



## Prediksi Harga Saham Jakarta *Islamic Index* Menggunakan Metode *Long Short-Term Memory*

Didih Rizki Chandranegara<sup>#1</sup>, Raffi Ainul Afif<sup>#2</sup>, Christian Sri Kusuma Aditya<sup>#3</sup>, Wildan Suharso<sup>#4</sup>,  
Hardianto Wibowo<sup>#5</sup>

<sup>#</sup>Teknik Informatika, Universitas Muhammadiyah Malang  
Jl. Raya Tlogomas No.246 Malang, Jawa Timur 65144

<sup>1</sup>didihrizki@umm.ac.id

<sup>2</sup>raffiainul@webmail.umm.ac.id

<sup>3</sup>christianskaditya@umm.ac.id

<sup>4</sup>wsuharso@umm.ac.id

<sup>5</sup>ardi@umm.ac.id

**Abstrak**— Saat ini investasi sudah sangat menyebar luas dan banyak dari kita sedang melakukannya. Investasi ini berguna untuk mengatasi kebutuhan hidup dimasa mendatang yang tidak menentu. Salah satu penyebab tidak menentunya kebutuhan dimasa mendatang adalah inflasi. Salah satu contoh investasi adalah saham. Di dalam jual beli saham di Indonesia terdapat Jakarta *Islamic Index* (JII). JII adalah salah satu *index* yang ada di pasar modal Indonesia yang mengelompokkan beberapa saham yang masuk dalam kriteria syariah dan dihitung rata-rata dari harga saham – saham tersebut. Dalam berinvestasi saham, kita tidak bisa melakukan pergerakan yang sembarangan karena saham yang relatif berubah-ubah menjadi penyebab kegagalan dalam berinvestasi saham. Dengan demikian ketika melakukan investasi saham harus dilakukan analisa yang tepat. Perkembangan teknologi saat ini sangat maju dan juga dapat membantu kita dalam melakukan analisa dalam berinvestasi dengan melakukan prediksi harga. Pada penelitian ini, akan dimanfaatkan kemajuan teknologi tersebut dengan melakukan penelitian prediksi, penelitian ini dilakukan menggunakan metode *Long short Term-Memory* (*LSTM*). Model *LSTM* yang diusulkan dapat memperoleh performa yang cukup baik dengan hasil *RMSE* mencapai 5.20877667554, dan *MAPE* 0.08658576985.

**Kata kunci**— *Investment, Prediction, LSTM, RMSE, MAPE*

### I. PENDAHULUAN

Kita harus menghadapi ketidakpastian kebutuhan hidup yang mungkin akan meningkat setiap harinya, terutama karena inflasi yang bisa membuat harga barang dan jasa meningkat seiring waktu. Oleh karena itu, melakukan investasi bisa menjadi cara untuk mengatasi hal tersebut.

Inflasi merupakan suatu keadaan yang mengidentifikasi tingkat harga secara umum (*price level*) cenderung meningkat [1]. Investasi berasal dari istilah *investire* yang artinya memakai atau menggunakan [2]. Saham sendiri merupakan suatu surat bernilai yang dimiliki seseorang yang dapat membuktikan bahwa

pemegang surat yang bernilai tersebut merupakan pemilik perusahaan dengan porsi yang ditentukan oleh banyaknya penyertaan modal yang ditanamkan oleh pemilik surat berharga pada perusahaan tersebut [3].

Jakarta *Islamic Index* (JII) merupakan contoh *index* saham yang tersedia dalam pasar modal Indonesia dimana *index* saham ini berisi perhitungan harga rata - rata saham untuk kategori saham yang masuk kriteria saham syariah. Pergerakan harga saham JII ditampilkan setiap harinya sesuai dengan harga *close* bursa pada hari itu [4]. Harga saham dapat mengalami fluktuasi yang tinggi dimana, harga saham tersebut bisa pada posisi grafik menaik atau pun juga dapat pada posisi menurun dalam beberapa menit bahkan dapat pula mengalami perubahan dalam jangkauan detik saja. Hal tersebut dapat diakibatkan oleh permintaan dan penawaran dalam bursa antara pembeli dan penjual saham [5].

Studi yang belakangan ini dapat digunakan oleh para peneliti dalam membuat arsitektur model untuk prediksi adalah data *mining* [6]. Metode algoritma dari data *mining* yang sudah diakui dapat dipakai untuk melakukan prediksi data deret waktu adalah metode teknik *Long Short Term Memory* (*LSTM*) yang merupakan versi lanjutan dari metode sebelumnya yaitu *Recurrent Neural Network* (*RNN*) [7]. Menurut Adhitio dkk [8] pada penelitiannya yang melakukan prediksi untuk saham bank BRI dapat memperoleh hasil *RMSE* (*Root Mean Square Error*) 227.460444244 [8].

Menurut Hastomo dkk [9] yang melakukan penelitian dengan tujuan optimasi prediksi saham di masa pandemi Covid-19 ini didapatkan *RMSE-epoch chart* yang bagus untuk masing – masing prediksi saham yang dilakukan, BBCA memiliki *RMSE* = 1120.651, BBRI memiliki *RMSE* = 156.297, ASII memiliki *RMSE* sebesar 134.551 sedangkan TLKM memiliki *RMSE* sebesar 71.658 [9]. Selanjutnya Julian dkk [10] dalam penelitiannya berhasil

melakukan prediksi dengan perolehan RMSE yang cukup baik yaitu sebesar 31.71 [10]. Wardani [11] juga dapat membuktikan penelitiannya bahwa model yang dibuatnya untuk memprediksi harga saham syariah dapat memperoleh hasil yang baik yaitu nilai *RMSE* sebesar 117,266 dan nilai *MAPE* sebesar 2,980%.

Kemudian pada penelitian prediksi harga emas oleh Alhamdani [12] yang menggunakan analisis parameter menghasilkan nilai terbaik *RMSE* 9139,14381 dan *MAPE* 0,69794% [12]. Selain itu pada penelitian Nurjaman dkk [3] yang melakukan prediksi saham Pfizer Inc memiliki hasil peramalan dengan nilai *RMSE* 0,9366 [3].

Untuk mengetahui akurasi dari model yang dibuat dalam penelitian ini menggunakan 2 pengujian perhitungan parameter yaitu dengan memakai *Root Mean Square Error (RMSE)*, dan *Mean Absolut Percentage Error (MAPE)*. *RMSE* adalah salah satu teknik umum yang dapat dipakai untuk mengetahui tingkat error pada model prediksi data yang berupa data angka [8]. Hasil dari *RMSE* didapatkan dari rata-rata kuadrat total *error* yang didapatkan pada model prediksi [13]. *MAPE* juga merupakan salah satu evaluasi yang dapat dilakukan dalam membangun model *LSTM*. *MAPE* dapat dimanfaatkan untuk menghitung besaran *error* dalam satuan persen, *MAPE* mengukur rata-rata *error* yang tidak diproses dalam satuan persen [14].

Pada kasus ini akan memakai metode *LSTM* untuk melakukan prediksi harga saham Jakarta *Islamic Index*. Dipilihnya metode ini dikarenakan karakteristik *LSTM* cocok untuk melakukan prediksi saham. Data yang dipakai adalah data historis harga saham Jakarta *Islamic Index* per 1 hari mulai dari 1 Januari 2019 sampai 31 Maret 2022. Dengan melakukan rancangan prediksi yang baik diharapkan dapat mempermudah para investor untuk melakukan analisa harga saham, dan juga akan meminimalkan resiko yang dapat terjadi pada saat investasi.

II. METODOLOGI PENELITIAN

Pada penelitian kali ini terbagi menjadi lima yaitu pengambilan data, *preprocessing* data, *modelling*, prediksi dan visualisasi, dan terakhir analisis hasil.

A. Pengambilan Data

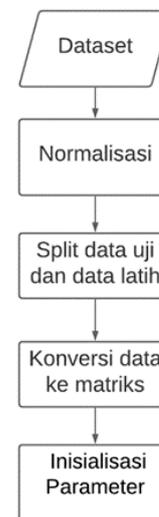
Pada penelitian ini akan menggunakan data harga saham harian Jakarta *Islamic Index* (JKII) yang merupakan data harga rata-rata dari saham syariah yang masuk dalam JKII. Data tersebut diambil atau diperoleh dari situs *Yahoo Finance* dengan kode ^JKII. Data yang diambil merupakan *historical data time series* mulai dari 1 Januari 2019 sampai 31 Desember 2021. Data harga saham yang diperoleh berupa tanggal, harga buka (*open price*), harga tertinggi (*high price*), harga terendah (*low price*), harga tutup (*close price*), dan jumlah transaksi (*volume*). Kemudian data tersebut disimpan dengan format *Comma Separated Values (CSV)*. Berikut sampel data yang dipakai dapat dilihat pada tabel 1.

TABEL I  
SAMPEL DATA

Date	Open	High	Low	Close	Adj Close	Volume
2020-02-04	641,7	643,6	637,1	639,6	639,6	691400000
2020-02-05	642,3	647,5	637,3	647,5	647,5	701500000
2020-02-06	650,8	651,1	642,5	644,2	644,2	579000000
2020-02-07	645,1	646,9	643,0	644,5	644,5	511700000

Dari beberapa feature yang ada pada dataset hanya feature *Close* atau data harga tutup saja yang akan digunakan pada penelitian kali ini.

B. Preprocessing



Gambar 1. Alur penelitian

Tahap pertama yang dilakukan dalam *preprocessing* adalah melakukan *cleaning* data dimana pada dataset yang telah ada masih banyak data kosong atau *null value*. *Null value* ini menunjukkan bahwa tidak ada pergerakan atau perubahan saham pada saat itu. setelah selesai melakukan *cleaning* data, kemudian akan dilakukan normalisasi data, dimana proses normalisasi data ini diperlukan dengan tujuan untuk membentuk data dalam posisi nilai dengan rentang yang sama supaya menghilangkan data *outlier* dan membuat distribusi data menjadi normal. Normalisasi yang dipakai adalah *min-max scaling*. *Min-max* adalah teknik normalisasi yang akan mentransformasi data secara linear dengan memakai nilai minimal dan maksimal, kemudian dari tranformasi tersebut akan dihasilkan keseimbangan antar data yang ada pada rentang yang sama [15]. Rumusnya dapat dilihat pada persamaan (1).

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \tag{1}$$

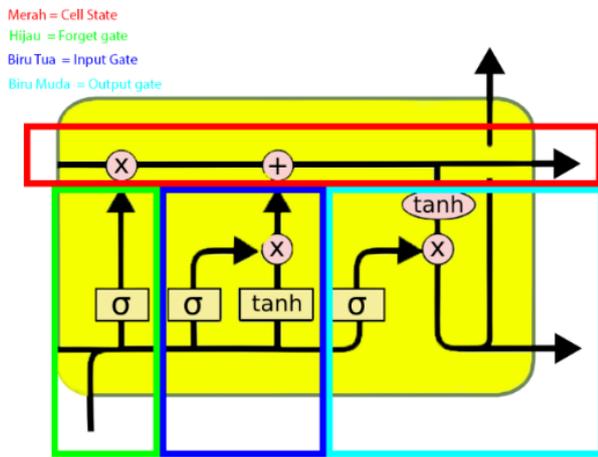
Setelah selesai dilakukan normalisasi, dataset akan dilakukan *splitting* atau pembagian *dataset* menjadi data

latih atau data *train* dan data uji atau data *test*. Pembagian data ini diperlukan supaya dalam proses pengujian dan pengetesan hasil prediksi nantinya berjalan dengan optimal, karena dalam prosesnya perlu menggunakan data yang berbeda untuk melakukan dua hal tersebut.

Kemudian setiap dari data yaitu data latih dan data uji akan diubah bentuknya menjadi *dataset matrix*, dan kemudian data yang telah ada akan disesuaikan *input*-nya sesuai yang diinginkan Metode *LSTM* untuk melatih modelnya. Didalam *LSTM* menerima input berupa beberapa *timestep*, dan dimana setiap *timestep*-nya mempunyai besar data yang bisa disesuaikan sesuai kebutuhan.

C. Modelling

*Long Short-Term Memory* sendiri adalah salah satu teknik prediksi yang dikembangkan dari metode *Recurrent Neural Network* yang dibangun untuk menghindari kekurangan *vanishing* dan *exploding gradient* dalam penggunaan *RNN* [16]. Dalam stuktur arsitektur *LSTM* terdapat yang namanya *forget gate*, *input gate*, *cell state* dan *output gate* [17]. *LSTM cell* akan membuat *input*-an dan akan disimpan dalam durasi tertentu. Ditinjau dari penalaran sederhana, *input gate* akan mengatur sampai dimana nilai baru akan menuju ke dalam *cell*, sedangkan *forget gate* mengatur sampai kapan nilai masih berada dalam *cell*, dan *output gate* mengatur sejauh mana nilai yang ada pada *cell* digunakan untuk mempertimbangkan aktivasi *output* dari unit *LSTM* [18].



Gambar 2. Arsitektur LSTM

*Forget gate* berkerja untuk melakukan pemilahan petunjuk dari *cell state* (memori jangka panjang) yang akan ditahan dalam *cell* atau tidak, hal tersebut dilakukan dengan cara mengalikan nilai yang ada pada *cell state* dan *forget vector* yang diperoleh *input*-an saat ini dan juga *hidden state* yang akan diterima, secara sederhana *forget gate* akan menghapus informasi nilai yang sudah tidak relevan lagi. Supaya *forget vector*, *hidden state*, dan *input* saat ini didapatkan, kita harus memasukkannya ke aktivasi *sigmoid*, seperti pada *layer* pertama *input gate*, tetapi dengan bobot yang berbeda. [12].

$$f_{gt} = \sigma(w_f[o_{t-1}, i_t]) + bs_f \tag{2}$$

*Input gate* mempunyai dua fungsi, pertama adalah melakukan pembaruan informasi dalam *cell state*, kondisi ini akan diatur oleh *layer sigmoid* seperti pada persamaan (3), Sedangkan fungsi lainnya akan membangun sebuah kandidat vektor baru dengan fungsi aktivasi pada *layer tanh* untuk meninjau beberapa informasi baru ditambahkan, dan dipakai untuk memperbarui kondisi informasi dari *cell state* seperti pada persamaan (4) [19]

$$i_{gt} = \sigma(w_i[o_{t-1}, i_t]) + bs_{igt} \tag{3}$$

$$\hat{c}_t = \tanh(w_c[o_{t-1}, i_t]) + bs_c \tag{4}$$

*Output gate* bekerja dengan dua *layer* untuk memperoleh *hidden state* yang baru yang kemudian akan diteruskan ke *timestep* selanjutnya. *Layer* yang pertama bekerja untuk menentukan informasi yang akan di keluarkan menurut input saat ini, menggunakan aktivasi *sigmoid* seperti pada persamaan (5). Kemudian *layer* lainnya akan menempatkan nilai yang ada pada *cell state* dengan fungsi aktivasi *tanh*. Setelah itu untuk mendapatkan *output*-nya akan dikalikan hasil *layer* pertama dan kedua seperti pada persamaan (6).

$$o_{gt} = \sigma(w_o[o_{t-1}, i_t]) + bs_{ogt} \tag{5}$$

$$o_t = o_{gt} * \tanh(c_t) \tag{6}$$

Dalam tahap *modelling* pada penelitian ini menggunakan *sequential model*. Dalam pembuatan modelnya akan dilakukan penentuan pola *timeseries* dan beberapa skenario dengan mengubah jumlah *neuron hidden*, *layer*, *learning rate*, *batch size* serta *epoch*. Tujuannya untuk mencari hasil yang terbaik.

Dari hasil percobaan beberapa model akan diambil nilai *RMSE* dan *MAPE* yang paling maksimal untuk dijadikan *final model*. Nilai *RMSE* yang maksimal dapat dilihat dari nilai kesalahannya yang paling kecil, semakin kecil nilai *RMSE* dari model yang telah dibuat berarti semakin dekat nilai prediksi dengan data yang telah ada.

D. Prediksi dan Visualisasi

Setelah mendapatkan model yang terbaik maka tahap selanjutnya adalah melakukan prediksi menggunakan model yang telah dibuat sebelumnya. Dari model yang telah dibuat dapat dilihat prediksi dari data yang ada. Kemudian akan didapatkan hasil prediksi untuk beberapa hari kedepan yang kemudian akan divisualisasikan dengan grafik.

E. Analisis Hasil

Pada tahap terakhir ini akan dilakukan analisis hasil dari prediksi dan visualisasi dari model yang telah dibuat tadi. Analisis tersebut berupa melihat perhitungan *error* dari pembuatan model tadi, apakah sudah maksimal atau tidak. Hal tersebut dapat diketahui dengan melakukan perbandingan hasil dari prediksi pada penelitian kali ini dengan penelitian sebelumnya yang juga terkait dengan

kasus prediksi harga saham. Jika hasil dari analisis kurang maksimal akan dilakukan evaluasi prediksi, dimana akan dicari hal apa yang membuat hasil dari prediksinya kurang maksimal.

### III. HASIL DAN PEMBAHASAN

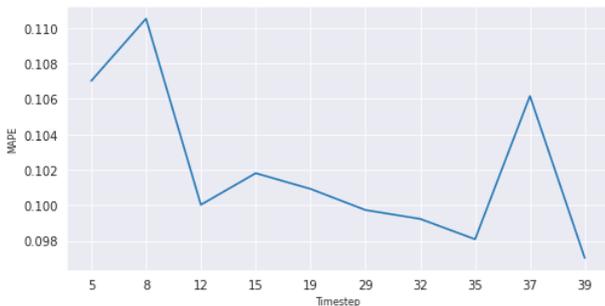
Pada pengerjaannya penelitian ini menggunakan bahasa pemrograman *python* dengan *library* utama yaitu *keras* dan juga beberapa *library* lainnya, yang digunakan untuk mempermudah dalam proses pengerjaan penelitian ini, *library – library* tersebut tertera Gambar 3.

```
import math
import matplotlib.pyplot as plt
import keras
import pandas as pd
import numpy as np
from keras.models import Sequential
from keras.layers import Dense
from keras.layers import LSTM
from keras.layers import Dropout
from keras.layers import *
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import mean_squared_error
from sklearn.metrics import mean_absolute_percentage_error
from keras.callbacks import EarlyStopping
import tensorflow as tf
from numpy import array
from google.colab import drive
import seaborn as sns
import numpy
from tensorflow.keras.optimizers import Adam
import plotly.express as px
import plotly.graph_objects as go
```

Gambar 3. *Library* yang dipakai

#### A. Penentuan Pola Timeseries

Penentuan jumlah *timestep* untuk menemukan pola *timeseries* yang optimal akan membantu model *LSTM* menjadi lebih baik. Pada penelitian ini menggunakan jumlah data yang tidak terlalu banyak, maka dari itu penting untuk mencari besar *timestep* untuk menentukan pola *timeseries* yang paling optimal supaya terhindar dari *loss* yang tinggi. Jumlah *timestep* yang akan dicoba adalah 6, 8, 12, 15, 19, 29, 32, 35, 37, 39. Hasil dari pencarian jumlah *timestep* yang optimal dapat dilihat pada grafik gambar.

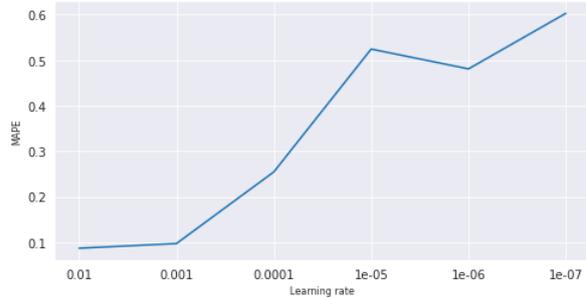


Gambar 4. Grafik hasil penentuan *timeseries*

#### B. Skenario 1

Pada skenario ini akan mencari jumlah *learning rate* terbaik untuk penelitian ini, dengan cara mengubah besaran parameter *learning rate* menjadi : 0,01, 0,001, 0,0001,

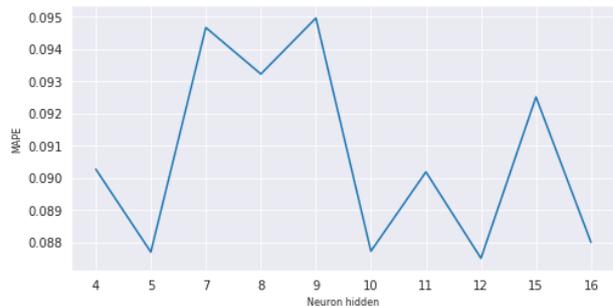
0,00001, 0,000001, 0,0000001, dengan bantuan kombinasi *hidden neuron* 10, *hidden layer* 1, *epoch* 50, *batch size* 64, dan juga menggunakan *timestep* paling optimal yaitu 39. Untuk menentukan *learning rate* terbaik ditentukan dari hasil *RMSE* dan *MAPE* terbaik dari kombinasi tersebut.



Gambar 5. Grafik hasil skenario 1

#### C. Skenario 2

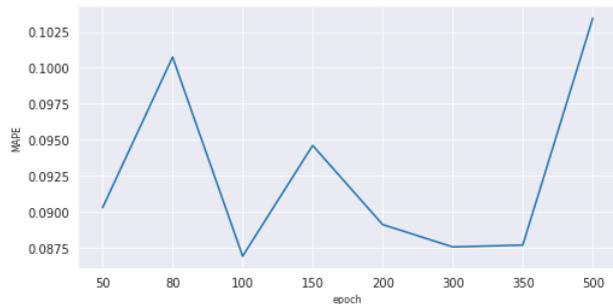
Pada skenario 2 ini akan mencari jumlah *hidden neuron* terbaik untuk mencapai hasil *RMSE* dan *MAPE* yang maksimal, dan pada skenario ini *hidden neuron* yang akan dipakai berjumlah: 4, 5, 7, 8, 9, 10, 11, 12, 15, 16, dan *learning rate* terbaik pada skenario 1, sedangkan untuk jumlah *hidden layer*, *epoch*, dan *batch size* masih sama seperti skenario 1.



Gambar 6. Grafik hasil skenario 2

#### D. Skenario 3

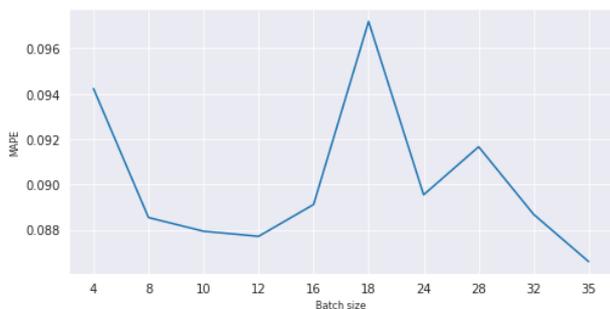
Skenario 3 ini akan bertujuan mencari kombinasi *epoch* yang terbaik, dengan nilai *learning rate* terbaik pada skenario 1 yaitu 0,01, dan *hidden neuron* terbaik pada skenario 2, sedangkan *hidden layer*, *batch size* masih menggunakan besaran yang sama seperti skenario sebelumnya. Jumlah *epoch* yang akan dicoba adalah 50, 80, 100, 150, 200, 300, 350, 500.



Gambar 7. Grafik hasil skenario 3

E. Skenario 4

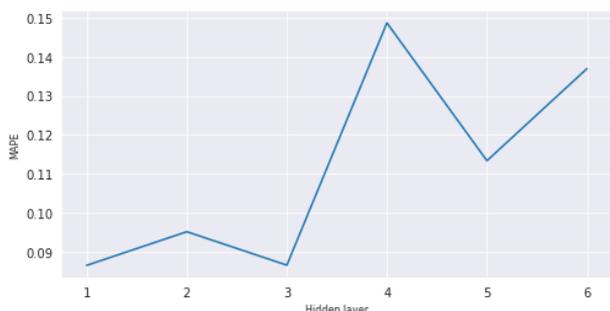
Pada skenario ini akan mencari jumlah *batch size* yang paling optimal untuk melakukan prediksi saham pada penelitian ini. Kombinasi yang dipakai pada skenario ini merupakan kombinasi terbaik pada skenario 3, tetapi dengan mengubah jumlah *batch size*-nya dengan jumlah : 4, 8, 10, 12, 16, 18, 24, 28, 32, 35.



Gambar 8. Grafik hasil skenario 4

F. Skenario 5

Skenario ini merupakan skenario terakhir dan juga yang akan menentukan kombinasi *LSTM* paling baik pada penelitian ini dalam melakukan prediksi saham. Skenario ini akan mencari jumlah *hidden layer* yang terbaik dengan mencoba beberapa jumlah *hidden layer* yaitu: 1, 2, 3, 4, 5, 6, dengan kombinasi parameter pada skenario – skenario sebelumnya.



Gambar 9. Grafik hasil skenario 5

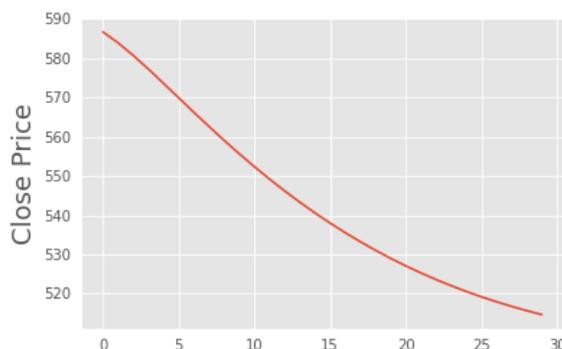
Pada skenario ini menunjukkan bahwa kombinasi *LSTM* paling optimal pada penelitian ini adalah *learning rate* 0,01, *hidden neuron* 12, *hidden layer* 1, *epoch* 100, dan *batch size* 35 menghasilkan nilai *RMSE* dan *MAPE* 5.20877667554, 0.08658576985. Dengan begitu kombinasi tersebut akan digunakan sebagai *final* model untuk prediksi nilai saham dikemudian hari.

G. Prediksi dan Visualisasi

Tahap ini akan melakukan prediksi saham untuk 30 hari kedepan menggunakan *final* model. Sebelum melakukan prediksi untuk kemudian hari, dilakukan prediksi terhadap data saham. Dari hasil prediksi saham dengan data *aktual*, *train prediction*, dan *test prediction* dapat dilihat pada Gambar 10, dan untuk prediksi 30 hari kedepan dapat dilihat pada Gambar 11.



Gambar 10. Grafik perbandingan hasil prediksi dengan data aktual



Gambar 11. Hasil prediksi 30 hari kedepan

Dari hasil beberapa skenario yang telah dilakukan menciptakan sebuah kombinasi parameter untuk *final* model *LSTM* yang juga sudah dilakukan prediksi untuk kemudian hari. Hasil yang didapatkan juga sudah cukup baik. Namun tentunya perlu perbandingan untuk dapat mengatakan bahwa kombinasi *LSTM* yang sudah dibuat bisa dikatakan cukup baik, maka dari itu hasil dari kombinasi *LSTM* yang telah dibuat dibandingkan dengan kombinasi *RNN* yang juga dibuat pada penelitian kali ini. Kombinasi *RNN* yang akan digunakan sebagai pebanding yaitu: jumlah *timestep* 39, *learning rate* 0,01, *hidden neuron* 16, *hidden layer* 1, *epoch* 100, *batch size* 35.

Dari kombinasi tersebut menghasilkan jumlah *RMSE* 7.195272654293766 dan *MAPE* 0.1026672830975423, dilihat dari hasilnya terbukti bahwa model *LSTM* yang sebelumnya telah dibuat lebih baik dari pada kombinasi *RNN* yang dibuat sebagai pebanding. Selain dibandingkan dengan kombinasi *RNN*, model *LSTM* yang sebelumnya telah dibuat juga dibandingkan dengan penelitian terdahulu yang juga melakukan prediksi saham Jakarta *Islamic Index* yaitu Prediksi saham JII menggunakan transformasi *wavellet diskrit daubechies*, dimana pada penelitian ini menghasilkan nilai *MAPE* sebesar 0,188662. Tabel 2 merupakan hasil perbandingannya.

TABEL II  
PERBANDINGAN HASIL PENELITIAN

	Kombinasi <i>LSTM</i>	Kombinasi <i>RNN</i>	Penelitian terdahulu
Jumlah data	795	795	256
<i>RMSE</i>	5.20877667554	7.19527265429	-
<i>MAPE</i>	0.08658576985	0.10266728309	0,188662

#### IV. KESIMPULAN

Pada penelitian ini menghasilkan pola *timeseries* untuk Model *LSTM* yang optimal yaitu 39 *timestep*, dengan pola ini mampu menghasilkan nilai *RMSE* dan *MAPE* yang paling optimal dibandingkan pola yang lain. Kemudian dilakukan beberapa skenario dengan mengubah parameter yang ada untuk mencari kombinasi model *LSTM* yang paling baik.

Skenario pertama mengubah jumlah *learning rate*, dan didapatkan *learning rate* terbaik sebesar 0,01, hasil pada skenario ini jika menggunakan *learning rate* lebih kecil dari 0,01 maka *loos* akan semakin besar. Setelah itu pada skenario 2 mencari jumlah *hidden neuron*, dan didapatkan bahwa dengan *hidden neuron* berjumlah 12 dapat menghasilkan nilai *RMSE* dan *MAPE* paling baik dibandingkan dengan jumlah *hidden neuron* lain yang dicoba.

Lalu pada skenario 3 mengubah parameter *epoch*, dan didapatkan *epoch* paling maksimal yaitu berjumlah 100, jika lebih dari itu dilihat dari hasilnya akan membuat *loos* semakin tinggi. Kemudian skenario 4 mencari jumlah *batch size* paling baik, hasilnya didapatkan *batch size* paling optimal dengan nilai *MAPE* dan *RMSE* paling baik yaitu berjumlah 35. Skenario yang terakhir yaitu mencari jumlah *hidden layer* yang paling optimal untuk penelitian ini, dengan menggabungkan hasil- hasil pada skenario – skenario sebelumnya, menunjukkan untuk penelitian ini model yang dibuat paling optimal menggunakan hanya satu *layer*, karena dilihat dari hasilnya jika menggunakan lebih dari satu *layer* menghasilkan nilai *loos* yang tinggi. Sehingga dengan menggunakan pola *timeseries* dengan 39 *timestep* dan dengan kombinasi *LSTM learning rate* 0,01, *hidden neuron* 12, *epoch* 100, *batch size* 35, dan *hidden layer* 1 berhasil mencapai nilai *RMSE* dan *MAPE* yang optimal

Pengujian untuk kombinasi model *LSTM* yang telah dibuat menggunakan *RMSE* dan *MAPE* pada penelitian ini dibandingkan dengan kombinasi *RNN* yang juga dibuat, dan dengan penelitian terdahulu yang menggunakan metode *transformasi wavellet diskrit daubechies*. Hasilnya model *LSTM* yang telah dibuat masih lebih baik dari pada model *RNN* dan juga penelitian terdahulu. Hal ini membuktikan bahwa model *LSTM* yang telah dibuat sudah bisa dikatakan cukup baik.

#### REFERENSI

- [1] R. Susanto, I. P.-J. (Journal of Applied, and undefined 2021, "Pengaruh Inflasi Dan Pertumbuhan Ekonomi Terhadap Tingkat Kemiskinan Di Indonesia," journal.lppmunindra.ac.id, vol. 7, no. 2, pp. 271–278, 2020, Accessed: Jul. 09, 2022. [Online]. Available: <https://journal.lppmunindra.ac.id/index.php/JABE/article/view/7653>
- [2] S. Sudirman and M. Alhudhori, "PENGARUH KONSUMSI RUMAH TANGGA, INVESTASI TERHADAP PERTUMBUHAN EKONOMI DI PROVINSI JAMBI," Ekonomis: Journal of Economics and Business, vol. 2, no. 1, pp. 81–91, Mar. 2018, doi: 10.33087/EKONOMIS.V2I1.33.
- [3] A. Nurjaman, ... A. H.-E.-P., and undefined 2021, "Long Short-Term Memory (LSTM) untuk Prediksi Harga Saham Pfizer Inc," prosiding.statistics.unpad.ac.id, Accessed: Jan. 18, 2022. [Online]. Available: <http://prosiding.statistics.unpad.ac.id/index.php/prosidingnasional/article/view/26>
- [4] L. Mayola, S. Sanjaya, W. S.- Sebatik, and undefined 2018, "Identifikasi Karakteristik Jakarta Islamic Index Dengan Menggunakan Algoritma K-Means," jurnal.wicida.ac.id, Accessed: Jan. 20, 2022. [Online]. Available: <https://www.jurnal.wicida.ac.id/index.php/sebatik/article/view/312>
- [5] P. Inflasi Dan Suku Bunga Terhadap Harga Saham Pada Perusahaan Perbankan Yang Terdaftar Di Bursa Efek Indonesia Handini Hadistia, A. Sekolah Tinggi Ilmu Manajemen Sukma, P. Studi Manajemen, and S. Tinggi Ilmu Manajemen Sukma, "Pengaruh Inflasi Dan Suku Bunga Terhadap Harga Saham Pada Perusahaan Perbankan Yang Terdaftar Di Bursa Efek Indonesia," journals.synthesispublication.org, vol. 3, no. 2, pp. 67–73, 2021, Accessed: Jul. 02, 2022. [Online]. Available: <https://journals.synthesispublication.org/index.php/civitas/article/view/309>
- [6] S. Zahara, M. I.-J. R. (Rekayasa S. Dan, and undefined 2019, "Prediksi Indeks Harga Konsumen Menggunakan Metode Long Short Term Memory (LSTM) Berbasis Cloud Computing," jurnal.iaii.or.id, Accessed: Jul. 01, 2022. [Online]. Available: <http://www.jurnal.iaii.or.id/index.php/RESTI/article/view/1086>
- [7] C. S. Hsu and J. R. Jiang, "Remaining useful life estimation using long short-term memory deep learning," Proceedings of 4th IEEE International Conference on Applied System Innovation 2018, ICASI 2018, pp. 58–61, Jun. 2018, doi: 10.1109/ICASI.2018.8394326.
- [8] A. Satyo Bayangkari Karno, J. K. Noer Ali, and K. Bekasi, "Prediksi Data Time Series Saham Bank BRI Dengan Mesin Belajar LSTM (Long ShortTerm Memory)," Journal of Information and Information Security (JIFORTY), vol. 1, no. 1, pp. 1–8, 2020, Accessed: Jul. 03, 2022. [Online]. Available: <http://www.ejurnal.uharajaya.ac.id/index.php/jiforty/article/view/133>
- [9] W. Hastomo, A. Karno, ... N. K.-... (Jurnal E. dan, and undefined 2021, "Optimasi Deep Learning untuk Prediksi Saham di Masa Pandemi Covid-19," jurnal.untan.ac.id, Accessed: Nov. 03, 2021. [Online]. Available: <https://jurnal.untan.ac.id/index.php/jepin/article/view/47411>
- [10] R. Julian, M. P.-J. (Jurnal T. I. dan, and undefined 2021, "Peramalan Harga Saham Pertambangan Pada Bursa Efek Indonesia (BEI) Menggunakan Long Short Term Memory (LSTM)," jurnal.mdp.ac.id, vol. 8, no. 3, 2021, Accessed: Jan. 03, 2022. [Online]. Available: <https://jurnal.mdp.ac.id/index.php/jatisi/article/view/1159>
- [11] W. Wardani, "Prediksi harga saham syariah menggunakan metode recurrent neural network-long short term memory," 2021, Accessed: Jul. 03, 2022. [Online]. Available: <http://digilib.uinsby.ac.id/id/eprint/49542>
- [12] F. Alhamdani, "Prediksi Harga Emas Menggunakan Metode Time Series Long Short-Term Memory Neural Network," 2021, Accessed: Jan. 15, 2022. [Online]. Available: <https://eprints.umm.ac.id/76096/>

- [13] L. Wiranda, M. S.-J. N. P. Teknik, and undefined 2020, "Penerapan Long Short Term Memory Pada Data Time Series Untuk Memprediksi Penjualan Produk Pt. Metiska Farma," *ejournal.undiksha.ac.id*, vol. 8, Accessed: Jul. 03, 2022. [Online]. Available: <https://ejournal.undiksha.ac.id/index.php/janapati/article/view/19139>
- [14] I. Halimi and W. A. Kusuma, "Prediksi Indeks Harga Saham Gabungan (IHSG) Menggunakan Algoritma Neural Network," *Jurnal Edukasi dan Penelitian Informatika (JEPIN)*, vol. 4, no. 1, p. 24, Jun. 2018, doi: 10.26418/JP.V4I1.25384.
- [15] "Suyanto, 2018. Machine Learning Tingkat Dasar dan... - Google Scholar." [https://scholar.google.com/scholar?hl=en&as\\_sdt=0%2C5&q=Su yanto%2C+2018.+Machine+Learning+Tingkat+Dasar+dan+Lanj ut.+Bandung%3A+Informatika+Bandung&btnG=](https://scholar.google.com/scholar?hl=en&as_sdt=0%2C5&q=Su+yanto%2C+2018.+Machine+Learning+Tingkat+Dasar+dan+Lanjut.+Bandung%3A+Informatika+Bandung&btnG=) (accessed Jul. 04, 2022).
- [16] fadil indra sanjaya and D. Heksaputra, "Prediksi Rerata Harga Beras Tingkat Grosir Indonesia dengan Long Short Term Memory," *JATISI (Jurnal Teknik Informatika dan Sistem Informasi)*, vol. 7, no. 2, pp. 163–174, Aug. 2020, doi: 10.35957/JATISI.V7I2.388.
- [17] M. Aldi, J. Jondri, A. A.- eProceedings, and undefined 2018, "Analisis dan Implementasi Long Short Term Memory Neural Network untuk Prediksi Harga Bitcoin," ... *.telkomuniversity.ac.id*, Accessed: Jul. 04, 2022. [Online]. Available: [https://openlibrarypublications.telkomuniversity.ac.id/index.php/e ngineering/article/view/6739](https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/6739)
- [18] A. Khumaidi, R. Raafi'udin, I. S.-J. Telematika, and undefined 2020, "Pengujian Algoritma Long Short Term Memory untuk Prediksi Kualitas Udara dan Suhu Kota Bandung," *journal.ithb.ac.id*, vol. 15, no. 1, Accessed: Jul. 04, 2022. [Online]. Available: <https://journal.ithb.ac.id/telematika/article/view/340>
- [19] N. Aulia, "Prediksi Harga Ethereum Berdasarkan Informasi Blockchain Menggunakan Metode Long Short Term Memory," 2020, Accessed: Jul. 04, 2022. [Online]. Available: <https://dspace.uui.ac.id/handle/123456789/23610>