi krisis [6]. Salah satu indeks saham syariah terbesar di Indonesia adalah Jakarta Islamic Index (JII). Jakarta Islamic Index terdiri dari 30 saham paling likuid dan konsisten di Indonesia yang dievaluasi setiap enam bulan dan merupakan indeks



Gambar 1. Tahapan Penelitian

saham yang memiliki kapitalisasi pasar yang besar dan dapat menjadi tolak ukur dalam memilih saham syariah [8].

Salah satu masalah yang sering dihadapi oleh analis investasi modal adalah penaksiran risiko [9]. Untuk meminimalkan risiko, diversifikasi saham dilakukan dengan membentuk portofolio. Pembentukan portofolio saham dapat memaksimalkan *return* dengan memperkecil tingkat risiko [10]. Selain membentuk portofolio, investor saham juga harus memiliki kemampuan untuk memilih saham yang tepat untuk mendapatkan *return* yang maksimal dengan tingkat risiko yang rendah [11]. Pemilihan saham yang tepat merupakan aspek paling fundamental bagi investor individu maupun institusi [12]. Pemilihan saham yang tepat sangat bergantung pada kinerja saham tersebut di masa depan [13] Maka dari itu, optimalisasi portofolio harus dilakukan mulai dari menentukan banyaknya saham dalam portofolio dan saham apa saja yang dipilih untuk menghasilkan *return* yang tinggi dengan tingkat risiko yang rendah.

Optimalisasi portofolio dibutuhkan untuk meningkatkan kinerja portofolio agar lebih maksimal dalam mendapatkan return dan lebih maksimal untuk meminimalkan risiko. Optimalisasi merupakan proses pemilihan proporsi saham yang masuk dalam portofolio [14]. Model *Mean-Variance* (MV) oleh Markowitz (1952) adalah model yang paling baik dan populer dalam mengoptimalkan portofolio [12]. Model ini dapat mengukur *return* dengan *expected return* dan risiko dengan varian sehingga dapat memudahkan investor dalam melakukan *trade-off* antara memaksimalkan *return* dan meminimalkan risiko. Dalam proses ini, pemilihan saham yang tepat menjadi langkah yang sangat krusial, mengingat komposisi saham dalam portofolio akan secara langsung memengaruhi potensi return dan tingkat risiko yang dihadapi investor. Pada penelitian ini, pemilihan saham dilakukan menggunakan model *Long-Short Term Memory* (LSTM), yang telah terbukti efektif dalam memprediksi pergerakan harga saham, baik untuk saham syariah maupun non-syariah [15]–[20]. Pembentukan portofolio saham syariah dengan melakukan seleksi saham yang tepat sangat penting dilakukan. Saham-saham yang terpilih dalam portofolio terbaik yang dihasilkan dari penelitian ini berbasis prediksi dengan model LSTM dengan sebelumnya dilakukan optimalisasi portofolio saham menggunakan metode *Mean-Variance* (MV).

Penelitian ini bertujuan untuk mendapatkan portofolio saham yang optimal dari indeks JII dengan memaksimalkan *return* dan meminimalkan tingkat risiko. Dengan mempertimbangkan keunggulan saham syariah yang mampu memberikan kinerja lebih stabil, khususnya pada masa krisis ekonomi, penelitian ini diharapkan dapat menjadi referensi bagi investor, baik investor muslim maupun non-muslim, dalam berinvestasi secara lebih efektif di pasar saham syariah. Selain itu, seiring bertambahnya jumlah investor saham muslim, penelitian ini diharapkan mampu membantu investor saham untuk berinvestasi di JII dengan *return* yang maksimal dan tingkat risiko seminimal mungkin.

TABEL 1
FORMULA INDIKATOR TEKNIKAL

<i>Indikator</i>	<i>Formula</i>
Simple 10-day moving average (SMA)	$\frac{C_t + C_{t-1} + C_{t-2} + \dots + C_{t-10}}{10}$
Weighted 10-day moving average (WMA)	$\frac{10C_t + 9C_{t-1} + 8C_{t-2} + \dots + C_{t-10}}{10}$
Exponential 10-day moving average (EMA)	$(C_t \times \alpha) + (EMA_{t-1} \times (1 - \alpha))$
Moving Average Convergence Divergence (MACD)	$EMA_{12}(t) - EMA_{26}(t)$
Relative Strength Index (RSI)	$100 - \left(\frac{100}{1 + \frac{n_{up}}{n_{down}}} \right)$
Rate of Change 10-day (ROC)	$\frac{C_t - C_{t-10}}{10}$
Momentum 10-day	$C_t - C_{t-10}$

II. METODE

Dalam penelitian ini, ada beberapa tahapan untuk membangun dan menguji model prediksi serta optimalisasi portofolio saham. Langkah awal melibatkan pengumpulan data saham syariah yang diperoleh dari situs web *Yahoo Finance*. Tahapan selanjutnya adalah membentuk indikator teknikal yang digunakan sebagai variabel eksogen. Pemisahan data *training* dan *testing* dilakukan kepada seluruh variabel dalam *dataset*. Data *training* digunakan untuk melakukan *hyperparameter tuning* untuk mendapatkan model terbaik. Data *testing* digunakan untuk melakukan prediksi dan optimalisasi portofolio. Penelitian ini diakhiri dengan melakukan evaluasi pada portofolio yang terbentuk. Tahapan penelitian secara umum digambarkan melalui diagram alir pada Gambar 1.

A. Pembangunan Dataset

Penelitian ini menggunakan data sekunder yang diambil dari situs *website* resmi Yahoo Finance di <https://finance.yahoo.com/>. Data saham yang diambil meliputi *Open*, *Low*, *High*, *Close*, *Adjusted Close*, dan *Volume*. Data saham yang dikumpulkan merupakan data harian dari seluruh saham yang terdaftar pada indeks JII30 periode efektif 3 Juni 2024 hingga 29 November 2024. Rentang waktu pengambilan data dimulai dari Januari 2020 hingga Desember 2023, dengan total sebanyak 974 baris data.

Proses *preprocessing* dilakukan pada *dataset* dengan melakukan pembatasan rentang waktu. Rentang waktu yang digunakan mulai dari tanggal 1 Januari 2020 hingga 31 Desember 2023. Apabila saham dibentuk setelah rentang waktu yang ditetapkan, saham dihilangkan dari *dataset*.


Indikator teknikal dalam penelitian ini didefinisikan sebagai angka yang menggambarkan kecenderungan pergerakan harga saham [21]. Angka dihitung berdasarkan data historis saham seperti *Open*, *Low*, *High*, *Close*, *Adjusted Close*, dan *Volume*. Indikator teknikal ini sering digunakan pada penelitian serupa seperti pada penelitian [22] dan [23]. Formula indikator teknikal yang digunakan pada penelitian ini dapat dilihat pada Tabel 1. Dimana C_t adalah variabel Close waktu ke- t ; α adalah *smoothing parameter* dengan rumus $\frac{2}{1+10}$; n_{up} adalah jumlah keuntungan 14 hari sebelumnya; dan n_{down} adalah jumlah kerugian 14 hari sebelumnya. Tujuh indikator teknikal dan data historis Close digunakan sebagai variabel eksogen untuk memprediksi nilai variabel targetnya yaitu variabel harga *Close*. Setelah terbentuk, transformasi data dilakukan dengan metode *Min-max Normalization* rentang 0 sampai 1.

Proses selanjutnya adalah pemisahan (*splitting*) data *training* dan *testing*. Data *training* digunakan untuk melatih model dan *hyperparameter tuning*. Data yang digunakan mulai bulan Januari 2020 hingga bulan Desember 2022 dengan total baris sebanyak 735 baris. Data *testing* digunakan untuk mengevaluasi hasil model terbaik yang diambil sepanjang tahun 2023 dengan total baris berjumlah 239 baris.

B. Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) merupakan perkembangan dari *Recurrent Neural Network* (RNN) yang dapat mengingat informasi pada saat itu dan informasi urutan sebelumnya. LSTM memberikan solusi dalam mengatasi *gradient* yang semakin membesar atau mengecil pada RNN dengan menggunakan *forget gates* [24]. *Forget gates* mempunyai kemampuan untuk belajar mereset blok memori ketika isi dari blok sudah kadaluwarsa dan kurang berguna.

Struktur lengkap LSTM terdiri dari tiga pintu yaitu, *input gate*, *forget gate*, dan *output gate*. *Input gate* berperan dalam *memory cell* untuk merekam informasi baru ke dalam *cell states* baru secara selektif. *Forget gate* berguna untuk mengingat status dari *memory cell* dan melupakan informasi pada *memory cells* secara selektif. *Output gate* berperan sebagai jaringan terakhir yang bekerja pada *input* dan *output* dari *hidden layer* untuk menghasilkan hasil akhir yang mencakup status *cell* dan input. Ketiga “pintu” ini memungkinkan LSTM untuk memutuskan informasi mana yang harus dilupakan dan dipertahankan secara efektif [25]. Arsitektur LSTM dapat dilihat pada



Sumber: Colah
Gambar 2. Arsitektur LSTM [26]

Formula operasi LSTM adalah sebagai berikut [27]:

$$\text{Forget gate: } \mathbf{f}_t = \sigma(\mathbf{W}_f \mathbf{x}_t + \mathbf{U}_f \mathbf{h}_{t-1} + \mathbf{b}_f) \quad (1)$$

$$\text{Input gate: } \mathbf{i}_t = \sigma(\mathbf{W}_i \mathbf{x}_t + \mathbf{U}_i \mathbf{h}_{t-1} + \mathbf{b}_i) \quad (2)$$

$$\text{Output gate: } \mathbf{o}_t = \sigma(\mathbf{W}_o \mathbf{x}_t + \mathbf{U}_o \mathbf{h}_{t-1} + \mathbf{b}_o) \quad (3)$$

$$\tilde{\mathbf{c}}_t = \tanh(\mathbf{W}_c \mathbf{x}_t + \mathbf{U}_c \mathbf{h}_{t-1} + \mathbf{b}_c) \quad (4)$$

$$\mathbf{c}_t = \mathbf{f}_t \mathbf{c}_{t-1} + \mathbf{i}_t \tilde{\mathbf{c}}_t \quad (5)$$

$$\mathbf{h}_t = \mathbf{o}_t \tanh(\mathbf{c}_t) \quad (6)$$

\mathbf{W}_q dan \mathbf{U}_q merupakan matriks bobot dan koneksi berulang, dengan indeks *input gate* i , *output gate* o , *forget gate* f ataupun *memory cells* c , tergantung pada aktivasi yang dihitung. $\mathbf{c}_t \in \mathbb{R}^h$ tidak hanya sel LSTM saja tetapi berisi sel h dalam unit LSTM, sementara \mathbf{i}_t , \mathbf{o}_t , dan \mathbf{f}_t menjelaskan aktivasi dari *input*, *output*, dan *forget gate* pada waktu ke- t . Melalui mekanisme ini, LSTM dapat mempertahankan informasi penting dalam data deret waktu, bahkan ketika terdapat jeda panjang antara peristiwa penting. Kemampuan ini menjadikan LSTM sangat efektif digunakan dalam berbagai tugas seperti prediksi data deret waktu, pemrosesan teks, serta pengenalan pola pada data sekuensial.

C. Hyperparameter Tuning

Model *deep learning* seperti LSTM memiliki *hyperparameter* yang harus disesuaikan untuk mendapatkan hasil yang optimal. Penelitian ini menggunakan algoritma GridSearchCV dengan *5-fold cross validation* untuk menemukan kombinasi *hyperparameter* terbaik. Dalam proses ini, *dataset* dibagi secara otomatis menjadi lima *subset* masing-masing berjumlah sekitar 147 baris, di mana pada setiap iterasi, empat *subset* digunakan untuk pelatihan dan satu *subset* digunakan untuk validasi, sehingga memungkinkan evaluasi model yang lebih *robust* terhadap variasi data. Proses pencarian kombinasi *hyperparameter* optimal dilakukan dengan menggunakan rata-rata Mean Squared Error (MSE) dari kelima iterasi sebagai metrik scoring pada GridSearchCV. *Hyperparameter* yang dioptimalisasikan meliputi *neurons*, *learning rate*, jumlah *epoch*, *dropout rate*, *batch size*, dan *time steps* [28]. Tabel 2 menunjukkan nilai *hyperparameter* yang dimasukkan ke dalam algoritma GridSearchCV.

- Neurons*: *Neurons* merupakan bagian dari model LSTM yang berfungsi untuk mengingat informasi yang akan diingat atau dilupakan. Jumlah *neurons* yang terlalu sedikit membuat model kurang dapat mengingat informasi yang penting pada saat melakukan prediksi. Sebaliknya, jumlah *neurons* yang terlalu banyak juga menyebabkan model *overfit* pada data *training* [29].
- Learning rate*: *hyperparameter* ini merupakan *hyperparameter* yang sangat penting dalam model. *Hyperparameter* ini mengatur sejauh mana bobot model akan berubah. Pemilihan *learning rate* terbaik akan menghasilkan model dengan performa tinggi [29].
- Epoch*: arti satu *epoch* adalah satu iterasi proses pelatihan. *Hyperparameter* ini digunakan untuk melihat pola yang tersembunyi pada data *training*. Nilai yang terlalu kecil akan membuat model tidak dapat menangkap pola dan nilai yang terlalu besar akan mengakibatkan *overfitting*.

TABEL 2
KOMBINASI HYPERPARAMETER

Hyperparameter	Nilai
Neurons	50, 100, 200, 500
Learning Rate	0,0001, 0,001, 0,01
Epoch	100, 250, 500
Dropout Rate	0,1, 0,2
Batch Size	32, 64,128
Time Steps	10, 15, 20, 25, 30

- d) *Dropout rate*: layer *dropout* ditambahkan untuk mencegah terjadi *overfitting* pada data *training* [30].
- e) *Batch size*: ukuran atau jumlah sampel yang akan digunakan dalam proses satu iterasi untuk memperbarui parameter.
- f) *Time steps*: jumlah data historis yang akan digunakan untuk melakukan prediksi. *Hyperparameter* ini berdampak besar pada kinerja prediksi model [31].

Penelitian ini menggunakan algoritma optimalisasi bernama Adam atau *Adaptive Moment Estimation*. Adam telah teruji memiliki kinerja baik dalam mengoptimalkan model *neural network* [29], [32], [33]. Jumlah *layer LSTM* pada penelitian ini berjumlah satu. Dengan *dense output layer* berjumlah satu unit, hasil prediksi adalah prediksi satu hari ke depan. Dengan *dense layer* sejumlah satu, prediksi pada data *testing* dilakukan untuk satu hari ke depan selama 12 bulan tersebut. Prediksi harga saham (Close) pada data *testing* dilakukan dengan memasukkan data historis ketujuh indikator teknikal dan data historis Close sebagai variabel *input*. Proses ini dilakukan secara terus menerus hingga diperoleh seluruh nilai Close pada data *testing*. *Hyperparameter tuning* hanya akan dilakukan pada data saham PTBA.JK karena keterbatasan sumber daya.

D. Optimalisasi Portofolio

Optimalisasi portofolio dimulai dengan menghitung rata-rata *return* dari harga saham yang diprediksi. *Return* dapat dihitung dengan persamaan sebagai berikut:

$$\hat{r}_t = \frac{\hat{p}_t - \hat{p}_{t-1}}{\hat{p}_t} \quad (7)$$

dimana \hat{r}_t adalah *return* saham pada waktu ke- t dan \hat{p}_t adalah prediksi harga saham pada waktu ke- t .

Saham diurutkan berdasarkan rata-rata *return* harian terbesar dari hasil prediksi. Sejumlah (N) saham dipilih dari hasil urutan tersebut yang masuk ke dalam portofolio.

Hasil portofolio dioptimalisasi dengan metode MV. Metode ini digunakan untuk meminimalkan risiko pada portofolio. Formula MV adalah sebagai berikut [13]:

$$\min SD_p = \min v' \Sigma v \quad (8)$$

$$\begin{cases} v' \mu = R_p \\ v' 1 = 1 \\ 0 \leq v_i \leq 1, \forall i = 1, \dots, q \end{cases} \quad (9)$$

dimana SD_p adalah estimasi risiko portofolio; v merupakan vektor bobot saham berukuran $1 \times q$; Σ melambangkan matriks kovarian *return* berukuran $q \times q$; 1 merepresentasikan vektor yang semua elemennya memiliki nilai 1; R_p adalah estimasi *return* saham; dan q merepresentasikan total jumlah saham.

E. Evaluasi Hasil

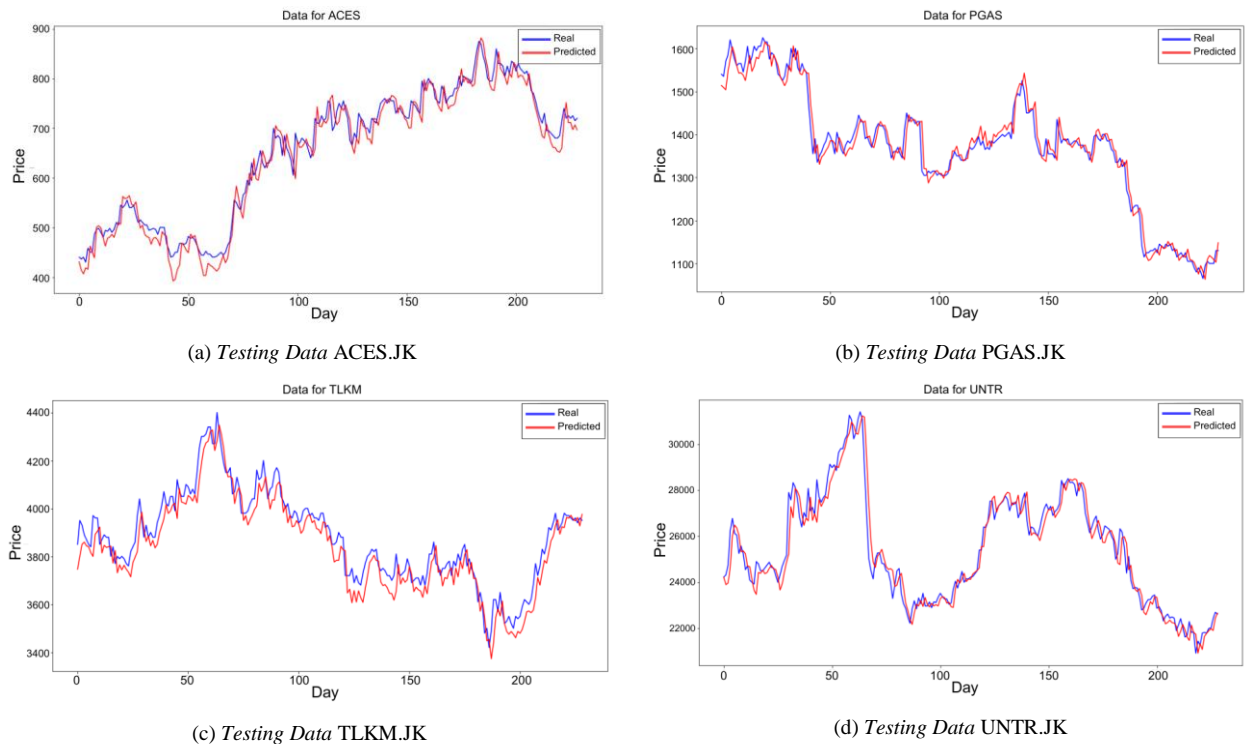
Metrik evaluasi yang sering digunakan dalam model prediksi saham adalah *Root-Mean-Square Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE) [34]. Persamaan ketiga matriks evaluasi tersebut adalah sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (10)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (11)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{y}_i - y_i|}{y_i} \quad (12)$$

dimana y_i merupakan nilai asli; \hat{y}_i melambangkan nilai hasil prediksi; dan n adalah total sampel.



Gambar 3. Perbandingan Hasil Prediksi dengan *Testing Data*

Kinerja portofolio dievaluasi menggunakan tiga metrik evaluasi lain, yaitu *Sharpe Ratio*, *mean return*, dan standar deviasi portofolio. Metrik evaluasi tersebut sering dan berkinerja baik dalam mengevaluasi dan membandingkan kinerja portofolio [13], [35], [36]. *Sharpe ratio* dapat dihitung melalui persamaan berikut:

$$SR = \frac{R_p - RF}{SD_p} \quad (13)$$

dengan *RF* adalah rata-rata *return* investasi bebas risiko. Rasio *risk-free* yang ditetapkan pada penelitian ini sebesar 6,7% sesuai dengan imbal hasil obligasi Indonesia selama 10 tahun terakhir.

III. HASIL DAN PEMBAHASAN

A. Prediksi Harga Saham JII

Model LSTM paling optimal didapatkan dari *hyperparameter* terbaik dengan jumlah *neurons* sebanyak 100, *learning rate* sebesar 0,01, *epoch* sejumlah 100, *dropout rate* sebesar 0,2, *batch size* berjumlah 64, dan *time steps* sebanyak 10. Dari 1080 kombinasi *hyperparameter* yang terbentuk, sepuluh kombinasi *hyperparameter* terbaik dapat dilihat pada TABEL . Model ini digunakan untuk memprediksi data harga saham pada data *testing* yaitu selama satu tahun atau 12 bulan.

Gambar 3 merupakan contoh perbandingan hasil prediksi saham ACES.JK, PGAS.JK, dan TLKM.JK menggunakan model LSTM paling optimal dan data *testing* selama 12 bulan. Model LSTM untuk saham ACES.JK memiliki nilai RMSE 622.538, MAE 19.631, dan MAPE 3,16%. Hasil evaluasi saham PGAS.JK dengan model LSTM optimal memiliki nilai RMSE 681.072, MAE 18.970, dan MAPE 1,38%. Sedangkan untuk saham TLKM.JK, hasil evaluasi model LSTM memiliki nilai RMSE 4339.411, MAE 54.672, dan MAPE 1,41%. Hasil evaluasi lengkap 25 saham dalam indeks JII dapat dilihat pada TABEL .

Berdasarkan nilai MAPE, model LSTM dapat dengan sangat baik memprediksi seluruh saham yang ada pada indeks JII karena nilai MAPE yang dihasilkan <10% [37]. Saham dengan tingkat kesalahan prediksi terendah ada pada saham INDF.JK dengan nilai 0,98% dan tingkat kesalahan prediksi tertinggi ada pada saham MAPI.JK dengan nilai 4,08%.

TABEL 3
EVALUASI HASIL KOMBINASI HYPERPARAMETER LSTM DIURUTKAN BERDASARKAN RATA-RATA MSE
(Semakin tinggi nilai rata-rata MSE, semakin buruk kombinasi *hyperparameter*)

Batch Size	Epochs	Dropout Rate	Learning Rate	Neurons	Time Step	Rata-rata MSE	Rank
64	100	0,2	0,01	100	10	0,000678091	1
64	100	0,1	0,01	50	15	0,000708083	2
128	100	0,1	0,01	100	20	0,000735199	3
64	100	0,2	0,01	100	15	0,000735274	4
64	100	0,2	0,01	200	10	0,000772805	5
128	250	0,2	0,01	100	20	0,000776553	6
64	100	0,1	0,01	100	15	0,000792437	7
32	100	0,2	0,01	200	10	0,000795205	8
64	100	0,1	0,01	100	30	0,000809306	9
32	100	0,2	0,01	50	10	0,000811402	10

TABEL 4
EVALUASI HASIL PREDIKSI MODEL LSTM DIURUTKAN BERDASARKAN MAPE
(Rendahnya nilai MAPE menunjukkan sedikitnya kesalahan dalam prediksi)

No.	Kode Saham	RMSE	MAE	MAPE (%)	No.	Kode Saham	RMSE	MAE	MAPE (%)
1	INDF.JK	7276,845	66,459	0.98	14	SMGR.JK	25623,042	130,982	2.00
2	ICBP.JK	36938,696	141,009	1.30	15	ANTM.JK	2223,904	38,841	2.03
3	PGAS.JK	681,072	18,971	1.38	16	INKP.JK	70010,979	188,049	2.17
4	TLKM.JK	4339,412	54,673	1.41	17	PTBA.JK	11970,015	72,584	2.33
5	CPIN.JK	10723,102	76,949	1.47	18	ITMG.JK	1079996,726	790,421	2.74
6	ASII.JK	12841,124	90,264	1.47	19	BRMS.JK	44,334	4,945	2.87
7	UNVR.JK	7481,677	64,852	1.61	20	MDKA.JK	14060,935	90,025	2.87
8	UNTR.JK	360374,113	416,006	1.62	21	BRPT.JK	3061,192	32,390	2.97
9	INCO.JK	15077,089	96,381	1.63	22	ACES.JK	622,539	19,631	3.16
10	AKRA.JK	984,465	23,591	1.65	23	EXCL.JK	6514,817	67,739	3.19
11	BRIS.JK	1676,240	28,819	1.77	24	MEDC.JK	2739,307	37,643	3.21
12	KLBF.JK	1983,732	35,309	1.81	25	MAPI.JK	7607,014	72,210	4.08
13	ADRO.JK	4625,426	52,388	1.99					

B. Pembentukan Portofolio dan Optimalisasi

Portofolio dibentuk dari saham yang memiliki hasil prediksi *return* tertinggi yang ada pada TABEL 5. Apabila jumlah saham dalam portofolio terlalu banyak maka tingkat kesulitan dalam mengontrol dan mengelola portofolio akan tinggi. Sulitnya mengontrol dan mengelola portofolio dengan jumlah saham yang terlalu banyak biasanya dirasakan oleh investor individu. Penelitian [35] mendapatkan hasil bahwa portofolio dengan tujuh saham menunjukkan kinerja yang paling optimal. Sedangkan, penelitian [38] mengemukakan bahwa investor individu umumnya memiliki tiga atau empat saham dalam portofolionya. Di sisi lain, penelitian [20] menyatakan bahwa sepuluh saham dalam portofolio adalah jumlah yang paling optimal daripada jumlah saham lainnya. Penelitian ini menggunakan $N \in \{4, 5, 6, 7, 8, 9, 10\}$ dengan N adalah jumlah saham dalam portofolio. TABEL 4 menunjukkan daftar saham untuk masing-masing N . Untuk mengetahui lebih lanjut perbedaan pembentukan portofolio menggunakan hasil prediksi *return* model LSTM dan tidak, portofolio dengan saham *random* berjumlah N dibentuk sebagai pembanding. Pengambilan saham *random* dilakukan dengan mengurutkan kode saham berdasarkan abjad lalu diambil angka *random* yang merepresentasikan kode saham. Saham yang terpilih pada portofolio saham *random* ada pada TABEL 5.

TABEL 3
HASIL PREDIKSI RETURN SAHAM
(Semakin tinggi nilai *return* menunjukkan saham yang baik untuk diinvestasikan)

No.	Kode Saham	Return	No.	Kode Saham	Return	No.	Kode Saham	Return
1	BRPT.JK	0,002955	10	ICBP.JK	0,000182	19	PGAS.JK	-0,001046
2	ACES.JK	0,002866	11	INKP.JK	0,000131	20	KLBF.JK	-0,001050
3	MAPI.JK	0,001472	12	INDF.JK	-0,000055	21	UNVR.JK	-0,001051
4	BRIS.JK	0,001397	13	UNTR.JK	-0,000119	22	PTBA.JK	-0,001142
5	BRMS.JK	0,000850	14	SMGR.JK	-0,000395	23	ITMG.JK	-0,001288
6	AKRA.JK	0,000513	15	EXCL.JK	-0,000406	24	MDKA.JK	-0,001978
7	MEDC.JK	0,000465	16	ADRO.JK	-0,000631	25	INCO.JK	-0,002109
8	TLKM.JK	0,000341	17	CPIN.JK	-0,000739			
9	ASII.JK	0,000222	18	ANTM.JK	-0,000778			

TABEL 4
SAHAM-SAHAM DALAM PORTOFOLIO HASIL PREDIKSI MODEL LSTM

<i>N</i>	<i>Saham</i>
4	BRPT.JK, ACES.JK, MAPI.JK, BRIS.JK
5	BRPT.JK, ACES.JK, MAPI.JK, BRIS.JK, BRMS.JK
6	BRPT.JK, ACES.JK, MAPI.JK, BRIS.JK, BRMS.JK, AKRA.JK
7	BRPT.JK, ACES.JK, MAPI.JK, BRIS.JK, BRMS.JK, AKRA.JK, MEDC.JK
8	BRPT.JK, ACES.JK, MAPI.JK, BRIS.JK, BRMS.JK, AKRA.JK, MEDC.JK, TLKM.JK
9	BRPT.JK, ACES.JK, MAPI.JK, BRIS.JK, BRMS.JK, AKRA.JK, MEDC.JK, TLKM.JK, ASII.JK
10	BRPT.JK, ACES.JK, MAPI.JK, BRIS.JK, BRMS.JK, AKRA.JK, MEDC.JK, TLKM.JK, ASII.JK, ICBP.JK

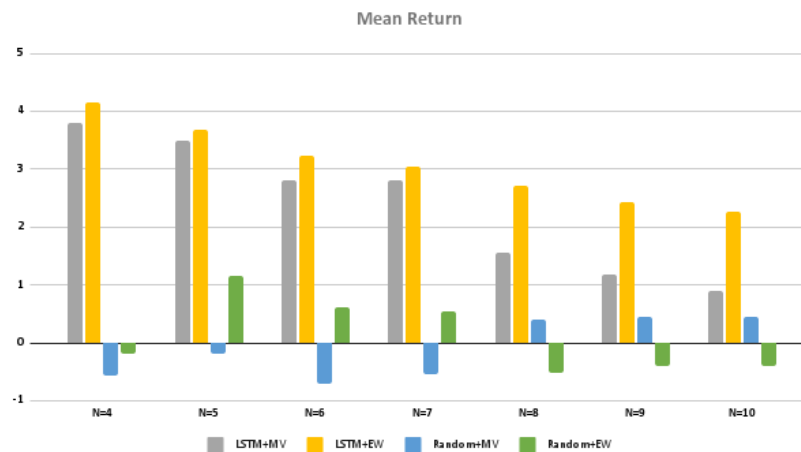
TABEL 5
SAHAM-SAHAM DALAM PORTOFOLIO RANDOM

<i>N</i>	<i>Saham</i>
4	PTBA.JK, ANTM.JK, ACES.JK, CPIN.JK
5	PTBA.JK, ANTM.JK, ACES.JK, CPIN.JK, BRPT.JK
6	PTBA.JK, ANTM.JK, ACES.JK, CPIN.JK, BRPT.JK, UNVR.JK
7	PTBA.JK, ANTM.JK, ACES.JK, CPIN.JK, BRPT.JK, UNVR.JK, ASII.JK
8	PTBA.JK, ANTM.JK, ACES.JK, CPIN.JK, BRPT.JK, UNVR.JK, ASII.JK, UNTR.JK
9	PTBA.JK, ANTM.JK, ACES.JK, CPIN.JK, BRPT.JK, UNVR.JK, ASII.JK, UNTR.JK, AKRA.JK
10	PTBA.JK, ANTM.JK, ACES.JK, CPIN.JK, BRPT.JK, UNVR.JK, ASII.JK, UNTR.JK, AKRA.JK, INKP.JK

Metode *Mean-Variance* (MV) diimplementasikan untuk mengoptimalkan kedua portofolio saham. Sebagai pembandingan, metode bobot sama rata atau *equal weight* (EW) juga diimplementasikan. Kedua metode ini dibandingkan untuk melihat perbedaan penggunaan bobot optimal (MV) dan bobot sama rata (EW).

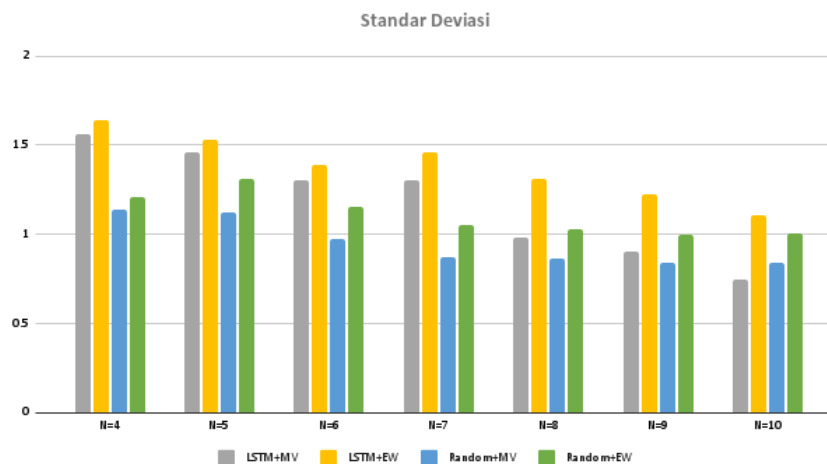
Gambar 4 menunjukkan kinerja *mean return* portofolio tiap model dan metode optimisasi berdasarkan nilai *N*. Pada portofolio LSTM, metode EW terlihat lebih unggul dibandingkan metode MV. Titik tertinggi metode MV dan EW sama pada nilai $N=4$ dan titik terendah juga pada nilai *N* yang sama yaitu 10. *Mean return* semakin menurun seiring bertambahnya nilai *N* pada portofolio LSTM. Berbeda dengan portofolio LSTM, portofolio *random* memberikan hasil metode EW lebih unggul pada $N<8$ sedangkan metode MV unggul pada $N>7$. Perbedaan lain terletak pada nilai *mean return* portofolio *random* yang ada pada nilai negatif baik pada

metode EW dan MV. Secara keseluruhan, portofolio LSTM memiliki nilai *mean return* yang tinggi jika dibandingkan dengan portofolio *random* dan metode EW bekerja lebih baik untuk optimalisasi nilai *mean return*.



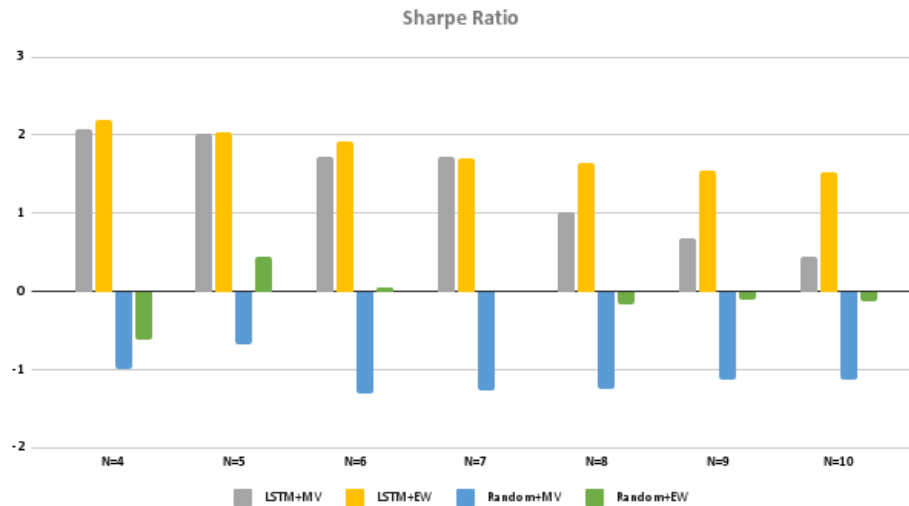
Gambar 4. Mean Return Bulanan Portofolio dengan N
(Semakin tinggi nilai *mean return* semakin baik portofolio yang dibentuk)

Standar deviasi portofolio LSTM pada Gambar 5 menunjukkan hasil yang serupa dengan *mean return* di mana nilai standar deviasi metode EW lebih besar dibandingkan metode MV. Dalam konteks prediksi harga saham, nilai standar deviasi yang besar menandakan risiko yang lebih tinggi sehingga dapat mempengaruhi kinerja portofolio. Nilai standar deviasi metode MV akan berkurang seiring bertambahnya nilai N yang sedikit berbeda dengan metode EW yang naik pada $N=7$ lalu kembali menurun. Nilai standar deviasi portofolio *random* menunjukkan hal yang tidak jauh berbeda dengan portofolio LSTM di mana metode MV unggul dalam semua nilai N dan EW memiliki kenaikan standar deviasi ketika $N=5$ yang kemudian kembali menurun. Secara keseluruhan, portofolio *random* memiliki nilai standar deviasi yang jauh lebih kecil dibandingkan portofolio LSTM.



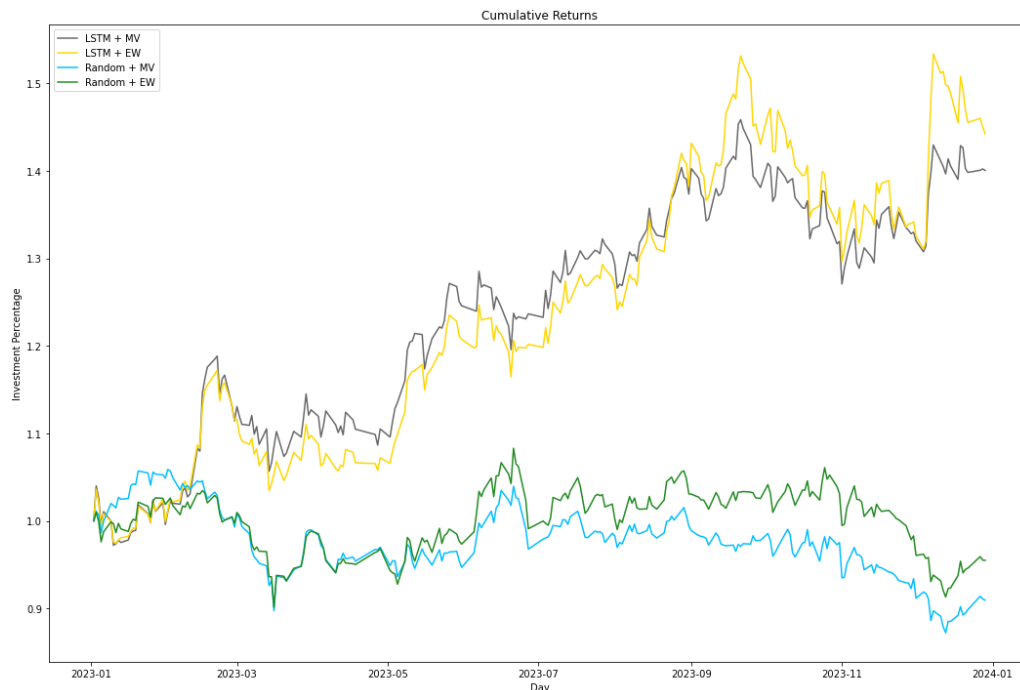
Gambar 5. Standar Deviasi Bulanan Portofolio dengan N
(Semakin tinggi nilai standar deviasi semakin buruk portofolio yang dibentuk)

Pada Gambar 6, portofolio LSTM+EW menunjukkan nilai *sharpe ratio* yang stabil menurun untuk setiap nilai N sedangkan portofolio LSTM+MV mengalami penurunan nilai yang signifikan pada $N=8$ dan terus menurun secara signifikan sampai $N=10$. Baik menggunakan metode MV atau EW pada portofolio LSTM, nilai *sharpe ratio* tertinggi ada pada $N=4$ dan terendah ada pada $N=10$. Semua nilai *sharpe ratio* pada portofolio *random* bernilai negatif kecuali pada portofolio *random+EW* dengan $N=5$ dan $N=6$. Dilihat dari nilai *sharpe ratio*, metode EW lebih mampu memberikan nilai yang lebih tinggi dibandingkan metode MV.



Gambar 6. Sharpe Ratio Bulanan Portofolio dengan N (Semakin tinggi semakin baik portofolio yang dibentuk)

Dapat disimpulkan, ukuran portofolio $N=4$ dapat menjadi ukuran portofolio yang optimal dilihat dari tiga kriteria yang digunakan. Model LSTM+MV dengan $N=4$ dapat dikatakan sebagai model yang paling optimal. Meskipun nilai *sharpe ratio* dan *mean return*-nya lebih kecil dibandingkan model LSTM+EW, risiko portofolio LSTM+MV lebih kecil dibandingkan portofolio LSTM+EW yang membuat portofolio tersebut lebih mudah untuk dikelola. Hasil ukuran portofolio ini sejalan dengan penelitian [38] yang menyebutkan bahwa investor individu memiliki tiga atau empat saham dalam satu portofolio. Untuk analisis lebih lanjut, digunakan portofolio dengan $N=4$.



Gambar 7. Pertumbuhan Portofolio pada Simulasi Saham

Selanjutnya, seluruh portofolio dilakukan simulasi pertumbuhan portofolio pada periode *testing* yaitu tahun 2023. Masing-masing model diberikan nilai awal sebesar 1,0 dan plot seluruh portofolio dapat dilihat pada Gambar 7. Strategi portofolio LSTM+EW terlihat unggul dibandingkan strategi portofolio lain dengan keuntungan mencapai lebih dari 1,5 nilai awal. *Cumulative return* strategi LSTM+MV tepat berada dibawah LSTM+EW dengan risiko yang sedikit lebih rendah dilihat dari kestabilan laju grafik yang tidak terlalu menanjak ke atas atau pun menanjak ke bawah. Hal ini sesuai dengan teori *high risk, high return* yang menyebutkan bahwa

keuntungan yang tinggi akan diiringi dengan risiko yang tinggi pula. Performa strategi random+MV dan random+EW terlihat menunjukkan hasil yang kurang baik dengan laju grafik yang menurun dari nilai awalnya.

TABEL 6 menunjukkan bobot seluruh saham dari portofolio yang diusulkan dalam penelitian ini, yaitu LSTM+MV dengan $N=4$. Saham dengan bobot tertinggi ada pada saham BRIS.JK dengan bobot 36,7% dari keseluruhan nilai investasi. Diikuti dengan saham MAPI.JK sebesar 25,5%, ACES.JK sebesar 23,1%, dan BRPT.JK sebesar 14,5%.

TABEL 6
BOBOT SAHAM PADA STRATEGI LSTM+MV

<i>Saham</i>	<i>Bobot</i>
BRIS.JK	0,367
MAPI.JK	0,255
ACES.JK	0,231
BRPT.JK	0,145

IV. SIMPULAN

Model LSTM dapat digunakan untuk memprediksi semua harga saham pada indeks JII dengan akurat. Hal ini dapat dilihat dari nilai MAPE yang bernilai $<10\%$, dengan nilai MAPE terendah sebesar 0,98% pada saham INDF.JK dan nilai MAPE tertinggi sebesar 4,08% pada saham MAPI.JK.

Prediksi harga saham membentuk rata-rata *return* harian untuk setiap saham yang diurutkan dari yang tertinggi dan terendah. Saham dengan nilai prediksi *return* tertinggi dimasukkan ke dalam portofolio yang dioptimalisasi menggunakan metode *Mean-Variance (MV)* dan *Equal Weight (EW)*. Jumlah saham dalam portofolio berjumlah $N \in \{4,5,6,7,8,9,10\}$ dengan N merepresentasikan jumlah saham. Portofolio dengan $N=4$ menunjukkan hasil yang paling optimal dengan seimbangannya nilai *mean return*, standar deviasi, dan *sharpe ratio*.

Portofolio berbasis prediksi menunjukkan kinerja yang lebih memuaskan dibandingkan dengan portofolio yang dipilih secara acak. Hal ini dapat dilihat dari nilai *mean return* dan *sharpe ratio* portofolio LSTM yang terpaut sangat jauh dibandingkan portofolio acak dengan risiko yang sedikit lebih tinggi. Metode optimalisasi MV juga berperan penting dalam meningkatkan kinerja portofolio. Portofolio berbasis LSTM dengan metode optimalisasi MV menunjukkan hasil yang paling optimal dengan risiko yang paling rendah.

Pengembangan penelitian selanjutnya dapat mengkaji penggunaan model *hybrid* seperti LSTM+XGBoost atau eksplorasi teknik optimalisasi portofolio yang lebih kompleks seperti model Black-Litterman juga dapat dipertimbangkan untuk menghasilkan portofolio dengan kinerja yang lebih optimal.

DAFTAR PUSTAKA

- [1] E. Tandelilin, *Portofolio dan Investasi: Teori dan aplikasi*. Yogyakarta: Kanisius, 2010. [Online]. Available: https://scholar.google.com/citations?view_op=view_citation&hl=id&user=F40fW3gAAAAJ&citation_for_view=F40fW3gAAAAJ:bEWYMUwI8FkC
- [2] M. Ramadhan, T. Suharti, and I. Nurhayati, "Diversifikasi Saham Dalam Pembentukan Portofolio Untuk Meminimumkan Risiko," *Manag. J. Ilmu Manaj.*, vol. 3, no. 4, p. 450, 2020, doi: 10.32832/manager.v3i4.3914.
- [3] F. K. Mubarak, A. R. Darmawan, and Z. Luailiyah, "Optimalisasi Portofolio Nilai Saham: Studi Komparasi Kinerja Saham Syariah dan Nonsyariah," *Econ. J. Ekon. Islam*, vol. 8, no. 2, pp. 309–336, 2017, doi: 10.21580/economica.2017.8.2.2368.
- [4] U. Derigs and S. Marzban, "New strategies and a new paradigm for Shariah-compliant portfolio optimization," *J. Bank. Financ.*, vol. 33, no. 6, pp. 1166–1176, Jun. 2009, doi: 10.1016/j.jbankfin.2008.12.011.
- [5] M. Touiti and J. E. Henchiri, "Risk and performance of Islamic indexes during subprime crisis," SSRN 2917060, 2016, doi: <http://dx.doi.org/10.2139/ssrn.2917060>.
- [6] K. Mehmood, W. Akhter, and M. Shahbaz, "Performance of Islamic vs. Conventional Capital Markets during Global Financial Crisis: An Empirical Study," *Artic. Cent. Islam. Financ. Dep. Manag. Sci. COMSATS Inst. Inf. Technol. Lahore, Pakistan*, 2016.
- [7] R. Sukmana and M. Kholid, "Impact of global financial crisis on Islamic and conventional stocks in emerging market: an application of ARCH and GARCH method," *Iefpedia.Com*, pp. 1–11, 2009, [Online]. Available: <http://www.iefpedia.com/english/wp-content/uploads/2010/12/Impact-of-global-financial-crisis-on-Islamic-and-conventional-stocks-Muhamad-Kholid.pdf>
- [8] S. Bakhri, F. Nurbaiti, and A. A. Yusuf, "The Most Influential Factors On Stock Prices In The JII Index," *J. Manaj.*, vol. 27, no. 3, pp. 612–631, 2023, doi: <https://doi.org/10.24912/jm.v27i3.1300>.
- [9] S. Husnan, "Dasar-dasar teori portofolio & Analisis Sekuritas," vol. 5, 2018.
- [10] E. J. Elton, M. J. Gruber, S. J. Brown, and W. N. Goetzmann, *Modern portfolio theory and investment analysis*. John Wiley & Sons, 2009. [Online]. Available: https://books.google.co.id/books?hl=id&lr=&id=aOtcTEQ3DAUC&oi=fnd&pg=PA1&dq=Modern+portfolio+theory+and+investment+analysis&ots=ozIFM9wAhS&sig=T_0ROJSTkXT4S3zCd-Vp89jLrmw&redir_esc=y#v=onepage&q=Modern+portfolio+theory+and+investment+analysis&f=false
- [11] S. Deng and X. Min, "Applied Optimization in Global Efficient Portfolio Construction Using Earning Forecasts," *J. Invest.*, vol. 22, no. 4, pp. 104–114, 2013, doi: 10.3905/joi.2013.22.4.104.
- [12] W. Chen, H. Zhang, M. K. Mehlatat, and L. Jia, "Mean-variance portfolio optimization using machine learning-based stock

- price prediction,” *Appl. Soft Comput.*, vol. 100, p. 106943, 2021, doi: 10.1016/j.asoc.2020.106943.
- [13] A. Chaweevanchon and R. Chaysiri, “Markowitz Mean-Variance Portfolio Optimization with Predictive Stock Selection Using Machine Learning,” *Int. J. Financ. Stud.*, vol. 10, no. 3, 2022, doi: 10.3390/ijfs10030064.
- [14] M. Ulfa, A. F. Amrullah, L. Ayudyanti, and H. Patria, “Portfolio Optimization Modeling in the Consumer Goods Industry,” *J. Ilm. Akunt. Dan Keuang.*, vol. 4, no. 6, pp. 2271–2278, 2022, [Online]. Available: <https://www.journal.ikopin.ac.id/index.php/fairvalue/issue/view/68>
- [15] G. Bathla, “Stock price prediction using LSTM and SVR,” *PDGC 2020 - 2020 6th Int. Conf. Parallel, Distrib. Grid Comput.*, pp. 211–214, 2020, doi: 10.1109/PDGC50313.2020.9315800.
- [16] A. Moghar and M. Hamiche, “Stock market prediction using LSTM recurrent neural network,” *Procedia Comput. Sci.*, vol. 170, pp. 1168–1173, 2020, doi: <https://doi.org/10.1016/j.procs.2020.03.049>.
- [17] H. N. Bhandari, B. Rimal, N. R. Pokhrel, R. Rimal, K. R. Dahal, and R. K. C. Khatri, “Predicting stock market index using LSTM,” *Mach. Learn. with Appl.*, vol. 9, p. 100320, 2022, doi: <https://doi.org/10.1016/j.mlwa.2022.100320>.
- [18] A. FAUZI, “Forecasting Saham Syariah Dengan Menggunakan Lstm,” *Al-Masraf J. Lemb. Keuang. dan Perbank.*, vol. 4, no. 1, p. 65, 2019, doi: 10.15548/al-masraf.v4i1.235.
- [19] D. Shah, W. Campbell, and F. H. Zulkernine, “A comparative study of LSTM and DNN for stock market forecasting,” in 2018 IEEE international conference on big data (big data), 2018, pp. 4148–4155. doi: 10.1109/BigData.2018.8622462.
- [20] W. Wang, W. Li, N. Zhang, and K. Liu, “Portfolio formation with preselection using deep learning from long-term financial data,” *Expert Syst. Appl.*, vol. 143, p. 113042, 2020, doi: 10.1016/j.eswa.2019.113042.
- [21] E. I. Ardyanta and S. Hasrini, “A prediction of stock price movements using support vector machines in Indonesia,” *J. Asian Financ. Econ. Bus.*, vol. 8, no. 8, pp. 399–407, 2021, doi: <https://doi.org/10.13106/jafeb.2021.vol8.no8.0399>.
- [22] S. Deng, T. Mitsubuchi, K. Shioda, T. Shimada, and A. Sakurai, “Combining technical analysis with sentiment analysis for stock price prediction,” *Proc. - IEEE 9th Int. Conf. Dependable, Auton. Secur. Comput. DASC 2011*, pp. 800–807, 2011, doi: 10.1109/DASC.2011.138.
- [23] M. R. Vargas, C. E. M. Dos Anjos, G. L. G. Bichara, and A. G. Evsukoff, “Deep Learning for Stock Market Prediction Using Technical Indicators and Financial News Articles,” *Proc. Int. Jt. Conf. Neural Networks*, vol. 2018-July, pp. 1–8, 2018, doi: 10.1109/IJCNN.2018.8489208.
- [24] F. A. Gers, J. Schmidhuber, and F. Cummins, “Learning to forget: Continual prediction with LSTM,” *Neural Comput.*, vol. 12, no. 10, pp. 2451–2471, 2000, doi: 10.1162/089976600300015015.
- [25] Q. Qu, Z. Li, J. Tang, S. Wu, and R. Wang, “A trend forecast of import and export trade total volume based on LSTM,” in IOP Conference Series: Materials Science and Engineering, 2019, vol. 646, no. 1, p. 012002. doi: 10.1088/1757-899X/646/1/012002.
- [26] C. Olah, “Understanding LSTM Networks,” 2015. <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- [27] B. C. Mateus, M. Mendes, J. T. Farinha, R. Assis, and A. M. Cardoso, “Comparing LSTM and GRU Models to Predict the Condition of a Pulp Paper Press,” *Energies*, vol. 14, no. 21, 2021. doi: 10.3390/en14216958.
- [28] Z. Wang *et al.*, “Climate and environmental data contribute to the prediction of grain commodity prices using deep learning,” *J. Sustain. Agric. Environ.*, vol. 2, no. 3, pp. 251–265, 2023, doi: 10.1002/sae2.12041.
- [29] N. Reimers and I. Gurevych, “Optimal Hyperparameters for Deep LSTM-Networks for Sequence Labeling Tasks,” 2017, doi: <https://doi.org/10.48550/arXiv.1707.06799>.
- [30] M. Yang and J. Wang, “Adaptability of Financial Time Series Prediction Based on BiLSTM,” *Procedia Comput. Sci.*, vol. 199, pp. 18–25, 2021, doi: 10.1016/j.procs.2022.01.003.
- [31] G. H. T. Ribeiro, P. S. G. M. De Neto, G. D. C. Cavalcanti, and I. R. Tsang, “Lag selection for time series forecasting using Particle Swarm Optimization,” *Proc. Int. Jt. Conf. Neural Networks*, pp. 2437–2444, 2011, doi: 10.1109/IJCNN.2011.6033535.
- [32] D. P. Kingma and J. L. Ba, “Adam: A method for stochastic optimization,” 3rd Int. Conf. Learn. Represent. ICLR 2015 - Conf. Track Proc., pp. 1–15, 2015, doi: <https://doi.org/10.48550/arXiv.1412.6980>.
- [33] T. Fischer and C. Krauss, “Deep learning with long short-term memory networks for financial market predictions,” *Eur. J. Oper. Res.*, vol. 270, no. 2, pp. 654–669, 2018, doi: 10.1016/j.ejor.2017.11.054.
- [34] D. Chicco, M. J. Warrens, and G. Jurman, “The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation,” *PeerJ Comput. Sci.*, vol. 7, pp. 1–24, 2021, doi: 10.7717/PEERJ-CS.623.
- [35] M. Sikalo, A. Arnaut-Berilo, and A. Zaimovic, “Efficient Asset Allocation: Application of Game Theory-Based Model for Superior Performance,” *Int. J. Financ. Stud.*, vol. 10, no. 1, 2022, doi: 10.3390/ijfs10010020.
- [36] W. Lefebvre, G. Loeper, and H. Pham, “Mean-variance portfolio selection with tracking error penalization,” *Mathematics*, vol. 8, no. 11, pp. 1–23, 2020, doi: 10.3390/math8111915.
- [37] C. D. Lewis, *Industrial and business forecasting methods: A practical guide to exponential smoothing and curve fitting*. London: Butterworth Scientific, 1982. [Online]. Available: <https://catalog.loc.gov/vwebv/holdingsInfo?searchId=5675&recPointer=0&recCount=25&searchType=0&bibId=3758845>
- [38] E. Rangelova, “Disposition Effect and Firm Size: New Evidence on Individual Investor Trading Activity,” *SSRN Electron. J.*, 2005, doi: 10.2139/ssrn.293618.