



ITS
Institut
Teknologi
Sepuluh Nopember

TUGAS AKHIR - IS184853

PERAMALAN HARGA SAHAM DENGAN MENGUNAKAN METODE LONG SHORT-TERM MEMORY (LSTM) RNN

STOCK PRICE FORECASTING USING LONG SHORT-TERM MEMORY (LSTM) RNN

ISVANIA ALMIRA JANITRA
NRP. 05211640000017

Dosen Pembimbing
Ahmad Muklason, S.Kom., M.Sc., Ph.D.
Dr. Retno Aulia Vinarti, S.Kom., M.Kom.

DEPARTEMEN SISTEM INFORMASI
Fakultas Teknologi Elektro dan Informatika Cerdas
Institut Teknologi Sepuluh Nopember
Surabaya 2020



ITS
Institut
Teknologi
Sepuluh Nopember

TUGAS AKHIR - IS184853

PERAMALAN HARGA SAHAM DENGAN MENGGUNAKAN METODE LONG SHORT- TERM MEMORY (LSTM) RNN

ISYANIA ALMIRA JANITRA
NRP. 0521164000017

Dosen Pembimbing
Ahmad Muklason, S.Kom., M.Sc., Ph.D.
Dr. Retno Aulia Vinarti, S.Kom., M.Kom.

DEPARTEMEN SISTEM INFORMASI
Fakultas Teknologi Elektro dan Informatika Cerdas
Institut Teknologi Sepuluh Nopember
Surabaya 2020



UNDERGRADUATE THESIS - IS184853

STOCK PRICE FORECASTING USING LONG SHORT-TERM MEMORY (LSTM) RNN

ISYANIA ALMIRA JANITRA
NRP. 05211640000017

Supervisors
Ahmad Muklason, S.Kom., M.Sc., Ph.D.
Dr. Retno Aulia Vinarti, S.Kom., M.Kom.

DEPARTMENT OF INFORMATION SYSTEMS
Faculty of Intelligent Electrical and Informatics Technology
Institut Teknologi Sepuluh Nopember
Surabaya 2020

LEMBAR PENGESAHAN

PERAMALAN HARGA SAHAM DENGAN MENGUNAKAN METODE LONG SHORT-TERM MEMORY (LSTM) RNN

TUGAS AKHIR

Disusun untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer
pada
Departemen Sistem Informasi
Fakultas Teknologi Elektro dan Informatika Cerdas
Institut Teknologi Sepuluh Nopember

Oleh :

ISVANIA ALMIRA JANITRA
NRP. 05211640000017

Surabaya, Januari 2020

**KEPALA
DEPARTEMEN SISTEM INFORMASI**



~ ~ ~
Dr. Mujahidin, S.T., M.T.
NIP. 19701010 200312 1 001

LEMBAR PERSETUJUAN

PERAMALAN HARGA SAHAM DENGAN MENGUNAKAN METODE LONG SHORT-TERM MEMORY (LSTM) RNN

TUGAS AKHIR

Disusun untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer
pada
Departemen Sistem Informasi
Fakultas Teknologi Elektro dan Informatika Cerdas
Institut Teknologi Sepuluh Nopember

Oleh :

ISVANIA ALMIRA JANITRA
NRP. 0521164000017

Disetujui Tim Penguji : Tanggal Ujian : 2 Desember 2019
Periode Wisuda : Maret 2020

Ahmad Mukhlison, S.Kom., M.Sc, Ph.D.

(Pembimbing I)

Dr. Retna Aulia Winarti, S.Kom., M.Kom.

(Pembimbing II)

Edwin Riksa Komara, S.Kom., M.T.

(Penguji I)

Faizal Mahananto, S.Kom, M.Eng.

(Penguji II)



PERAMALAN HARGA SAHAM DENGAN MENGUNAKAN METODE LONG SHORT- TERM MEMORY (LSTM) RNN

Nama : Isvania Almira Janitra
NRP : 0521164000017
Departemen : Sistem Informasi - FTEIC
Pembimbing I : Ahmad Muklason, S.Kom., M.Sc., Ph.D.
Pembimbing II : Dr. Retno Aulia Vinarti, S.Kom, M.Kom.

ABSTRAK

Harga saham sangatlah penting bagi sebuah perusahaan karena dengan menginvestasi saham, perusahaan dapat melakukan pendanaan jangka panjang dengan cara menjual saham tersebut. Harga saham selalu mengalami perubahan dan tidak selalu stabil. Harga saham bersifat non linier dan non stasioner yang disebabkan oleh berbagai faktor. Harga saham merupakan data non linier yang dimana tiap datanya membentuk hubungan hierarki sehingga data saham tersebut memiliki hubungan erat satu dengan yang lainnya (sequential). Harga saham merupakan data yang kompleks dengan kebisingan yang tidak terduga sehingga hal itu membuat harga saham sulit untuk diramalkan. Tetapi, peramalan harga saham di masa mendatang akan sangat berguna dan penting dalam perkembangan ekonomi serta dapat mempermudah perusahaan dan / atau investor dalam membuat keputusan finansial.

Long Short-Term Memory (LSTM) merupakan salah satu arsitektur terbaik dari Recurrent Neural Network (RNN) yang sudah terbukti dapat memproses data yang bersifat sequential. LSTM seringkali digunakan untuk meramalkan harga saham karena LSTM memiliki efek yang signifikan untuk permasalahan time series yaitu dapat memahami struktur data secara dinamis dari waktu ke waktu dengan kapasitas prediksi

yang tinggi. Hal tersebut sesuai karena data harga saham merupakan data yang non stasioner sehingga membutuhkan arsitektur yang dapat memahami struktur data secara dinamis dari waktu ke waktu. LSTM juga menggunakan sel memori sebagai unit perhitungan yang menggantikan neuron pada hidden layer jaringan. Oleh karena itu, LSTM dapat digunakan untuk meramalkan indeks harga saham di masa mendatang.

Mean Absolute Percentage Error (MAPE) merupakan ukuran ketepatan relatif yang digunakan untuk mengetahui persentase penyimpangan hasil peramalan dengan data aktual. Sedangkan, *Root Mean Square Error (RMSE)* adalah akar kuadrat dari mean atau average kuadrat dari semua eror. Semakin kecil nilai MAPE dan RMSE maka akan semakin kecil tingkat kesalahan atau erornya.

Peramalan harga saham dengan menggunakan Metode LSTM ini melibatkan variabel open, low, high, dan close dari harga saham harian Chevron Corporation dengan periode waktu 5 tahun dari tahun 2014-2019. Model LSTM terbaik yang diperoleh dari penelitian ini ialah model LSTM dengan satu hidden layer, 125 neuron hidden layer, 100 epochs, dan jenis optimizer Adam dengan nilai rata-rata MAPE testing sebesar 1.501% dan nilai rata-rata RMSE testing sebesar 2.397. Sedangkan untuk hasil peramalan harga saham Chevron Corporation satu bulan kedepan dengan model LSTM terbaik tersebut menghasilkan nilai MAPE sebesar 1.108% dan nilai RMSE sebesar 1.576.

Dengan adanya penelitian tentang peramalan harga saham dengan menggunakan Metode LSTM ini diharapkan dapat membantu perusahaan dan / atau investor untuk mengetahui indeks harga saham di masa mendatang. Hal tersebut dapat dilakukan dengan memperhatikan hasil peramalan harga saham dengan akurasi terbaik. Akurasi hasil peramalan yang terbaik dapat diketahui dengan melihat hasil perhitungan nilai MAPE testing dan RMSE testing yang diperoleh dari

peramalan tersebut. Dimana nilai MAPE di bawah 20% sudah dapat dikatakan baik dan nilai MAPE kurang dari 10% dinyatakan sangat baik. Sedangkan untuk nilai RMSE dapat dikatakan ideal jika nilai RMSE yang dihasilkan bernilai nol atau mendekati nol.

Kata Kunci : Harga Saham, Long Short-Term Memory (LSTM), Recurrent Neural Network (RNN), Mean Absolute Percentage Error (MAPE), Root Mean Square Error (RMSE)

Halaman ini sengaja dikosongkan

STOCK PRICE FORECASTING USING LONG SHORT-TERM MEMORY (LSTM) RNN

Name : Isvania Almira Janitra
NRP : 05211640000017
Department : Information Systems - FTEIC
Supervisor I : Ahmad Muklason, S.Kom., M.Sc., Ph.D.
Supervisor II : Dr. Retno Aulia Vinarti, S.Kom, M.Kom.

ABSTRACT

Stock price is very important for a company because by investing in shares, the company can make long-term funding by selling the shares. Stock prices always change and are not always stable. Stock prices are non-linear and non-stationary which are caused by various factors. Stock prices are non-linear data in which each data forms a hierarchical relationship so that the stock data has a close relationship with one another (sequential). Stock prices are complex data with unexpected noise so it makes stock prices difficult to predict. However, forecasting stock prices in the future will be very useful and important in economic development and can facilitate companies and / or investors in making financial decisions.

Long Short-Term Memory (LSTM) is one of the best architectures of Recurrent Neural Network (RNN) which has been proven to be able to process sequential data. LSTM is often used to predict stock prices because LSTM has a significant effect on time series problems that is able to understand data structures dynamically from time to time with high predictive capacity. This is appropriate because stock price data is non-stationary data so it requires an architecture that can understand data structures dynamically from time to time. LSTM also uses memory cells as calculation units that replace

neurons in the hidden layer network. Therefore, LSTM can be used to forecast the stock price index in the future.

Mean Absolute Percentage Error (MAPE) is a measure of relative accuracy used to determine the percentage of deviation from forecasting results with actual data. Whereas, Root Mean Square Error (RMSE) is the square root of the mean or average square of all errors. The smaller the MAPE and RMSE values the smaller the error or error rate.

Forecasting stock prices using the LSTM Method involves the open, low, high, and close variables of Chevron Corporation's daily share price with a period of 5 years from 2014-2019. The best LSTM models obtained from this study are LSTM models with one hidden layer, 125 hidden layer neurons, 100 epochs, and Adam optimizer type with an average MAPE testing value of 1.501% and an average RMSE testing value of 2.397. As for the results of forecasting Chevron Corporation stock prices one month ahead with the best LSTM model produces a MAPE value of 1.108% and an RMSE value of 1.576.

Mean Absolute Percentage Error (MAPE) is a measure of relative accuracy used to determine the percentage of deviation from forecasting results with actual data. This can avoid problems in interpreting the measurement of accuracy relative to the magnitude of the actual and predicted values. Where MAPE values below 20% can be said to be good, and MAPE values of less than 10% are stated to be very good. The smaller the MAPE value obtained, the smaller the error or error rate.

With the research on stock price forecasting using the LSTM Method is expected to help companies and / or investors to find out the stock price index in the future. This can be done by taking into account the results of forecasting stock prices with the best accuracy. The best accuracy of forecasting results can be known by looking at the results of the value of MAPE testing and RMSE testing obtained from the forecasting. Where MAPE

values below 20% can be said to be good and MAPE values less than 10% are declared very good. Whereas the RMSE value can be said to be ideal if the resulting RMSE value is zero or close to zero.

Keywords : Stock Price, Long Short-Term Memory (LSTM), Recurrent Neural Network (RNN), Mean Absolute Percentage Error (MAPE), Root Mean Square Error (RMSE)

Halaman ini sengaja dikosongkan

SURAT PERNYATAAN BEBAS PLAGIARISME

Saya yang bertandatangan di bawah ini:

Nama : Isvania Almira Janitra
NRP : 05211640000017
Tempat/Tanggal lahir : Jakarta / 6 Januari 1998
Fakultas/Departemen : FTEIC / Sistem Informasi
Nomor Telp/Hp/email : 082144450130 /
vanialmirajnr@gmail.com

Dengan ini menyatakan dengan sesungguhnya bahwa penelitian/makalah/tugas akhir saya yang berjudul:

PERAMALAN HARGA SAHAM DENGAN
MENGUNAKAN METODE LONG SHORT-TERM
MEMORY (LSTM) RNN

Bebas dari Plagiarisme dan Bukan Hasil Karya Orang Lain.

Apabila dikemudian hari ditemukan seluruh atau sebagian penelitian/makalah/tugas akhir tersebut terdapat indikasi plagiarisme, maka saya bersedia menerima sanksi sesuai peraturan dan ketentuan yang berlaku.

Demikian surat pernyataan ini saya buat dengan sesungguhnya dan untuk dipergunakan sebagaimana mestinya.

Surabaya, 2 Desember 2019



Isvania Almira Janitra
NRP. 05211640000017

Halaman ini sengaja dikosongkan

KATA PENGANTAR

Segala puji bagi Allah SWT yang telah memberikan karunia-Nya sehingga penulis dapat menyelesaikan tugas akhir yang berjudul **“Peramalan Harga Saham dengan Menggunakan Metode Long Short-Term Memory (LSTM) RNN”** ini sebagai salah satu syarat kelulusan di Departemen Sistem Informasi Fakultas Teknologi Elektro dan Informatika Cerdas Institut Teknologi Sepuluh Nopember Surabaya.

Terima kasih penulis sampaikan kepada pihak-pihak yang telah mendukung, memberikan saran, motivasi, semangat, doa, dan bantuan baik berupa materiil maupun moril demi tercapainya tujuan pembuatan tugas akhir ini. Secara khusus penulis menyampaikan ucapan terima kasih yang sedalam-dalamnya kepada:

1. Kedua orang tua dan adik penulis, Bapak Isfanari Iskandar, S.T., M.T., Ibu Entin Listiandarina, S.E, dan Adek Aisy yang senantiasa mendoakan, memberikan motivasi dan semangat, sehingga penulis mampu menyelesaikan tugas akhir dan pendidikan sarjana ini dengan baik.
2. Bapak Dr. Mudjahidin, S.T., M.T. selaku Kepala Departemen Sistem Informasi ITS, Bapak Nisfu Asrul Sani, S.Kom., M.Sc. selaku Ketua Program Studi Sarjana Departemen Sistem Informasi ITS, serta seluruh dosen pengajar beserta staf dan karyawan Departemen Sistem Informasi ITS selama penulis menjalani perkuliahan.
3. Ibu Nur Aini Rakhmawati, S.Kom., M.Sc.Eng., Ph.D. sebagai dosen wali penulis selama menempuh pendidikan di Departemen Sistem Informasi ITS.
4. Bapak Ahmad Muklason, S.Kom., M.Sc., Ph.D. dan Ibu Dr. Retno Aulia Vinarti, S.Kom, M.Kom. selaku dosen pembimbing yang telah banyak meluangkan waktu untuk membimbing, mengarahkan, dan mendukung dengan

- memberikan ilmu, petunjuk, dan motivasi dalam penyelesaian tugas akhir ini.
5. Bapak Edwin Riksakomara, S.Kom., M.T. dan Bapak Faizal Mahananto, S.Kom., M.Eng. selaku dosen penguji yang telah memberikan kritik dan saran dalam penyempurnaan tugas akhir ini.
 6. Ibu Wiwik Anggraeni, S.Si., M.Kom. selaku dosen yang telah banyak meluangkan waktu untuk membimbing, mengarahkan, dan mendukung dengan memberikan ilmu, petunjuk, dan motivasi dalam penyelesaian tugas akhir ini.
 7. Mas Adytiawan Arga Dwitama selaku mentor penulis ketika melaksanakan kerja praktik di Chevron Pacific Indonesia yang telah mengarahkan, memberikan ilmu, petunjuk, dan saran dalam penyelesaian tugas akhir ini.
 8. Teman-teman Sistem Informasi angkatan 2016 (Artemis) yang senantiasa menemani dan memberikan motivasi bagi penulis selama perkuliahan hingga dapat menyelesaikan tugas akhir ini.
 9. Teman-teman laboratorium RDIB (*10 shades of RDIB*) yang senantiasa berjuang bersama-sama dengan penulis.
 10. Seluruh pihak lainnya yang tidak dapat disebutkan satu per satu, yang telah membantu penulis selama perkuliahan hingga dapat menyelesaikan tugas akhir ini.

Penyusunan laporan tugas akhir ini masih jauh dari kata sempurna, sehingga penulis menerima adanya kritik maupun saran yang membangun untuk perbaikan di masa yang akan datang. Semoga buku tugas akhir ini dapat memberikan manfaat bagi pembaca.

Surabaya, 2 Desember 2019

Penulis

DAFTAR ISI

LEMBAR PENGESAHAN	I
LEMBAR PERSETUJUAN.....	III
ABSTRAK	V
<i>ABSTRACT</i>	IX
SURAT PERNYATAAN BEBAS PLAGIARISME	XIII
KATA PENGANTAR	XV
DAFTAR ISI.....	XVII
DAFTAR TABEL.....	XXIII
DAFTAR KODE.....	XXV
BAB I PENDAHULUAN	1
1.1. Latar Belakang	1
1.2. Rumusan Masalah	4
1.3. Batasan Masalah.....	4
1.4. Tujuan.....	5
1.5. Manfaat.....	5
1.5.1. Bagi Penulis.....	6
1.5.2. Bagi Bidang Ilmu Pengetahuan.....	6
1.5.3. Bagi Pelaku Bisnis Terkait.....	6
1.6. Relevansi	6
BAB II TINJAUAN PUSTAKA.....	9
2.1. Penelitian Sebelumnya	9
2.2. Dasar Teori.....	15
2.2.1 Peramalan.....	15
2.2.2 Harga Saham	16
2.2.3 Recurrent Neural Network (RNN)	17
2.2.4 Long Short-Term Memory (LSTM).....	18
2.2.4.1 Forget Gate.....	20
2.2.4.2 Input Gate.....	20
2.2.4.3 Output Gate	20
2.2.4.4 Update Gate.....	21
2.2.5 <i>Training Long Short-Term Memory</i>	21
2.2.6 Mean Absolute Percentage Error (MAPE).....	21
2.2.7 Root Mean Square Error (RMSE).....	22

BAB III METODOLOGI	23
3.1 Diagram Metodologi.....	23
3.2 Studi Literatur	23
3.3 Pengumpulan Data.....	24
3.4 Data <i>Preprocessing</i>	24
3.5 Pembuatan Model LSTM	25
3.6 Peramalan dengan Model LSTM.....	25
3.7 Analisis dan Pengujian Performa Model LSTM.....	25
3.8 Penyusunan Buku TA	26
BAB IV PERANCANGAN	29
4.1 Pengumpulan Data dan Data <i>PreProcessing</i>	29
4.1.1 Pengumpulan Data.....	29
4.1.2 Uji Korelasi	29
4.1.3 Data <i>Preprocessing</i>	30
4.2 Pembuatan Model LSTM	30
4.3 Peramalan dengan Model LSTM.....	34
4.4 Analisis dan Pengujian Performa Model LSTM.....	34
BAB V IMPLEMENTASI	37
5.1 Pengumpulan Data.....	37
5.2 Uji Korelasi.....	38
5.3 Data <i>Preprocessing</i>	38
5.3.1 Normalisasi Data	38
5.3.2 Pengubahan Data menjadi <i>Supervised Learning</i>	39
5.3.3 Pembagian Data <i>Training</i> dan Data <i>Testing</i>	41
5.4 Pembuatan Model LSTM	42
5.5 Pembuatan Model Simple RNN	43
5.6 Peramalan dengan Model LSTM.....	44
5.7 Analisis dan Pengujian Performa Model LSTM.....	45
6 BAB VI HASIL DAN PEMBAHASAN	47
6.1 Hasil Pengumpulan Data	47
6.2 Hasil Uji Korelasi	48
6.3 Hasil Data <i>Preprocessing</i>	49
6.4 Hasil Analisis dan Pengujian Performa Model	50
6.5 Hasil Peramalan Data <i>Training</i>	53
6.6 Hasil Peramalan Data <i>Testing</i>	53
6.7 Hasil Peramalan Data Chevron Corporation	54

6.7.1 Hasil Peramalan Data <i>Open</i>	55
6.7.2 Hasil Peramalan Data <i>Low</i>	55
6.7.3 Hasil Peramalan Data <i>High</i>	56
6.8 Hasil Peramalan Masa Mendatang	57
6.9 Hasil Peramalan dengan Data Saham Lain.....	57
6.10 Hasil Peramalan dengan 12 <i>Timewindow</i>	60
6.11 Hasil Peramalan dengan Model Simple RNN	61
6.12 Hasil Perbandingan Nilai MAPE dan RMSE	62
BAB VII KESIMPULAN DAN SARAN	63
7.1 Kesimpulan.....	63
7.2 Saran.....	64
DAFTAR PUSTAKA	65
BIODATA PENULIS	67
LAMPIRAN A. DETAIL PERCOBAAN MODEL	69
LAMPIRAN B. DETAIL PERCOBAAN MODEL LSTM 12 <i>TIMEWINDOW</i>	101

Halaman ini sengaja dikosongkan

DAFTAR GAMBAR

Gambar 2.1. Memori pada RNN	17
Gambar 2.2. Arsitektur LSTM	18
Gambar 2.3. Simbol Arsitektur LSTM.....	19
Gambar 3.1. Diagram Metodologi Penelitian	23
Gambar 6.1. Plot Data Harga Saham Harian.....	47
Gambar 6.2. Hasil Uji Korelasi	48
Gambar 6.3. Data yang sudah dinormalisasi	49
Gambar 6.4. Grafik Perbandingan Data Aktual dan Prediksi untuk Hasil Peramalan Data Training	53
Gambar 6.5. Grafik Perbandingan Data Aktual dan Prediksi untuk Hasil Peramalan Data Testing	54
Gambar 6.6. Grafik Hasil Peramalan Data Open Chevron Corporation	55
Gambar 6.7. Grafik Hasil Peramalan Data Low Chevron Corporation	56
Gambar 6.8. Grafik Hasil Peramalan Data High Chevron Corporation	56
Gambar 6.9. Grafik Perbandingan Data Aktual dan Prediksi untuk Hasil Peramalan Data Harga Saham Chevron 1 Bulan Kedepan	57
Gambar 6.10. Grafik Perbandingan Data Aktual dan Prediksi untuk Hasil Peramalan Data Harga Saham Starbucks Corporation	58
Gambar 6.11. Grafik Perbandingan Data Aktual dan Prediksi untuk Hasil Peramalan Data Harga Saham Apple Inc....	59
Gambar 6.12. Grafik Perbandingan Data Aktual dan Prediksi untuk Hasil Peramalan Data Harga Saham Sidomulyo..	59
Gambar 6.13. Grafik Hasil Peramalan Data Close Chevron Corporation dengan 12 Timewindow.....	60
Gambar 6.14. Grafik Hasil Peramalan Data Chevron Corporation dengan Model Simple RNN.....	61

Halaman ini sengaja dikosongkan

DAFTAR TABEL

Tabel 2.1. Literatur 1	9
Tabel 2.2. Literatur 2	10
Tabel 2.3. Literatur 3	12
Tabel 2.4. Literatur 4	13
Tabel 2.5. Kriteria MAPE	22
Tabel 4.1. Detail Kombinasi Model LSTM	31
Tabel 6.1. Analisa Hasil Peramalan dengan Model LSTM....	50
Tabel 6.2. Hasil Perbandingan Nilai MAPE dan RMSE.....	62

Halaman ini sengaja dikosongkan

DAFTAR KODE

Kode 5.1. Implementasi plotting data dengan matplotlib.pyplot	37
Kode 5.2. Implementasi normalisasi data dengan MinMax Normalization.....	38
Kode 5.3. Pembuatan fungsi pengubahan data ke supervised learning.....	39
Kode 5.4. Pengubahan data menjadi Supervised Learning	40
Kode 5.5. Menghapus kolom yang tidak ingin diramalkan ...	40
Kode 5.6. Supervised Learning 12 Timewindow.....	41
Kode 5.7. Menghapus Kolom Open, Low, dan High.....	41
Kode 5.8. Pembagian data training dan testing	42
Kode 5.9. Model LSTM dengan 1 hidden layer.....	42
Kode 5.10. Model LSTM dengan 2 hidden layer.....	43
Kode 5.11. Fit Model LSTM.....	43
Kode 5.12. Model Simple RNN.....	43
Kode 5.13. Fit Model Simple RNN.....	44
Kode 5.14. Peramalan dengan data training.....	45
Kode 5.15. Peramalan dengan data testing.....	45
Kode 5.16. Penghitungan MAPE dan RMSE	46
Kode 5.17. Penghitungan SMAPE.....	46

Halaman ini sengaja dikosongkan

BAB I

PENDAHULUAN

Pada bab ini akan menjelaskan tentang latar belakang penelitian, perumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian, dan relevansi terhadap penelitian yang dilakukan. Berdasarkan penjelasan pada bab ini diharapkan dapat memberikan gambaran umum mengenai permasalahan dan pemecahan masalah pada tugas akhir ini.

1.1. Latar Belakang

Dewasa ini, pertumbuhan ekonomi untuk suatu negara merupakan hal yang krusial. Seiring dengan berkembangnya dunia bisnis yang memasuki era globalisasi mengakibatkan persaingan ekonomi yang semakin tajam, sehingga setiap perusahaan dituntut untuk senantiasa berproduksi secara efisien dan mampu membuat keputusan finansial yang tepat bila ingin tetap memiliki keunggulan daya saing [1]. Perusahaan-perusahaan di Indonesia mengandalkan pasar modal yang sedang berkembang (*emerging market*) dimana dalam perkembangannya sangat rentan terhadap kondisi makroekonomi secara umum [2].

Perkembangan pasar modal dapat dilihat pada Indeks Harga Saham Gabungan (IHSG) yang digunakan oleh Bursa Efek Indonesia. Harga saham yang naik menunjukkan peningkatan pasar sedangkan harga saham yang turun menunjukkan adanya kelesuan pasar [3]. Harga saham sangatlah penting bagi sebuah perusahaan karena dengan menginvestasi saham, perusahaan dapat melakukan pendanaan jangka panjang dengan cara menjual saham tersebut.

Harga saham selalu mengalami perubahan dan tidak selalu stabil karena bersifat non linier dan non stasioner yang disebabkan oleh berbagai faktor. Harga saham merupakan data yang kompleks dengan kebisingan yang tidak terduga sehingga hal itu membuat harga saham sulit untuk diramalkan. Peramalan

harga saham merupakan suatu hal yang sulit untuk diprediksi. Tetapi, peramalan harga saham di masa mendatang akan sangat berguna dan penting dalam perkembangan ekonomi serta dapat mempermudah perusahaan dan / atau investor dalam membuat keputusan finansial.

Dengan perkembangan teknologi yang semakin pesat, peluang untuk memprediksi harga saham dengan berbagai metode yang ada mulai terbuka lebar. Metode-metode yang sudah pernah digunakan untuk meramalkan harga saham yaitu Deep Neural Network (DNN), Support Vector Regression (SVR), Back propagation Algorithm-Multi-layer Perceptron, Support Vector Machine (SVM), dll. Dengan adanya berbagai metode tersebut memicu para peneliti untuk membandingkan hasil prediksi dari tiap metode untuk memperoleh metode yang terbaik untuk mendapatkan hasil peramalan saham yang akurat.

Pada tugas akhir ini, penulis menggunakan Metode Long Short-Term Memory (LSTM) RNN untuk meramalkan harga saham harian. Data harga saham harian yang digunakan ialah data harga saham harian Chevron Corporation yang diperoleh dari Yahoo Finance. LSTM adalah salah satu arsitektur terbaik dari Recurrent Neural Network (RNN) yang sudah terbukti dapat memproses data yang bersifat *sequential*. Metode LSTM RNN tersebut dipilih karena data harga saham yang digunakan bersifat *sequential* dan mempunyai hubungan erat satu dengan yang lainnya. Arsitektur RNN melakukan perhitungan yang sama secara berulang-ulang atas *input* yang kita berikan begitupula dengan LSTM. LSTM dikatakan arsitektur terbaik dari RNN karena pada LSTM terdapat *timewindow* yang ditentukan berdasarkan seberapa banyak ketergantungan yang ada pada data harga saham harian tersebut. LSTM diperkenalkan oleh Sepp Hochreite dan Jurgen Schmidhuber pada tahun 1997 [4]. LSTM dirancang untuk memperkirakan, memprediksi dan mengklasifikasikan data *time series* bahkan dengan jeda waktu yang lama antara peristiwa-peristiwa penting yang terjadi sebelumnya. LSTM seringkali digunakan

untuk meramalkan harga saham karena LSTM memiliki efek yang signifikan untuk permasalahan *time series* yaitu dapat memahami struktur data secara dinamis dari waktu ke waktu dengan kapasitas prediksi yang tinggi. LSTM menggunakan sel memori sebagai unit perhitungan yang menggantikan *neuron* pada *hidden layer* jaringan. TensorFlow pada LSTM juga mampu memperbarui keadaan saat ini dengan informasi di masa lalu dan menghitung gradien menggunakan *truncated Backpropogation Through Time (BPTT)* yang mampu secara efektif mencegah masalah *gradient vanishing* yang umum di banyak jaringan saraf terutama pada Recurrent Neural Network (RNN). Oleh karena itu, LSTM dapat digunakan untuk meramalkan indeks harga saham di masa mendatang.

Peramalan harga saham harian dengan menggunakan Metode LSTM ini melibatkan variabel *open*, *low*, *high*, dan *close* dari harga saham harian Chevron Corporation dengan periode waktu 5 tahun dari tahun 2014-2019. Peramalan harga saham dengan menggunakan Metode LSTM ini menggunakan data harga saham harian Chevron Corporation dalam proses pembuatan modelnya kemudian model LSTM terbaik yang diperoleh akan diuji menggunakan data harga saham perusahaan lainnya guna menguji apakah model tersebut bisa digunakan untuk meramalkan data harga saham harian lainnya atau tidak. Data harga saham harian lainnya yang digunakan dalam penelitian ini ialah data harga saham harian Starbucks Corporation, Apple Inc, dan Sidomulyo. Peramalan harga saham harian ini melibatkan variabel *open*, *low*, *high*, dan *close* karena data tersebut saling berpengaruh terhadap perubahan harga saham seiring berjalannya waktu. Untuk menguji akurasi dari hasil peramalan harga saham tersebut dapat dilihat dari nilai Mean Absolute Percentage Error (MAPE) dan Root Mean Square Error (RMSE). MAPE merupakan ukuran ketepatan relatif yang digunakan untuk mengetahui persentase penyimpangan hasil peramalan dengan data aktual. Hal tersebut dapat menghindari permasalahan dalam interpretasi pengukuran akurasi relatif terhadap besarnya nilai aktual dan nilai prediksi. Dimana nilai

MAPE di bawah 20% sudah dapat dikatakan baik, dan nilai MAPE kurang dari 10% dinyatakan sangat baik. Sedangkan, RMSE adalah akar kuadrat dari *mean* atau *average* kuadrat dari semua eror. Dimana nilai RMSE dapat dikatakan ideal jika nilai RMSE yang dihasilkan bernilai nol atau mendekati nol. Semakin kecil nilai MAPE dan RMSE maka akan semakin kecil tingkat kesalahan atau erornya.

Dengan adanya penelitian tentang peramalan harga saham dengan menggunakan Metode LSTM ini diharapkan dapat membantu perusahaan dan / atau investor untuk mengetahui indeks harga saham di masa mendatang. Hal tersebut dapat dilakukan dengan memperhatikan hasil peramalan harga saham dengan akurasi terbaik. Akurasi hasil peramalan yang terbaik dapat diketahui dengan melihat hasil perhitungan nilai MAPE *testing* dan RMSE *testing* yang diperoleh dari peramalan tersebut.

1.2. Rumusan Masalah

Berdasarkan uraian pada latar belakang tersebut, berikut rumusan masalah yang akan diselesaikan dalam tugas akhir ini:

1. Bagaimana model Long Short-Term Memory pada peramalan harga saham harian?
2. Bagaimana hasil peramalan harga saham harian dengan menggunakan Metode Long Short-Term Memory?
3. Bagaimana akurasi hasil peramalan harga saham harian dengan menggunakan Metode Long Short-Term Memory?

1.3. Batasan Masalah

Berdasarkan pada rumusan masalah yang telah disebutkan di atas, berikut batasan masalah terkait dengan pengerjaan tugas akhir ini:

1. Data yang digunakan pada penelitian ini ialah data harga saham harian Chevron Corporation dengan periode waktu 5 tahun dari tahun 2014-2019 yang diperoleh dari Yahoo Finance.

2. Data harga saham lain yang digunakan untuk menguji model LSTM pada penelitian ini ialah data harga saham harian Starbucks Corporation, Apple Inc, dan Sidomulyo dengan periode waktu 5 tahun dari tahun 2014-2019 yang diperoleh dari Yahoo Finance.
3. Variabel yang dilibatkan dalam penelitian ini ialah data *open*, *low*, *high*, dan *close* dari harga saham harian Chevron Corporation.
4. Ukuran *timewindow* yang digunakan dalam peramalan harga saham harian ini ialah 20.
5. Jumlah *hidden layer* yang digunakan untuk membuat model LSTM pada penelitian ini ialah 1 dan 2.
6. Jenis *optimizer* yang digunakan untuk membuat model LSTM pada penelitian ini ialah Adam, Adamax, dan RMSprop.
7. Peramalan harga saham harian dengan Metode LSTM pada penelitian ini menggunakan bahasa pemrograman Python, *library* Keras, dan TensorFlow sebagai *back-end*.

1.4. Tujuan

Berikut tujuan dari penelitian tugas akhir ini berdasarkan pada pemaparan latar belakang dan rumusan masalah di atas:

1. Mendapatkan model Long Short-Term Memory yang terbaik untuk meramalkan harga saham harian.
2. Memperoleh hasil peramalan harga saham harian yang akurat dengan menggunakan Metode Long Short-Term Memory.
3. Mengetahui akurasi dari hasil peramalan harga saham harian dengan menggunakan Metode Long Short-Term Memory berdasarkan nilai Mean Absolute Percentage Error (MAPE) dan Root Mean Square Error (RMSE) yang diperoleh.

1.5. Manfaat

Berikut merupakan manfaat yang diharapkan dari penelitian tugas akhir ini:

1.5.1. Bagi Penulis

1. Mampu memahami metode dan model arsitektur LSTM RNN dalam melakukan peramalan harga saham jangka panjang.
2. Mampu menghitung akurasi dari hasil peramalan harga saham harian Chevron Corporation dengan Metode LSTM berdasarkan nilai MAPE yang diperoleh.

1.5.2. Bagi Bidang Ilmu Pengetahuan

Penelitian ini dapat dijadikan rujukan untuk penelitian terkait dengan peramalan harga saham harian dengan menggunakan Metode Long Short-Term Memory (LSTM).

1.5.3. Bagi Pelaku Bisnis Terkait

Penelitian ini dapat membantu investor dan / atau Chevron Corporation dalam mengetahui perkembangan harga saham di masa mendatang dan memudahkan pihak terkait dalam membuat keputusan finansial.

1.6. Relevansi

Peramalan Harga Saham dengan Menggunakan Metode Long Short-Term Memory (LSTM) RNN ini merupakan sebuah penelitian guna memenuhi tugas akhir yang memiliki relevansi dengan bidang keilmuan pada Laboratorium Rekayasa Data dan Intelengensi Bisnis (RDIB) di bidang *Computerized Decision Support*. Penelitian tugas akhir ini termasuk ke dalam cabang Ilmu Sistem Pemodelan dan Analisis karena penelitian tugas akhir ini menggunakan teknik peramalan dengan Metode LSTM yang relevan dengan mata kuliah Teknik Peramalan, Analitika Bisnis, dan Sistem Pendukung Keputusan.

Penelitian tugas akhir ini mengambil topik Peramalan Saham dengan menggunakan Metode LSTM yang dimana penelitian ini masih sangat relevan dengan keadaan saat ini. Dimana seiring dengan berkembangnya dunia bisnis yang memasuki era globalisasi ini mengakibatkan persaingan ekonomi yang

semakin tajam, sehingga setiap perusahaan dituntut untuk senantiasa memproduksi secara efisien dan mampu membuat keputusan finansial yang tepat bila ingin tetap memiliki keunggulan daya saing. Perusahaan di Indonesia sangat mengandalkan pasar modal dan hal ini secara tidak langsung berkaitan erat dengan harga saham. Oleh karena itu, topik ini akan sangat berguna untuk perusahaan dalam membuat keputusan finansial. Harga saham juga merupakan hal yang krusial bagi perusahaan. Peramalan harga saham harian dengan menggunakan Metode LSTM akan sangat membantu perusahaan, ditambah lagi metode ini merupakan metode baru yang sangat cocok digunakan untuk meramalkan harga saham jangka panjang suatu perusahaan. LSTM juga merupakan salah satu arsitektur terbaik dari Recurrent Neural Network (RNN) yang sudah terbukti dapat memproses data yang bersifat *sequential*. Selain itu terdapat banyak penelitian yang telah menggunakan LSTM untuk meramalkan harga saham jangka panjang. Dengan adanya beberapa penelitian mengenai peramalan harga saham dengan menggunakan Metode LSTM, maka dapat dikatakan bahwa Metode LSTM pada penelitian tugas akhir ini masih relevan dan layak untuk digunakan.

Halaman ini sengaja dikosongkan

BAB II TINJAUAN PUSTAKA

Pada bab ini akan menjelaskan tentang penelitian-penelitian terkait yang telah dilakukan sebelumnya dan dasar teori yang nantinya akan dijadikan sebagai acuan dalam pengerjaan tugas akhir ini.

2.1. Penelitian Sebelumnya

Terdapat beberapa penelitian sebelumnya yang memiliki topik serupa dengan tugas akhir ini dan dijadikan sebagai acuan dalam pengerjaan tugas akhir ini yang disajikan pada Tabel 2.1 sampai Tabel 2.4.

Tabel 2.1. Literatur 1

Penelitian I	
Judul Paper	<i>A Comparative Study of LSTM and DNN for Stock Market Forecasting</i>
Penulis; Tahun	Dev Shah, Wesley Campbell, Farhana H. Zulkernine; 2018
Deskripsi Umum Penelitian	Penelitian ini menyajikan studi perbandingan antara dua model Artificial Neural Network (ANN) yaitu Long Short-Term Memory (LSTM) Recurrent Neural Network (RNN) dan Deep Neural Network (DNN) dalam memperkirakan pergerakan harian dan mingguan indeks Indian BSE Sensex. Penelitian ini menggunakan dua model karena ingin mengurangi <i>overfitting</i> dan ingin membandingkan model mana yang terbaik. Pada penelitian ini terdapat prediksi harian dari harga saham Tech Mahindra (NSE: TECHM) yang dibuat untuk menguji generalisasi model data dengan periode waktu 20 tahun. Kedua jaringan tersebut berkinerja baik dalam membuat prediksi harian, dan keduanya

	digeneralisasikan dengan baik untuk membuat prediksi harian dari data Tech Mahindra. Dengan bantuan strategi untuk menghindari <i>overfitting</i> , kedua model tersebut mampu menggeneralisasi dengan baik ke kumpulan data baru yang lebih tidak stabil. Dan, hasil yang diperoleh dari penelitian ini ialah LSTM RNN lebih mengungguli DNN dalam hal prediksi mingguan karena lebih menjanjikan untuk membuat prediksi jangka panjang.
Keterkaitan Penelitian	Referensi peramalan harga saham harian yang menggunakan Metode LSTM. Pada penelitian tersebut juga menggunakan bahasa pemrograman Python, <i>library</i> Keras dan TensorFlow sebagai <i>back-end</i> .
Kelebihan	Penelitian ini menggunakan dan membandingkan dua metode sekaligus yaitu LSTM dan DNN. Jadi dari hasil penelitian tersebut dapat diketahui LSTM merupakan model yang lebih unggul dibandingkan DNN untuk meramalkan harga saham karena lebih menjanjikan untuk membuat prediksi jangka panjang.

Tabel 2.2. Literatur 2

Penelitian II	
Judul Paper	<i>Predicting Stock Prices Using LSTM</i>
Penulis; Tahun	Murtaza Roondiwala, Harshal Patel, Shraddha Varma; 2017
Deskripsi Umum Penelitian	Penelitian ini menggunakan Metode Long Short-Term Memory (LSTM) dalam melakukan peramalan terhadap harga saham harian milik NIFTY 50 Company dengan data periode waktu 50 tahun. Variabel yang digunakan untuk

	<p>meramalkan harga saham harian NIFTY 50 tersebut ialah dari data <i>open</i>, <i>high</i>, <i>low</i>, <i>close</i>, dan <i>volume</i>. Pada penelitian tersebut, nilai <i>output</i> yang dihasilkan pada <i>output layer</i> RNN akan dibandingkan dengan nilai target yang ada. Parameter yang digunakan bervariasi dengan angka dan epoch yang berbeda untuk mengukur RMSE dari data <i>training</i> dan <i>testing</i>. Penelitian ini menggunakan LSTM RNN karena dianggap sudah terbukti merupakan model yang terbaik dan dapat digunakan untuk memproses <i>sequential data</i>. Penelitian ini mendapatkan hasil peramalan terbaik dengan nilai <i>training</i> RMSE 0.00983 dan <i>testing</i> RMSE 0.00859.</p>
<p>Keterkaitan Penelitian</p>	<p>Referensi peramalan harga saham yang menggunakan Metode LSTM dengan variabel data <i>open</i>, <i>high</i>, <i>low</i>, <i>close</i>, dan <i>volume</i> dari harga saham harian. Karena pada penelitian tugas akhir ini penulis juga menggunakan variabel data <i>open</i>, <i>high</i>, <i>low</i>, <i>close</i>, dan <i>volume</i> dari harga saham harian Chevron Corporation untuk melakukan peramalannya.</p>
<p>Kelebihan</p>	<p>Penelitian ini menggunakan LSTM RNN karena dianggap sudah terbukti merupakan model yang terbaik dan dapat digunakan untuk memproses <i>sequential data</i>. Penelitian ini mendapatkan hasil peramalan terbaik dengan nilai <i>training</i> RMSE 0.00983 dan <i>testing</i> RMSE 0.00859.</p>

Tabel 2.3. Literatur 3

Penelitian III	
Judul Paper	<i>LSTM model optimization on stock price forecasting</i>
Penulis; Tahun	Yifeng Wang, Yuying Liu, Meiqing Wang, Rong Liu; 2018
Deskripsi Umum Penelitian	<p>Penelitian ini berfokus pada algoritma Long Short-Term Memory (LSTM) untuk mengoptimasi peramalan harga saham. LSTM RNN memiliki efek yang signifikan pada masalah <i>time series</i>. Dalam penelitian ini, model jaringan saraf BP dan model LSTM diterapkan masing-masing dan kemudian digabungkan dengan data saham. Hasil yang diperoleh, jelas hasil prediksi model LSTM yang lebih akurat, dan tingkat akurasi prediksinya bisa mencapai 60%-65%. Dalam proses pemodelan pada penelitian ini, untuk menyelesaikan '<i>saw-tooth phenomenon</i>' dari algoritma <i>gradient descent</i> yang tidak dapat dihindari, peneliti telah meningkatkan algoritma <i>gradient descent</i> tradisional dan secara khusus mendesain data input dari jaringan saraf. Selain itu, pada penelitian ini juga menetapkan pustaka kombinasi parameter dan menggunakan keterampilan <i>dropout</i> untuk mendapatkan hasil prediksi yang lebih ideal. Pada penelitian ini telah ditemukan bahwa fungsi-fungsi di TensorFlow tidak selalu optimal. Dari perspektif <i>training speed</i>, fungsi yang ditulis dari prinsip matematika memiliki kecepatan yang lebih cepat, dan mereka dapat memiliki desain</p>

	atau peningkatan yang lebih rinci dalam situasi yang berbeda.
Keterkaitan Penelitian	Referensi peramalan harga saham yang menggunakan Metode LSTM dengan data harga saham harian dan menggunakan TensorFlow sebagai <i>back-end</i> .
Kelebihan	Penelitian ini berfokus pada algoritma LSTM dan membandingkan hasil peramalannya dengan BP neural network. Berdasarkan hasil perbandingan yang diperoleh, sudah jelas hasil prediksi model LSTM yang lebih akurat, dan tingkat akurasi prediksinya bisa mencapai 60%-65%.

Tabel 2.4. Literatur 4

Penelitian III	
Judul Paper	<i>Improving trading technical analysis with TensorFlow Long Short-Term Memory (LSTM) Neural Network</i>
Penulis; Tahun	Chenjie Sang, Massimo Di Pierro; 2018
Deskripsi Umum Penelitian	Penelitian ini menggunakan Long Short-Term Memory (LSTM) untuk meningkatkan algoritma <i>trading</i> tradisional yang digunakan dalam analisis teknis. Penelitian ini menggunakan Tensorflow <i>library</i> . Penelitian ini dilakukan karena jaringan dianggap dapat mempelajari perilaku pasar dan dapat memprediksi kemungkinan kapan strategi yang diberikan dapat berhasil. TensorFlow pada LSTM mampu memperbarui keadaan saat ini dengan informasi di masa lalu dan menghitung gradien menggunakan <i>truncated</i> Backpropogation Through Time

	<p>(BPTT) yang mampu secara efektif mencegah masalah <i>gradient vanishing</i> yang umum di banyak jaringan saraf terutama pada Recurrent Neural Network (RNN). Penelitian ini menunjukkan bahwa TensorFlow dapat bermanfaat bagi Industri Keuangan. Hal itu disebabkan karena sebagian besar data keuangan berkorelasi dengan <i>time series</i>. Oleh karena itu, Long Short-Term Memory (LSTM) dan Recurrent Neural Network memiliki kinerja terbaik dan terbukti lebih baik daripada algoritma <i>trading</i> tradisional.</p>
<p>Keterkaitan Penelitian</p>	<p>Referensi penggunaan TensorFlow <i>library</i>, dimana penelitian tersebut menggunakan TensorFlow <i>library</i> dalam meningkatkan algoritma <i>trading</i> tradisional yang digunakan dalam analisis teknis. Penelitian tersebut memiliki keterkaitan dengan penelitian tugas akhir ini karena pada penelitian tugas akhir ini dalam melakukan peramalan harga saham harian juga menggunakan LSTM dan menggunakan TensorFlow <i>library</i> sebagai <i>back-end</i>.</p>
<p>Kelebihan</p>	<p>Penelitian ini menunjukkan bahwa TensorFlow dapat bermanfaat bagi Industri Keuangan karena sebagian besar data keuangan berkorelasi dengan <i>time series</i>. Penelitian ini juga berhasil membuktikan bahwa Long Short-Term Memory (LSTM) dan Recurrent Neural Network memiliki kinerja terbaik dan terbukti lebih baik daripada algoritma <i>trading</i> tradisional.</p>

2.2 Dasar Teori

2.2.1 Peramalan

Menurut Heizer dan Render (2009:162), peramalan (*forecasting*) adalah seni dan ilmu untuk memperkirakan kejadian di masa depan [6]. Hal ini dapat dilakukan dengan melibatkan pengambilan data historis dan memproyeksikannya ke masa mendatang dengan suatu bentuk model matematis atau prediksi intuisi bersifat subyektif, atau menggunakan kombinasi model matematis yang disesuaikan dengan pertimbangan yang baik dari seorang manajer. Peramalan juga merupakan sebuah proses untuk memperkirakan beberapa kebutuhan di masa mendatang yang meliputi kebutuhan dalam ukuran kuantitas, kualitas, waktu dan lokasi yang dibutuhkan dalam rangka memenuhi permintaan barang ataupun jasa (Nasution, 1999).

Menurut Render dan Heizer (2004), jenis peramalan dapat dibedakan menjadi 3 jenis jika dilihat dari perencanaan operasi di masa depan yaitu:

- a. Peramalan ekonomi (*economic forecasting*)
Peramalan ekonomi tersebut menjelaskan siklus bisnis dengan memprediksi tingkat inflasi, ketersediaan uang, dana yang dibutuhkan untuk membangun perumahan dan indikator perencanaan lainnya [6].
- b. Peramalan teknologi (*technological forecasting*)
Peramalan teknologi ini memperhatikan tingkat kemajuan teknologi yang dapat meluncurkan produk baru yang menarik, produk yang membutuhkan pabrik dan peralatan baru [6].
- c. Peramalan permintaan (*demand forecasting*)
Peramalan permintaan merupakan sebuah proyeksi permintaan untuk produk atau layanan suatu perusahaan. Peramalan ini juga bisa disebut sebagai peramalan penjualan yang mengendalikan produksi, kapasitas, serta sistem penjadwalan dan menjadi *input* bagi perencanaan keuangan, pemasaran, dan sumber daya manusia [6].

Menurut Taylor (2004), peramalan dapat dikategorikan menjadi 3 jika dilihat berdasarkan horizon waktu peramalannya yaitu:


- a. Ramalan jangka pendek (*short-range forecasting*)
Peramalan ini mencakup masa depan yang dekat (*immediate future*) dan memperhatikan kegiatan harian suatu perusahaan bisnis, seperti permintaan harian atau kebutuhan sumber daya harian [6].
- b. Ramalan jangka menengah (*medium-range forecasting*)
Peramalan ini mencakup jangka waktu satu atau dua bulan sampai satu tahun. Ramalan jangka waktu ini umumnya lebih berkaitan dengan rencana produksi tahunan yang mencerminkan hal-hal seperti puncak dan lembah dalam suatu permintaan dan kebutuhan untuk menjamin adanya tambahan sumber daya untuk tahun berikutnya [6].
- c. Ramalan jangka Panjang (*long-range forecasting*)
Peramalan ini mencakup periode yang lebih lama dari satu atau dua tahun. Ramalan ini berkaitan dengan usaha manajemen untuk merencanakan produk baru untuk pasar yang berubah, membangun fasilitas baru, atau menjamin adanya pembiayaan jangka Panjang [6].

2.2.2 Harga Saham

Saham dikenal memiliki karakteristik *high-risk* pengembalian yaitu mempunyai peluang keuntungan yang tinggi namun juga memiliki potensi risiko yang tinggi. Investor bisa mendapatkan keuntungan (*capital gain*) dalam jumlah besar dalam waktu singkat dengan menginvestasi saham [3]. Namun seiring dengan berfluktuasinya harga saham, maka dapat membuat investor mengalami kerugian besar dalam waktu singkat. Harga aktual disebut juga harga terakhir dari transaksi yang terjadi pada saham. Harga aktual adalah harga saham berdasarkan waktu yang telah diberikan. Perkiraan harga pada transaksi selanjutnya dapat dilihat dari harga aktual saham sehingga harga aktual saham dapat dijadikan sebagai dasar untuk melakukan peramalan pada transaksi selanjutnya.

2.2.3 Recurrent Neural Network (RNN)

Recurrent Neural Network (RNN) adalah Neural Network dengan fasilitas umpan balik menuju neuron itu sendiri maupun *neuron* yang lain, sehingga aliran informasi dari *input* mempunyai arah jamak (*multidirectional*). *Output* RNN tidak hanya tergantung pada *input* saat itu saja, tetapi juga tergantung pada kondisi *input* NN pada waktu lampau. Kondisi ini dimaksudkan untuk menampung kejadian lampau diikuti dengan proses komputasi. Hal ini penting untuk problematika yang cukup rumit, dan *output* NN berkaitan dengan variasi waktu (*time-varying*), sehingga NN memiliki kepekaan terhadap waktu dengan memori kondisi pada masa lampau.




Gambar 2.1. Memori pada RNN

Pada Gambar 2.1 merupakan gambar dari memori RNN dimana RNN masih memiliki kekurangan, kekurangan itu dapat dilihat pada input X_0, X_1 yang memiliki rentang informasi yang sangat besar dengan X_t, X_{t+1} sehingga ketika h_1 memerlukan informasi yang relevan dengan X_0, X_1 . RNN tidak dapat menghubungkan informasi karena memori lama yang tersimpan akan semakin tidak berguna dengan seiring berjalannya waktu karena tertimpa atau tergantikan dengan memori baru. Permasalahan ini ditemukan oleh Bengio, et al. (1994). Berbeda dengan RNN, LSTM tidak memiliki kekurangan tersebut karena LSTM dapat mengatur memori pada setiap masukannya dengan menggunakan *memory cells* dan *gate units* [7].

2.2.4 Long Short-Term Memory (LSTM)


Long Short-Term Memory (LSTM) adalah salah satu arsitektur terbaik dari Recurrent Neural Network (RNN) yang sudah terbukti dapat memproses data yang bersifat *sequential*. LSTM diperkenalkan oleh Sepp Hochreite dan Jurgen Schmidhuber pada tahun 1997 [4]. LSTM dirancang untuk memperkirakan, memprediksi dan mengklasifikasikan data *time series* bahkan dengan jeda waktu yang lama antara peristiwa-peristiwa penting yang terjadi sebelumnya. LSTM juga dirancang secara eksplisit untuk menghindari masalah ketergantungan jangka panjang. LSTM seringkali digunakan untuk meramalkan harga saham karena LSTM memiliki efek yang signifikan untuk permasalahan *time series* yaitu dapat memahami struktur data secara dinamis dari waktu ke waktu dengan kapasitas prediksi yang tinggi. LSTM juga menggunakan sel memori sebagai unit perhitungan yang menggantikan *neuron* pada *hidden layer* jaringan [8].



Gambar 2.2. Arsitektur LSTM

Dalam standar RNN, modul berulang memiliki struktur yang sangat sederhana dimana hanya memiliki lapisan tanh tunggal. Sedangkan, LSTM memiliki struktur yang berbeda dimana LSTM memiliki empat lapisan yang memiliki fungsi yang berbeda-beda seperti yang dapat dilihat pada Gambar 2.2. Jaringan LSTM terdiri dari 4 lapisan, satu *input layer*, dua *hidden layer*, dan satu *output layer*. Pada LSTM RNN, suatu

cell akan menyimpan sebuah nilai atau keadaan (*cell state*), baik untuk periode waktu yang panjang ataupun singkat.



Gambar 2.3. Simbol Arsitektur LSTM

Pada Gambar 2.3 merupakan gambar simbol-simbol yang terdapat pada arsitektur LSTM, dimana setiap garis membawa seluruh vektor dari *output* satu *node* ke input yang lainnya. Lingkaran merah muda melambangkan *pointwise operation*, seperti penambahan vektor, sedangkan kotak kuning melambangkan *neural network layer*. Garis yang digabungkan menunjukkan penggabungan, sedangkan garis yang bercabang menunjukkan kontennya sedang disalin dan salinannya pergi ke lokasi yang berbeda.

Unit LSTM terdiri dari empat *gate* yaitu *Input Gate*, *Output Gate*, *Forget Gate*, dan *Update Gate*. *Input gate* mengendalikan sejauh mana sebuah nilai baru mengalir ke dalam *cell*, *forget gate* mengendalikan sejauh mana sebuah nilai tetap berada di dalam *cell*, dan *output gate* mengendalikan sejauh mana nilai dalam *cell* digunakan untuk menghitung aktivasi *output* dari unit LSTM RNN. Masing-masing *gate* memiliki parameter sendiri, yaitu bobot dan bias. Mereka terhubung sedemikian rupa sehingga menghasilkan:

x_t = Input Tensor

h_t = Output Tensor

W = Bobot

B = Fungsi Bias

2.2.4.1 Forget Gate

Pada *forget gate*, informasi pada setiap data masukan akan diolah dan dipilih data mana saja yang akan disimpan atau dibuang pada *memory cells*. Fungsi aktivasi yang digunakan pada *forget gate* ini adalah fungsi aktivasi sigmoid. Dimana hasil keluarannya antara 0 dan 1. Jika keluarannya adalah 1 maka semua data akan disimpan dan sebaliknya jika keluarannya 0 maka semua data akan dibuang [7]. Dengan rumus *Forget Gate* (f_t) sebagai berikut:

$$f_t = \sigma_f(W_{fx}x_t + W_{fh}h_{t-1} + b_f) \quad (2.1)$$

2.2.4.2 Input Gate

Pada *input gate* terdapat dua *gate* yang akan dijalankan, pertama akan diputuskan nilai mana yang akan diperbarui menggunakan fungsi aktivasi sigmoid. Selanjutnya, fungsi aktivasi tanh akan membuat vektor nilai baru yang nantinya akan disimpan pada *memory cell* [7]. Dengan rumus *Input Gate* (i_t) sebagai berikut:

$$i_t = \sigma_i(W_{ix}x_t + W_{ih}h_{t-1} + b_i) \quad (2.2)$$

2.2.4.3 Output Gate

Pada *output gate* terdapat dua *gate* yang akan dijalankan, pertama akan diputuskan nilai pada bagian *memory cell* mana yang akan dikeluarkan dengan menggunakan fungsi aktivasi sigmoid. Selanjutnya nilai akan ditempatkan pada *memory cell* dengan menggunakan fungsi aktivasi tanh. Kemudian kedua *gate* tersebut dikalikan sehingga menghasilkan nilai keluarannya [7]. Dengan rumus untuk *Output Gate* (o_t) sebagai berikut:

$$o_t = \sigma_o(W_{ox}x_t + W_{oh}h_{t-1} + b_o) \quad (2.3)$$

2.2.4.4 Update Gate

Update gate akan mengganti nilai pada *memory cell* sebelumnya dengan nilai *memory cell* yang baru. Dimana nilai ini didapatkan dari menggabungkan nilai-nilai yang terdapat pada *forget gate* dan *input gate* [7]. Dengan rumus *Update Gate* (c_t) sebagai berikut:

$$c_t = f_i c_{t-1} + i_t \tanh(W_{cx}x_t + W_{ch}h_{t-1} + b_c) \quad (2.4)$$

$$h_t = o_t \tanh(c_t) \quad (2.5)$$

TensorFlow pada LSTM mampu memperbarui keadaan saat ini dengan informasi di masa lalu dan menghitung gradien menggunakan *truncated* Backpropogation Through Time (BPTT) yang mampu secara efektif mencegah masalah *gradient vanishing* yang umum di banyak jaringan saraf terutama pada *Recurrent Neural Network (RNN)* [9].

2.2.5 Training Long Short-Term Memory

Pada tahap ini, data dimasukkan ke jaringan saraf dan dilatih untuk memprediksi dengan menggunakan data bias dan bobot yang acak. Model LSTM ini terdiri dari lapisan *input* berurutan yang diikuti oleh 2 lapisan LSTM yaitu *dense layer* dengan aktivasi ReLU dan *dense output layer* dengan fungsi aktivasi linier [5].

2.2.6 Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) merupakan ukuran ketepatan relatif yang digunakan untuk mengetahui persentase penyimpangan hasil peramalan dengan data aktual. Rumus perhitungan MAPE adalah sebagai berikut:

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \times 100 \quad (2.6)$$

Dimana,

n = jumlah sampel

y_t = data asli

\hat{y}_t = hasil peramalan

MAPE mengukur eror mutlak sebagai persentase bukan dari tiap periodenya melainkan dari rata-rata eror mutlak pada sejumlah periode data aktual. Hal tersebut dapat menghindari permasalahan dalam interpretasi pengukuran akurasi relatif terhadap besarnya nilai aktual dan nilai prediksi. Nilai yang dihasilkan melalui evaluasi ini, menunjukkan kemampuan peramalan seperti yang ditunjukkan dalam kriteria MAPE pada Tabel 2.5. Dimana nilai MAPE di bawah 20% sudah dapat dikatakan baik, dan nilai MAPE kurang dari 10% dinyatakan sangat baik.

Tabel 2.5. Kriteria MAPE

MAPE	Pengertian
<10%	Sangat Baik
10% - 20%	Baik
20% - 50%	Cukup
>50%	Buruk

2.2.7 Root Mean Square Error (RMSE)

Root Mean Square Error (RMSE) adalah akar kuadrat dari *mean* atau *average* kuadrat dari semua eror. RMSE biasa digunakan untuk menganalisa dan membuat metrik eror pada prediksi numerik. Nilai RMSE dapat meminimalkan eror dan perbedaan antara target dan nilai *output* yang diperoleh. Semakin kecil nilai RMSE maka akan semakin kecil tingkat kesalahan atau erornya [5]. Berikut cara untuk menghitung nilai RMSE:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum (\hat{Y}_t - Y_t)^2} \quad (2.7)$$

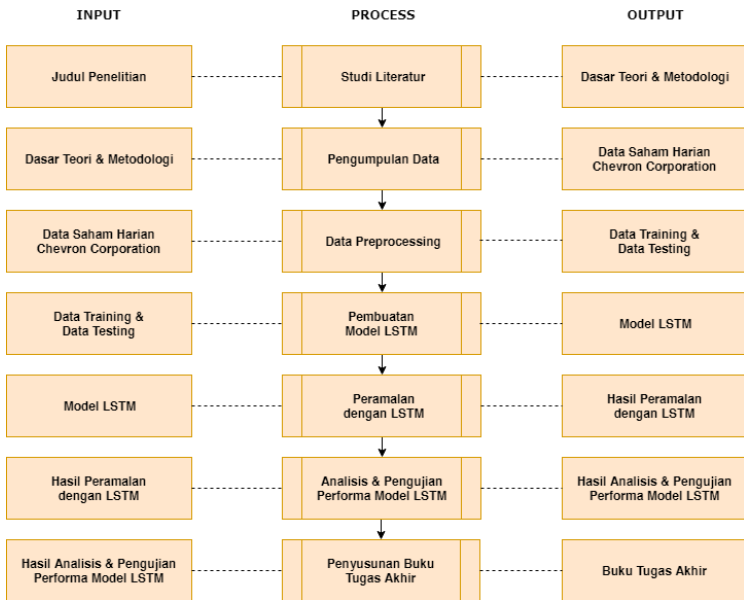
Dengan, \hat{Y}_t = nilai prediksi dan Y_t = nilai aktual.

BAB III METODOLOGI

Bab ini menjelaskan tahapan pengerjaan tugas akhir dan bagaimana alur dari penelitian beserta penjelasan dari tiap tahapannya yang digunakan sebagai metodologi.

3.1 Diagram Metodologi

Berikut adalah diagram metodologi yang menjelaskan tahapan input, proses, serta output yang akan dihasilkan dari penelitian tugas akhir ini.



Gambar 3.1. Diagram Metodologi Penelitian

3.2 Studi Literatur

Studi literatur merupakan tahapan awal yang dilakukan pada penulisan tugas akhir ini yang bertujuan untuk memahami semua konsep, metode, dan algoritma yang digunakan di dalam penelitian. Pada tahap ini pula dilakukan penggalian kebutuhan

terkait studi kasus yang akan diambil sebagai bekal dalam pengerjaan selanjutnya. Paper ilmiah yang dijadikan referensi utama merupakan paper internasional dan merupakan pengembangan terkini. Semua paper yang dijadikan acuan dalam penelitian ini merupakan paper penelitian seputar Long Short-Term Memory (LSTM). Paper internasional utama yang dijadikan rujukan tentang peramalan harga saham dengan LSTM adalah “*A Comparative Study of LSTM and DNN for Stock Market Forecasting*” oleh Dev Shah, Wesley Campbell, Farhana H. Zulkernine; 2018. Paper tersebut membahas tentang studi perbandingan antara dua model Artificial Neural Network (ANN) yaitu Long Short-Term Memory (LSTM) Recurrent Neural Network (RNN) dan Deep Neural Network (DNN) dalam memperkirakan pergerakan harian dan mingguan indeks Indian BSE Sensex.

3.3 Pengumpulan Data

Dalam melakukan pengumpulan data, penulis mengambil data saham harian milik Chevron Corporation dari Yahoo Finance. Data yang diambil yaitu data dengan rentang waktu 5 tahun yaitu dari tahun 2014-2019. Data yang digunakan yaitu data *open*, *low*, *high*, dan *close* dari harga saham harian Chevron Corporation. Selain itu, penulis juga mengambil data harga saham perusahaan lain yang digunakan untuk menguji model LSTM pada penelitian ini yaitu data harga saham harian Starbucks Corporation, Apple Inc, dan Sidomulyo dengan periode waktu 5 tahun dari tahun 2014-2019 yang diperoleh dari Yahoo Finance.

3.4 Data Preprocessing

Pada tahap data *preprocessing* ini melibatkan diskritisasi data yang merupakan bagian dari reduksi data tetapi dengan kepentingan khusus (terutama untuk data numerik), transformasi data (normalisasi), pembersihan dan integrasi data. Setelah dataset diubah menjadi dataset yang bersih, dataset tersebut dibagi menjadi data *training* dan data *testing* untuk

dievaluasi. Rasio pembagian untuk data *training* dan data *testing* pada penelitian ini ialah 70:30.

3.5 Pembuatan Model LSTM

Pada tahap ini akan dibuat model Long Short-Term Memory (LSTM) menggunakan *Keras Package* dan TensorFlow sebagai *back-end* dengan bahasa pemrograman Python. Dalam pembuatan model LSTM tersebut perlu dilakukan inisialisasi parameter, dimana pada penelitian ini parameter yang digunakan ditentukan secara acak. Selain itu, pada pembuatan model LSTM ini perlu dilakukan *training long short-term memory* terlebih dahulu seperti yang sudah dijelaskan pada sub bab 2.2.5.

3.6 Peramalan dengan Model LSTM

Peramalan harga saham harian Chevron Corporation ini menggunakan Metode Long Short-Term Memory (*LSTM*). Untuk melakukan peramalan tersebut, data harus dipecah terlebih dahulu menjadi *input* dan *output* dataset berdasarkan *timewindow* yang telah ditentukan. Ukuran *timewindow* yang dipilih untuk melakukan peramalan harga saham dengan LSTM ini ialah 20 dimana nantinya titik data pada waktu t diprediksi menggunakan 20 titik data sebelumnya ($t-1, t-2, \dots, t-19, t-20$). Hasil peramalan dengan menggunakan 20 *timewindow* akan dibandingkan dengan hasil peramalan model LSTM dengan 12 *timewindow* guna menguji ukuran *timewindow* pada peramalan harga saham harian Chevron Corporation. Ukuran *timewindow* dipilih berdasarkan kesesuaian masing-masing model dengan data harga saham [4].

3.7 Analisis dan Pengujian Performa Model LSTM

Pada setiap penerapan model Long Short-Term Memory (LSTM) dalam melakukan peramalan pasti akan menghasilkan sebuah nilai MAPE dan RMSE yang dapat meminimalkan eror dan perbedaan antara target dan nilai *output* yang diperoleh.

Semakin kecil nilai MAPE dan RMSE yang diperoleh maka akan semakin kecil tingkat kesalahan atau erornya. Analisis dan pengujian performa model LSTM ini bertujuan untuk menemukan hasil peramalan dengan akurasi terbaik yaitu dimana nilai MAPE di bawah 20% sudah dapat dikatakan baik, dan nilai MAPE kurang dari 10% dinyatakan sangat baik. Sedangkan untuk nilai RMSE dapat dikatakan ideal jika nilai RMSE yang dihasilkan bernilai nol atau mendekati nol.

3.8 Penyusunan Buku TA

Penyusunan buku TA (Tugas Akhir) merupakan tahapan terakhir dalam penelitian ini. Penyusunan buku TA ini dapat dikerjakan sembari melakukan tahapan yang lain. Tujuan dari penyusunan buku TA ini adalah sebagai dokumentasi dari penelitian sehingga dapat dijadikan referensi atau rujukan untuk penelitian selanjutnya. Pada Buku Tugas Akhir tersebut mencakup:

- a. Bab I Pendahuluan
Dalam bab ini dijelaskan mengenai latar belakang penelitian, perumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian, dan relevansi terhadap penelitian yang dilakukan. Penjelasan pada bab ini diharapkan dapat memberikan gambaran umum mengenai permasalahan dan pemecahan masalah pada tugas akhir ini.
- b. Bab II Tinjauan Pustaka
Dalam bab ini dijelaskan tentang penelitian-penelitian terkait yang telah dilakukan sebelumnya dan dasar teori yang nantinya akan dijadikan sebagai acuan dalam pengerjaan tugas akhir ini.
- c. Bab III Metodologi
Dalam bab ini dijelaskan tentang tahapan pengerjaan tugas akhir dan bagaimana alur dari penelitian beserta penjelasan dari tiap tahapannya yang digunakan sebagai metodologi.
- d. Bab IV Perancangan
Dalam bab ini dijelaskan tentang rancangan penelitian tugas akhir untuk membuat model peramalan. Bab ini

berisikan proses pengumpulan data, gambaran data masukan dan keluaran, serta pengolahan data.

e. Bab V Implementasi

Dalam bab ini dijelaskan tentang proses implementasi atau pelaksanaan penelitian tugas akhir dan pembuatan model yang akan digunakan untuk peramalan.

f. Bab VI Hasil dan Pembahasan

Dalam bab ini dijelaskan tentang hasil dan pembahasan setelah melakukan implementasi. Hasil yang dijelaskan adalah hasil uji coba model, validasi model, dan hasil peramalan dengan model LSTM.

g. Bab VII Kesimpulan dan Saran

Dalam bab ini dijelaskan mengenai kesimpulan dari semua proses yang telah dilakukan dan saran yang dapat diberikan untuk pengembangan yang lebih baik.

Halaman ini sengaja dikosongkan

BAB IV PERANCANGAN

Pada bab ini menjelaskan rancangan penelitian tugas akhir untuk membuat model peramalan. Bab ini berisikan proses pengumpulan data, gambaran data masukan dan keluaran, serta pengolahan data, pembuatan model, dan proses peramalan yang dilakukan.

4.1 Pengumpulan Data dan Data *PreProcessing*

Pada tahap awal dari perancangan ini dimulai dengan proses pengumpulan dan pengolahan data sehingga data dapat digunakan untuk peramalan harga saham harian dengan Metode Long Short-Term Memory (LSTM).

4.1.1 Pengumpulan Data

Data yang digunakan dalam penelitian tugas akhir ini ialah data *open*, *low*, *high*, dan *close* dari harga saham harian Chevron Corporation. Data harga saham harian Chevron Corporation tersebut diperoleh dari website Yahoo Finance. Pada penelitian ini, data yang diambil yaitu data harga saham harian dengan rentang waktu 5 tahun yaitu dari 23 Mei 2014 - 23 Mei 2019. Data tersebut akan digunakan untuk meramalkan data *close* untuk harga saham harian Chevron Corporation. Selain itu, penulis juga mengambil data harga saham perusahaan lain yang digunakan untuk menguji model LSTM pada penelitian ini yaitu data harga saham harian Starbucks Corporation, Apple Inc, dan Sidomulyo dengan rentang waktu 5 tahun yaitu dari 23 Mei 2014 - 23 Mei 2019 yang diperoleh dari Yahoo Finance.

4.1.2 Uji Korelasi

Pada penelitian tugas akhir ini diperlukan uji korelasi guna mengetahui keterkaitan antar variabel *open*, *low*, *high*, dan *close*. Proses uji korelasi ini dilakukan dengan menggunakan *generating correlation heat maps* pada Seaborn. *Library Seaborn* yang digunakan merupakan *library* visualisasi data pada Python berdasarkan *matplotlib*. Seaborn menyediakan

antarmuka tingkat tinggi untuk menggambar grafik statistik yang menarik dan informatif.

4.1.3 Data Preprocessing

Pada tahap data *preprocessing* ini data harga saham harian yang akan digunakan akan dinormalisasi terlebih dahulu dengan *MinMax Normalization* yang merupakan metode paling sederhana untuk mengubah skala berbagai fitur dengan kisaran $[0,1]$ atau $[-1,1]$. Berikut merupakan rumus dari *MinMax Normalization*:

$$x' = \frac{x - \min_x}{\max_x - \min_x} \quad (4.1)$$

Dimana,

x = Data yang akan dinormalisasi

x' = Data setelah dinormalisasi

\min_x = Nilai minimum dari keseluruhan data

\max_x = Nilai maksimum dari keseluruhan data

Kemudian data harga saham harian yang sudah dinormalisasi tersebut diubah menjadi *supervised learning problem*. Perubahan *frame* tersebut memungkinkan untuk mengakses rangkaian algoritma pembelajaran mesin linier dan nonlinier standar. Perubahan tersebut menggunakan *sliding window method* dimana pada penelitian ini menggunakan 20 *timewindow*.

Setelah data diubah menjadi *supervised learning*, data tersebut dibagi menjadi data *training* dan data *testing*. Rasio pembagian untuk data *training* dan data *testing* pada penelitian ini ialah 70:30. Dimana data *training* pada penelitian ini berjumlah 881 dan data *testing* berjumlah 358.

4.2 Pembuatan Model LSTM

Pada tahap ini akan dibuat model *Long Short-Term Memory (LSTM)* menggunakan *Keras Package* dan *TensorFlow* sebagai

back-end dengan bahasa pemrograman Python. Pembuatan model LSTM untuk peramalan harga saham harian Chevron Corporation ini menggunakan arsitektur LSTM dengan satu dan dua *hidden layer*. Pada pembuatan model LSTM ini penulis akan mencoba untuk mengubah jumlah *neuron hidden layer*, jenis *optimizer*, dan jumlah *epochs* untuk mencari serta mendapatkan model yang terbaik.

Berikut detail model LSTM yang akan dibuat berdasarkan kombinasi jumlah *hidden layer*, jumlah *neuron hidden layer*, jenis *optimizer*, dan jumlah *epochs* yang akan digunakan untuk melakukan peramalan harga saham harian Chevron Corporation:

Tabel 4.1. Detail Kombinasi Model LSTM

Model	Jumlah Hidden Layer	Optimizer	Jumlah Neuron	Jumlah Epoch
1	1	Adam	50	25
2	1	Adam	75	25
3	1	Adam	100	25
4	1	Adam	125	25
5	1	Adam	50	50
6	1	Adam	75	50
7	1	Adam	100	50
8	1	Adam	125	50
9	1	Adam	50	75
10	1	Adam	75	75
11	1	Adam	100	75
12	1	Adam	125	75
13	1	Adam	50	100
14	1	Adam	75	100
15	1	Adam	100	100
16	1	Adam	125	100
17	1	Adamax	50	25
18	1	Adamax	75	25
19	1	Adamax	100	25
20	1	Adamax	125	25

21	1	Adamax	50	50
22	1	Adamax	75	50
23	1	Adamax	100	50
24	1	Adamax	125	50
25	1	Adamax	50	75
26	1	Adamax	75	75
27	1	Adamax	100	75
28	1	Adamax	125	75
29	1	Adamax	50	100
30	1	Adamax	75	100
31	1	Adamax	100	100
32	1	Adamax	125	100
33	1	RMSprop	50	25
34	1	RMSprop	75	25
35	1	RMSprop	100	25
36	1	RMSprop	125	25
37	1	RMSprop	50	50
38	1	RMSprop	75	50
39	1	RMSprop	100	50
40	1	RMSprop	125	50
41	1	RMSprop	50	75
42	1	RMSprop	75	75
43	1	RMSprop	100	75
44	1	RMSprop	125	75
45	1	RMSprop	50	100
46	1	RMSprop	75	100
47	1	RMSprop	100	100
48	1	RMSprop	125	100
49	2	Adam	50	25
50	2	Adam	75	25
51	2	Adam	100	25
52	2	Adam	125	25
53	2	Adam	50	50
54	2	Adam	75	50
55	2	Adam	100	50
56	2	Adam	125	50
57	2	Adam	50	75
58	2	Adam	75	75

59	2	Adam	100	75
60	2	Adam	125	75
61	2	Adam	50	100
62	2	Adam	75	100
63	2	Adam	100	100
64	2	Adam	125	100
65	2	Adamax	50	25
66	2	Adamax	75	25
67	2	Adamax	100	25
68	2	Adamax	125	25
69	2	Adamax	50	50
70	2	Adamax	75	50
71	2	Adamax	100	50
72	2	Adamax	125	50
73	2	Adamax	50	75
74	2	Adamax	75	75
75	2	Adamax	100	75
76	2	Adamax	125	75
77	2	Adamax	50	100
78	2	Adamax	75	100
79	2	Adamax	100	100
80	2	Adamax	125	100
81	2	RMSprop	50	25
82	2	RMSprop	75	25
83	2	RMSprop	100	25
84	2	RMSprop	125	25
85	2	RMSprop	50	50
86	2	RMSprop	75	50
87	2	RMSprop	100	50
88	2	RMSprop	125	50
89	2	RMSprop	50	75
90	2	RMSprop	75	75
91	2	RMSprop	100	75
92	2	RMSprop	125	75
93	2	RMSprop	50	100
94	2	RMSprop	75	100
95	2	RMSprop	100	100
96	2	RMSprop	125	100

4.3 Peramalan dengan Model LSTM

Peramalan harga saham harian dengan Model LSTM ini akan dilakukan dengan menggunakan beberapa model LSTM yang telah dibuat berdasarkan kombinasi jumlah *hidden layer*, jumlah *neuron hidden layer*, jenis *optimizer*, dan jumlah *epochs* yang telah ditentukan untuk masing-masing model seperti yang telah ditampilkan pada Tabel 4.1. Setiap model yang ada akan dijalankan sebanyak 10 kali percobaan. Nilai MAPE dan RMSE tiap model tersebut merupakan hasil rata-rata dari 10 kali percobaan. Peramalan dengan beberapa model tersebut ditujukan untuk mencari model yang terbaik dengan nilai rata-rata MAPE *testing* dan nilai rata-rata RMSE *testing* yang terkecil.

Peramalan harga saham harian Chevron Corporation ini menggunakan data *training* dan data *testing* yang didapatkan dari proses data *preprocessing* yang telah dijelaskan pada sub bab 4.1.3. Kemudian untuk melakukan peramalan di masa mendatang akan dilakukan peramalan satu bulan kedepan dimana data aktualnya akan menggunakan data hasil peramalan satu bulan sebelumnya. Peramalan untuk satu bulan kedepan akan dilakukan dengan menggunakan model LSTM terbaik yang telah diperoleh.

4.4 Analisis dan Pengujian Performa Model LSTM

Analisa hasil peramalan harga saham harian terhadap beberapa model yang telah dibuat seperti yang telah ditampilkan pada Tabel 4.1 akan dilakukan dengan menghitung nilai rata-rata MAPE dan nilai rata-rata RMSE untuk masing-masing model yang diuji. Analisa tersebut dilakukan guna mencari model LSTM yang terbaik berdasarkan hasil peramalan yang memiliki nilai rata-rata MAPE *testing* dibawah 10% dan nilai rata-rata RMSE *testing* mendekati 0. Kemudian pengujian model akan dilakukan dengan melakukan peramalan terhadap data harga saham lain yaitu data harga saham harian Starbucks Corporation, Apple Inc, dan Sidomulyo dengan menggunakan model LSTM terbaik yang telah diperoleh.

Pengujian performa model LSTM terbaik tersebut juga akan dilakukan dengan membandingkan nilai MAPE *testing* dan RMSE *testing* dari hasil peramalan harga saham dengan menggunakan model LSTM dengan 20 *timewindow* dan model LSTM dengan 12 *timewindow*. Model LSTM terbaik tersebut juga akan dibandingkan dengan model Simple RNN guna menguji performa dari model LSTM terbaik yang telah diperoleh.

Halaman ini sengaja dikosongkan

BAB V IMPLEMENTASI

Pada bab ini akan menjelaskan tentang proses implementasi dari perancangan pembuatan model yang akan digunakan untuk peramalan harga saham harian pada penelitian tugas akhir ini.

5.1 Pengumpulan Data

Data yang digunakan dalam penelitian tugas akhir ini ialah data *open*, *low*, *high*, dan *close* dari harga saham harian Chevron Corporation. Data harga saham harian Chevron Corporation tersebut diperoleh dari website Yahoo Finance. Pada penelitian ini, data yang diambil yaitu data harga saham harian dengan rentang waktu 5 tahun yaitu dari 23 Mei 2014 - 23 Mei 2019. Data yang diperoleh ialah sebanyak 1259 data *open*, *low*, *high*, dan *close* dari harga saham harian Chevron Corporation.

Plotting terhadap data yang sudah diperoleh dapat dilakukan dengan menggunakan `matplotlib.pyplot` pada Python. Contoh implementasi kode pemrograman yang dapat digunakan untuk melakukan *plotting data* tersebut dapat dilihat pada Kode 5.1.

```
# specify columns to plot
groups = [0, 1, 2, 3]
i = 1

# plot each column
plt.figure()
for group in groups:
    plt.subplot(len(groups), 1, i)
    plt.plot(values[:, group])
    plt.title(dataset.columns[group], y=0.5, loc='right')
    i += 1
plt.show()
```

Kode 5.1. Implementasi *plotting data* dengan `matplotlib.pyplot`

Pada Kode 5.1, dataset akan diplot sekaligus menjadi satu kelompok yang terdiri dari *plotting data open*, *low*, *high* dan *close* dari harga saham harian Chevron Corporation.

5.2 Uji Korelasi

Uji korelasi dilakukan untuk mengetahui pengaruh atau hubungan antar variabel *open*, *low*, *high*, dan *close* terhadap data *close* dari harga saham harian Chevron Corporation yang akan diramalkan. Uji korelasi pada penelitian ini dilakukan dengan menggunakan *seaborn heatmap*. Python *seaborn* dapat menampilkan *heatmap* dengan menggunakan fungsi khusus yaitu `sns.heatmap(dataset.corr())`. “Dataset” tersebut merupakan data yang akan diuji, jadi data yang akan digunakan harus diinisiasikan terlebih dahulu.

5.3 Data Preprocessing

5.3.1 Normalisasi Data

Pada tahap implementasi data *preprocessing* ini data harga saham harian yang akan digunakan akan dinormalisasi terlebih dahulu dengan *MinMax Normalization* yang merupakan metode paling sederhana untuk mengubah skala berbagai fitur dengan kisaran $[0,1]$ atau $[-1,1]$. *MinMax Normalization* dapat dilakukan dengan menggunakan *MinMaxScaler* dari `sklearn.preprocessing`.

Pada penelitian ini, data yang akan dinormalisasi dibagi menjadi dua yang terdiri dari data dengan variabel *open*, *low*, *high* dan data dengan variabel target yang akan diramalkan yaitu data *close*. Oleh karena itu dalam melakukan normalisasi, data hasil normalisasi harus diinisiasi dengan berbeda seperti yang dapat dilihat pada Kode 5.2.

```
# normalize features
scaler = MinMaxScaler(feature_range=(0, 1))
close_scaler = MinMaxScaler(feature_range=(0, 1))
scaled = scaler.fit_transform(values)
scaled_close = close_scaler.fit_transform(close_values)
complete_scaled = np.concatenate((scaled, scaled_close), axis=1)
```

Kode 5.2. Implementasi normalisasi data dengan MinMax Normalization

Pada Kode 5.2 dapat dilihat bahwa data hasil normalisasi untuk variabel *open*, *low*, *high* diinisiasi dengan nama *scaled* dan

untuk data hasil normalisasi untuk variabel target (*close*) diinisiasi dengan nama *scaled_close*. Kemudian kedua data yang sudah dinormalisasi tersebut disatukan kembali dengan nama *complete_scaled*. Jadi data hasil normalisasi *open*, *low*, *high* akan disatukan kembali dengan data hasil normalisasi *close*.

5.3.2 Perubahan Data menjadi *Supervised Learning*

Data harga saham harian yang sudah dinormalisasi tersebut diubah menjadi *supervised learning problem*. Perubahan *frame* tersebut memungkinkan untuk mengakses rangkaian algoritma pembelajaran mesin linier dan nonlinier standar. Perubahan tersebut dilakukan dengan menggunakan *sliding window method* dimana pada penelitian ini menggunakan 20 *timewindow*. Contoh implementasi kode pemrograman yang dapat digunakan untuk mengubah *time series* menjadi *Supervised Learning* dapat dilihat pada Kode 5.3.

```
def series_to_supervised(data, n_in=1, n_out=1, dropnan=True):
    n_vars = 1 if type(data) is list else data.shape[1]
    df = DataFrame(data)
    cols, names = list(), list()

    # input sequence (t-n, ... t-1)
    for i in range(n_in, 0, -1):
        cols.append(df.shift(i))
        names += [('var%d(t-%d)' % (j+1, i)) for j in range(n_vars)]

    # forecast sequence (t, t+1, ... t+n)
    for i in range(0, n_out):
        cols.append(df.shift(-i))
        if i == 0:
            names += [('var%d(t)' % (j+1)) for j in range(n_vars)]
        else:
            names += [('var%d(t+%d)' % (j+1, i)) for j in range(n_vars)]

    # put it all together
    agg = concat(cols, axis=1)
    agg.columns = names

    # drop rows with NaN values
    if dropnan:
        agg.dropna(inplace=True)
    return agg
```

Kode 5.3. Pembuatan fungsi perubahan data ke *supervised learning*

Data yang sudah diubah menjadi *supervised learning* akan diinisiasi dengan nama “*reframed*”. Data yang digunakan

dalam proses ini ialah data “*complete_scaled*” yang sudah dinormalisasi sebelumnya. Kemudian masukkan jumlah *timewindow* yang digunakan seperti yang telah dijabarkan pada Kode 5.4. Setelah kode tersebut dijalankan maka jumlah baris dari data tersebut berkurang sesuai dengan jumlah *timewindow* yang digunakan yaitu menjadi 1239 dengan total 84 kolom.

```
# frame as supervised learning
reframed = series_to_supervised(complete_scaled, 20, 1)
```

```
reframed.shape
```

```
(1239, 84)
```

Kode 5.4. Pengubahan data menjadi Supervised Learning

Setelah data berhasil diubah menjadi *supervised learning* dengan 20 *timewindow*, kolom yang tidak ingin diramalkan harus dihapus terlebih dahulu. Disini kolom yang dihapus ialah kolom *open*, *low*, dan *high* yang berada pada kolom 80,81, dan 82. Ketiga kolom tersebut dihapus karena pada penelitian ini yang merupakan variabel target adalah *close*. Contoh implementasi kode pemrograman untuk menghapus kolom yang tidak ingin diramalkan tersebut dapat dilihat pada Kode 5.5.

```
reframed.drop(reframed.columns[[80,81,82]], axis=1, inplace=True)
```

```
reframed.shape
```

```
(1239, 81)
```

Kode 5.5. Menghapus kolom yang tidak ingin diramalkan

Untuk pembuatan model LSTM dengan 12 *timewindow* dapat dilihat pada Kode 5.6. Setelah kode tersebut dijalankan maka jumlah baris dari data tersebut berkurang sesuai dengan jumlah *timewindow* yang digunakan yaitu menjadi 1247 dengan total 52 kolom.


```
# frame as supervised learning
reframed = series_to_supervised(complete_scaled, 12, 1)
```

```
reframed.shape
```

```
(1247, 52)
```

Kode 5.6. *Supervised Learning 12 Timewindow*

Setelah data berhasil diubah menjadi *supervised learning* dengan 12 *timewindow*, kolom yang tidak ingin diramalkan harus dihapus terlebih dahulu. Disini kolom yang dihapus ialah kolom *open*, *low*, dan *high* yang dimana berada pada kolom 48,49, dan 50. Ketiga kolom tersebut dihapus karena pada penelitian ini yang merupakan variabel target adalah *close*. Contoh implementasi kode pemrograman untuk menghapus kolom yang tidak ingin diramalkan tersebut dapat dilihat pada Kode 5.7.

```
reframed.drop(reframed.columns[[48,49,50]], axis=1, inplace=True)
```

```
reframed.shape
```

```
(1247, 49)
```

Kode 5.7. *Menghapus Kolom Open, Low, dan High*

5.3.3 Pembagian Data *Training* dan Data *Testing*

Setelah data diubah menjadi *supervised learning*, data tersebut dibagi menjadi data *training* dan data *testing*. Rasio pembagian untuk data *training* dan data *testing* pada penelitian ini ialah 70:30. Dimana data *training* pada penelitian ini berjumlah 881 dan data *testing* berjumlah 358. Data yang sudah dibagi menjadi *training* dan *testing* kemudian dipecah menjadi *input* dan *output* untuk model LSTM yang akan dibuat nantinya. Setelah data dipecah menjadi *input* dan *output*, data tersebut diubah menjadi bentuk 3 dimensi. Pada proses ini, jumlah *timesteps* yang digunakan hanya satu. Contoh implementasi kode pemrograman untuk membagi dataset menjadi *training* dan *testing*, *input* dan *output* serta pengubahan data menjadi bentuk 3 dimensi dapat dilihat pada Kode 5.8.

```

# split into train and test sets
values = reframed.values
train = values[:881, :]
test = values[881:, :]

# split into input and outputs
train_x, train_y = train[:, :-1], train[:, -1]
test_x, test_y = test[:, :-1], test[:, -1]

# reshape input to be 3D
train_x = train_x.reshape((train_x.shape[0], 1, train_x.shape[1]))
test_x = test_x.reshape((test_x.shape[0], 1, test_x.shape[1]))
print(train_x.shape, train_y.shape, test_x.shape, test_y.shape)
(881, 1, 80) (881,) (358, 1, 80) (358,)

```

Kode 5.8. Pembagian data training dan testing

5.4 Pembuatan Model LSTM

Pembuatan model LSTM untuk peramalan harga saham harian Chevron Corporation ini menggunakan arsitektur LSTM dengan satu dan dua *hidden layer*. Pada pembuatan model LSTM ini penulis akan mencoba untuk mengubah jumlah *neuron hidden layer*, jenis *optimizer*, dan jumlah *epochs* untuk mencari serta mendapatkan model yang terbaik. Skenario model yang akan dibuat pada penelitian ini dapat dilihat pada Tabel 4.1. Untuk penggantian jumlah *neuron hidden layer* dapat dilakukan pada *hidden layer*. Untuk jenis *optimizer* yang akan digunakan dapat diganti pada fungsi *optimizer*. Contoh implementasi kode pemrograman untuk pembuatan model LSTM ini dapat dilihat pada Kode 5.9 dan 5.10. Dimana Kode 5.9 merupakan model dengan 1 *hidden layer* dan Kode 5.10 untuk model dengan dua *hidden layer*.

```

model = Sequential()
model.add(LSTM(125, return_sequences = False,
              input_shape=(train_x.shape[1], train_x.shape[2])))
model.add(Dense(1))
model.compile(loss='mean_squared_error', optimizer='adam')

```

Kode 5.9. Model LSTM dengan 1 hidden layer

```

model = Sequential()
model.add(LSTM(125, return_sequences = True,
              input_shape=(train_x.shape[1], train_x.shape[2])))
model.add(LSTM(125, return_sequences = False))
model.add(Dense(1))
model.compile(loss='mean_squared_error', optimizer='adam')

```

Kode 5.10. Model LSTM dengan 2 hidden layer

Setelah model berhasil dibuat, proses selanjutnya adalah *fit model* dengan data *input* yang telah dijelaskan pada sub bab 5.3.3. Pada saat *fit model*, jumlah iterasi atau *epochs* diganti sesuai dengan skenario model yang telah dibuat pada Tabel 4.1 guna mendapatkan model LSTM yang terbaik. Contoh implementasi kode pemrograman untuk *fit model* ini dapat dilihat pada Kode 5.11.

```

# fit model
history = model.fit(train_x, train_y,
                   epochs=100,
                   batch_size=72,
                   validation_split=0.2,
                   validation_data=(test_x, test_y),
                   verbose=0, shuffle=False)

```

Kode 5.11. Fit Model LSTM

5.5 Pembuatan Model Simple RNN

Pembuatan model Simple RNN untuk peramalan harga saham harian Chevron Corporation ini bertujuan sebagai pembanding guna menguji performa model LSTM yang ada. Contoh implementasi kode pemrograman yang dapat digunakan untuk membuat model Simple RNN dapat dilihat pada Kode 5.12.

```

modelRNN = Sequential()
modelRNN.add(SimpleRNN(units=125, input_shape=(train_x.shape[1], train_x.shape[2])))
modelRNN.add(Dense(1))
modelRNN.compile(loss='mean_squared_error', optimizer='adam')
modelRNN.summary()

```

Kode 5.12. Model Simple RNN

Pada saat *fit model* Simple RNN, jumlah iterasi atau *epochs* diganti sesuai dengan skenario model terbaik yang dihasilkan oleh model LSTM. Contoh implementasi kode pemrograman untuk *fit model* Simple RNN ini dapat dilihat pada Kode 5.13.

```
# fit model RNN
history = modelRNN.fit(train_x, train_y,
                       epochs=100,
                       batch_size=72,
                       validation_split=0.2,
                       validation_data=(test_x, test_y),
                       verbose=0, shuffle=False)
```

Kode 5.13. Fit Model Simple RNN

5.6 Peramalan dengan Model LSTM

Peramalan harga saham harian (*close*) dengan model LSTM ini akan dilakukan dengan menggunakan beberapa model LSTM yang telah dibuat berdasarkan kombinasi jumlah *hidden layer*, jumlah *neuron hidden layer*, jenis *optimizer*, dan jumlah *epochs* yang telah ditentukan untuk masing-masing model seperti yang telah ditampilkan pada Tabel 4.1. Setiap model yang ada akan dijalankan sebanyak 10 kali percobaan. Nilai MAPE dan RMSE tiap model tersebut merupakan hasil rata-rata dari 10 kali percobaan. Peramalan dengan beberapa model tersebut ditujukan untuk mencari model yang terbaik dengan nilai rata-rata MAPE *testing* dan nilai rata-rata RMSE *testing* yang terkecil.

Peramalan harga saham harian Chevron Corporation ini menggunakan data *training* dan data *testing* yang didapatkan dari data *preprocessing* yang telah dijelaskan pada sub bab 4.1.3. Pada proses peramalan ini juga menggunakan data *input* dan *output* yang telah dijelaskan pada sub bab 5.3.3. Contoh implementasi kode pemrograman untuk peramalan dengan data *training* dapat dilihat pada Kode 5.14 sedangkan implementasi kode pemrograman untuk peramalan dengan data *testing* dapat dilihat pada Kode 5.15.

```

predictrain = model.predict(train_x)
train_x_final = train_x.reshape((train_x.shape[0],
                                train_x.shape[2]))
inv_predictrain = close_scaler.inverse_transform(predictrain)

```

Kode 5.14. Peramalan dengan data training

```

predict = model.predict(test_x)
test_x_final = test_x.reshape((test_x.shape[0],
                               test_x.shape[2]))
inv_predict = close_scaler.inverse_transform(predict)

```

Kode 5.15. Peramalan dengan data testing

Setelah data berhasil diramalkan, kembalikan bentuk data menjadi seperti semula dengan cara membatalkan *scaling* yang sudah dilakukan sebelumnya agar data kembali seperti semula dimana belum terskala menjadi kisaran $[0,1]$ atau $[-1,1]$ seperti pada sub bab 5.3.1. Pembatalin *scaling* ini berlaku untuk data aktual dan data hasil peramalan.

Kemudian untuk melakukan peramalan di masa mendatang akan dilakukan peramalan satu bulan kedepan dimana data aktualnya akan menggunakan data hasil peramalan satu bulan sebelumnya. Peramalan untuk satu bulan kedepan akan dilakukan dengan menggunakan model LSTM terbaik yang telah diperoleh. Untuk melakukan peramalan satu bulan kedepan, diperlukan untuk meramal ketiga variabel lainnya terlebih dahulu yaitu *open*, *low*, dan *high*. Kemudian hasil peramalan tersebut dijadikan sebagai data aktual *open*, *low*, dan *high*.

5.7 Analisis dan Pengujian Performa Model LSTM

Analisa hasil peramalan harga saham harian terhadap beberapa model yang telah dibuat seperti yang telah ditampilkan pada Tabel 4.1 akan dilakukan dengan menghitung nilai rata-rata MAPE dan nilai rata-rata RMSE untuk masing-masing model yang diuji. Analisa tersebut dilakukan guna mencari model LSTM yang terbaik berdasarkan hasil peramalan yang memiliki

nilai rata-rata MAPE *testing* dibawah 10% dan nilai rata-rata RMSE *testing* mendekati 0.

Contoh implementasi kode pemrograman untuk menghitung MAPE dan RMSE dari hasil peramalan dapat dilihat pada Kode 5.16.

```
# calculate MAPE
def mean_absolute_percentage_error(y_true, y_pred):
    y_true, y_pred = np.array(y_true), np.array(y_pred)
    return np.mean(np.abs((y_true - y_pred) / y_true)) * 100
print("MAPE Training: %.3f" % mean_absolute_percentage_error(inv_ytrain, inv_predicttrain))
print("MAPE Testing: %.3f" % mean_absolute_percentage_error(inv_y, inv_predict))

# calculate RMSE
rmsetesting = sqrt(mean_squared_error(inv_y, inv_predict))
print("Test RMSE Training: %.3f" % rmsetraining)
print("Test RMSE Testing: %.3f" % rmsetesting)
```

Kode 5.16. Penghitungan MAPE dan RMSE

Contoh implementasi kode pemrograman untuk menghitung SMAPE dari hasil peramalan dapat dilihat pada Kode 5.17.

```
def smape(actual, predict):
    return 100/len(actual) * np.sum(2 * np.abs(predict - actual) / (np.abs(actual) + np.abs(predict)))

print("SMAPE Saham Sidomulyo: %.3f" % smape(inv_ylainsido, inv_predictlainsido))
```

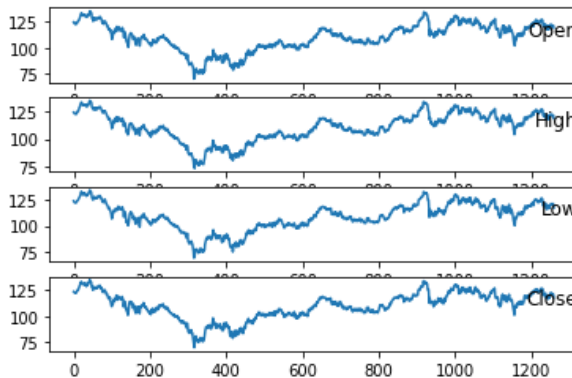
Kode 5.17. Penghitungan SMAPE

BAB VI HASIL DAN PEMBAHASAN

Pada bab ini akan dijelaskan tentang hasil dan pembahasan dari proses implementasi yang telah dilakukan sebelumnya, antara lain yaitu hasil uji coba model, validasi model, dan hasil peramalan yang telah dilakukan dalam penelitian tugas akhir ini.

6.1 Hasil Pengumpulan Data

Data yang digunakan dalam penelitian tugas akhir ini ialah data *open*, *low*, *high*, dan *close* dari harga saham harian Chevron Corporation. Data harga saham harian Chevron Corporation tersebut diperoleh dari website Yahoo Finance. Pada penelitian ini, data yang diambil yaitu data harga saham harian dengan rentang waktu 5 tahun yaitu dari 23 Mei 2014 - 23 Mei 2019. Data yang diperoleh ialah sebanyak 1259 data *open*, *low*, *high*, dan *close* dari harga saham harian Chevron Corporation. *Plotting* dari data harga saham harian dengan rentang waktu 5 tahun yaitu dari 23 Mei 2014 - 23 Mei 2019 dapat dilihat pada Gambar 6.1.




Gambar 6.1. Plot Data Harga Saham Harian

6.2 Hasil Uji Korelasi

Uji korelasi dilakukan untuk mengetahui pengaruh atau hubungan antar variabel *open*, *low*, *high*, dan *close* terhadap data *close* dari harga saham harian Chevron Corporation yang akan diramalkan. Uji korelasi pada penelitian ini dilakukan dengan menggunakan *seaborn heatmap*. Dengan menggunakan *heatmap*, data 2D (dua dimensi) dapat direpresentasikan menjadi grafis. Setiap nilai data direpresentasikan dalam matriks dan memiliki warna khusus. Warna matriks tergantung pada nilai. Biasanya, data yang bernilai rendah akan direpresentasikan dalam format warna dengan intensitas rendah dan data yang bernilai tinggi akan direpresentasikan dalam format warna dengan intensitas tinggi.

Hasil uji korelasi antar variabel tersebut dapat dilihat pada Gambar 6.2 dimana korelasi antar variabel *Open-Close* sebesar 0.9960, *Low-Close* sebesar 0.9976, *High-Close* sebesar 0.9984, dan *Close-Close* sebesar 1.0000. Berdasarkan hasil uji korelasi tersebut dapat disimpulkan bahwa variabel *open*, *low*, *high*, dan *close* memiliki hubungan atau sangat berkorelasi dengan data *close*. Sehingga semua variabel tersebut dapat digunakan untuk meramalkan harga *close* untuk harga saham harian Chevron Corporation.



Gambar 6.2. Hasil Uji Korelasi

6.3 Hasil Data *Preprocessing*

Pada tahap data *preprocessing* ini data harga saham harian yang akan digunakan akan dinormalisasi terlebih dahulu dengan *MinMax Normalization* yang merupakan metode paling sederhana untuk mengubah skala berbagai fitur dengan kisaran $[0,1]$ atau $[-1,1]$. Data yang sudah dinormalisasi dapat dilihat pada Gambar 6.3.

```
[ [0.83632666 0.82677414 0.83840275 0.82292147]
  [0.83101671 0.82080635 0.82935576 0.81474613]
  [0.8175855 0.80983861 0.82576813 0.80981016]
  ...
  [0.7883804 0.7877419 0.80049914 0.7916087 ]
  [0.78635015 0.77967738 0.79176406 0.77973154]
  [0.75370913 0.73822579 0.73748244 0.73808421]]
```

Gambar 6.3. Data yang sudah dinormalisasi

Kemudian data harga saham harian yang sudah dinormalisasi tersebut diubah menjadi *supervised learning problem*. Perubahan *frame* tersebut memungkinkan untuk mengakses rangkaian algoritma pembelajaran mesin linier dan nonlinier standar. *Supervised learning* terdiri dari pola *input* (x) dan pola *output* (y), sehingga suatu algoritma dapat belajar bagaimana memprediksi pola *output* dari pola *input* yang ada. Perubahan tersebut menggunakan *sliding window method* dimana pada penelitian ini menggunakan 20 *timewindow*. Setelah data diubah menjadi *supervised learning*, kolom yang tidak ingin diramalkan harus dihapus. Pada penelitian ini, kolom yang tidak ingin diramalkan ialah kolom 80, 81, dan 82 yang dimana berisi variabel *open*, *low*, dan *high* dari harga saham harian Chevron Corporation.

Setelah itu, data tersebut dibagi menjadi data *training* dan data *testing*. Rasio pembagian untuk data *training* dan data *testing* pada penelitian ini ialah 70:30. Dimana data *training* pada penelitian ini berjumlah 881 dan data *testing* berjumlah 358.

6.4 Hasil Analisis dan Pengujian Performa Model

Analisa hasil peramalan harga saham harian terhadap beberapa model yang telah dibuat seperti yang telah ditampilkan pada Tabel 4.1 akan dilakukan dengan menghitung dan membandingkan nilai MAPE dan RMSE untuk masing-masing model yang diuji. Analisa tersebut dilakukan guna mencari model yang terbaik dengan hasil peramalan yang memiliki nilai MAPE dibawah 10% dan nilai RMSE mendekati 0. Model LSTM terbaik ialah model yang menghasilkan nilai MAPE *testing* dan RMSE *testing* terkecil.

Analisa hasil peramalan dengan 96 skenario model berdasarkan kombinasi jumlah *hidden layer*, jumlah *neuron hidden layer*, jenis *optimizer*, dan jumlah *epochs* dapat dilihat pada Tabel 6.1.

Tabel 6.1. Analisa Hasil Peramalan dengan Model LSTM

Jumlah Hidden Layer	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training (%)	MAPE Testing (%)
1	Adam	50	25	2.525	3.084	1.893	2.000
1	Adam	75	25	2.575	3.119	1.926	2.024
1	Adam	100	25	2.595	3.160	1.950	2.049
1	Adam	125	25	2.593	3.157	1.948	2.104
1	Adam	50	50	2.339	2.600	1.792	1.628
1	Adam	75	50	2.518	2.623	1.975	1.648
1	Adam	100	50	2.467	2.635	1.922	1.655
1	Adam	125	50	2.423	2.634	1.878	1.652
1	Adam	50	75	2.366	2.549	1.857	1.627
1	Adam	75	75	2.480	2.497	1.974	1.572
1	Adam	100	75	2.577	2.425	2.071	1.590
1	Adam	125	75	2.593	2.538	2.086	1.597
1	Adam	50	100	2.333	2.430	1.848	1.544
1	Adam	75	100	2.403	2.412	1.921	1.519
1	Adam	100	100	2.503	2.438	2.021	1.536
1	Adam	125	100	2.371	2.397	1.883	1.501
1	Adamax	50	25	3.267	4.039	2.491	2.688
1	Adamax	75	25	3.206	3.983	2.442	2.650
1	Adamax	100	25	3.252	4.027	2.473	2.681
1	Adamax	125	25	3.285	4.063	2.504	2.702
1	Adamax	50	50	2.900	3.559	2.193	2.352
1	Adamax	75	50	2.851	3.459	2.150	2.277


1	Adamax	100	50	2.986	3.665	2.257	2.417
1	Adamax	125	50	2.843	3.490	2.142	2.299
1	Adamax	50	75	2.638	3.155	1.973	2.063
1	Adamax	75	75	2.685	3.169	2.010	2.132
1	Adamax	100	75	2.572	3.105	1.924	2.028
1	Adamax	125	75	2.497	2.981	1.858	1.934
1	Adamax	50	100	2.436	2.902	1.808	1.871
1	Adamax	75	100	2.331	2.782	1.720	1.781
1	Adamax	100	100	2.250	2.648	1.657	1.691
1	Adamax	125	100	2.242	2.704	1.656	1.717
1	RMSprop	50	25	3.995	2.974	3.345	1.934
1	RMSprop	75	25	4.199	3.003	3.553	1.964
1	RMSprop	100	25	4.393	3.122	3.731	2.050
1	RMSprop	125	25	4.505	3.169	3.832	2.082
1	RMSprop	50	50	3.348	2.648	2.791	1.701
1	RMSprop	75	50	3.484	2.680	2.917	1.733
1	RMSprop	100	50	3.559	2.710	2.985	1.755
1	RMSprop	125	50	3.610	2.733	3.028	1.773
1	RMSprop	50	75	2.701	2.618	2.187	1.713
1	RMSprop	75	75	2.714	2.638	2.198	1.732
1	RMSprop	100	75	2.819	2.721	2.294	1.796
1	RMSprop	125	75	2.798	2.740	2.277	1.814
1	RMSprop	50	100	2.718	2.829	2.221	1.893
1	RMSprop	75	100	2.597	2.798	2.101	1.871
1	RMSprop	100	100	2.630	2.817	2.128	1.882
1	RMSprop	125	100	2.672	2.877	2.171	1.937
2	Adam	50	25	2.772	3.377	2.104	2.184
2	Adam	75	25	2.748	3.297	2.092	2.106
2	Adam	100	25	2.941	3.184	2.293	2.010
2	Adam	125	25	2.976	3.245	2.329	2.048
2	Adam	50	50	2.350	2.621	1.794	1.641
2	Adam	75	50	2.392	2.658	1.829	1.665
2	Adam	100	50	2.550	2.702	1.997	1.699
2	Adam	125	50	2.443	2.663	1.891	1.676
2	Adam	50	75	2.260	2.454	1.737	1.542
2	Adam	75	75	2.408	2.558	1.877	1.609
2	Adam	100	75	2.618	2.634	2.089	1.663
2	Adam	125	75	2.541	2.686	2.009	1.723
2	Adam	50	100	2.429	2.656	1.904	1.740
2	Adam	75	100	2.366	2.585	1.844	1.664
2	Adam	100	100	2.389	2.607	1.868	1.676
2	Adam	125	100	2.338	2.545	1.817	1.607
2	Adamax	50	25	3.332	4.195	2.553	2.813

2	Adamax	75	25	3.282	4.125	2.505	2.752
2	Adamax	100	25	3.230	4.033	2.463	2.677
2	Adamax	125	25	3.163	3.950	2.408	2.614
2	Adamax	50	50	3.018	3.746	2.287	2.470
2	Adamax	75	50	2.943	3.643	2.226	2.394
2	Adamax	100	50	2.807	3.451	2.115	2.260
2	Adamax	125	50	2.759	3.382	2.078	2.210
2	Adamax	50	75	2.522	2.991	1.868	1.929
2	Adamax	75	75	2.419	2.862	1.794	1.826
2	Adamax	100	75	2.271	2.677	1.678	1.692
2	Adamax	125	75	2.204	2.589	1.628	1.621
2	Adamax	50	100	2.251	2.628	1.660	1.653
2	Adamax	75	100	2.146	2.511	1.584	1.578
2	Adamax	100	100	2.098	2.446	1.565	1.545
2	Adamax	125	100	2.150	2.461	1.617	1.555
2	RMSprop	50	25	4.007	3.172	3.327	2.065
2	RMSprop	75	25	4.100	3.178	3.412	2.077
2	RMSprop	100	25	4.252	3.231	3.556	2.119
2	RMSprop	125	25	4.431	3.339	3.719	2.204
2	RMSprop	50	50	3.461	2.866	2.889	1.793
2	RMSprop	75	50	3.263	2.738	2.683	1.785
2	RMSprop	100	50	3.480	2.846	2.880	1.872
2	RMSprop	125	50	3.624	2.916	3.016	1.925
2	RMSprop	50	75	2.643	2.666	2.115	1.756
2	RMSprop	75	75	2.645	2.938	2.114	1.986
2	RMSprop	100	75	2.744	3.011	2.215	2.037
2	RMSprop	125	75	2.771	3.123	2.272	2.127
2	RMSprop	50	100	2.313	2.841	1.916	2.028
2	RMSprop	75	100	2.437	3.319	1.914	2.312
2	RMSprop	100	100	2.514	3.366	1.988	2.348
2	RMSprop	125	100	2.556	3.435	2.027	2.397

Berdasarkan Tabel 6.1, model LSTM terbaik untuk meramalkan harga saham harian Chevron Corporation ialah model 16 dengan satu *hidden layer*, 125 *neuron hidden layer*, 100 *epochs*, dan jenis *optimizer* Adam dengan nilai rata-rata MAPE *testing* sebesar 1.501% dan RMSE *testing* sebesar 2.397. Nilai MAPE dan RMSE yang ditampilkan pada Tabel 6.1 merupakan nilai rata-rata dari sepuluh kali menjalankan model untuk masing-masing model yang ada. Untuk detail 10 percobaan dari masing-masing model dapat dilihat pada Lampiran A.

6.5 Hasil Peramalan Data *Training*

Hasil peramalan data *training* Chevron Corporation dengan menggunakan model LSTM terbaik dengan satu *hidden layer*, 125 *neuron hidden layer*, 100 *epochs*, dan jenis *optimizer* Adam dapat dilihat pada Gambar 6.4.




Gambar 6.4. Grafik Perbandingan Data Aktual dan Prediksi untuk Hasil Peramalan Data *Training*

Pada Gambar 6.4 dapat dilihat bahwa garis berwarna *orange* menunjukkan data aktual dari data *training* tersebut. Sedangkan garis berwarna biru muda menunjukkan hasil peramalan dari data *training* tersebut. Grafik diatas diperoleh dengan satu kali menjalankan model sehingga nilai MAPE dan RMSE yang diperoleh berbeda dengan nilai MAPE dan RMSE yang tertera pada Tabel 6.1. Nilai MAPE yang diperoleh dari peramalan data *training* tersebut ialah sebesar 1.478%. Sedangkan, nilai RMSE yang diperoleh dari peramalan data *training* tersebut ialah sebesar 1.956.

6.6 Hasil Peramalan Data *Testing*

Hasil peramalan data *testing* Chevron Corporation dengan menggunakan model LSTM terbaik dengan satu *hidden layer*, 125 *neuron hidden layer*, 100 *epochs*, dan jenis *optimizer* Adam dapat dilihat pada Gambar 6.5.



Gambar 6.5. Grafik Perbandingan Data Aktual dan Prediksi untuk Hasil Peramalan Data Testing

Pada Gambar 6.5 dapat dilihat bahwa garis berwarna *orange* menunjukkan data aktual dari data *testing* tersebut. Sedangkan garis berwarna biru muda menunjukkan hasil peramalan dari data *testing* tersebut. Grafik diatas diperoleh dengan satu kali menjalankan model sehingga nilai MAPE dan RMSE yang diperoleh berbeda dengan nilai MAPE dan RMSE yang tertera pada Tabel 6.1. Nilai MAPE yang diperoleh dari peramalan data *testing* tersebut ialah sebesar 1.414%. Sedangkan, nilai RMSE yang diperoleh dari peramalan data *testing* tersebut ialah sebesar 2.246.

6.7 Hasil Peramalan Data Chevron Corporation

Peramalan di masa mendatang akan dilakukan dengan melakukan peramalan satu bulan kedepan dimana data aktualnya akan menggunakan data hasil peramalan satu bulan sebelumnya. Untuk melakukan peramalan data *close* satu bulan kedepan, diperlukan untuk meramal ketiga variabel lainnya terlebih dahulu yaitu *open*, *low*, dan *high*. Kemudian hasil peramalan tersebut dijadikan sebagai data aktual *open*, *low*, dan *high*.

6.7.1 Hasil Peramalan Data *Open*


Hasil peramalan data *testing* Chevron Corporation untuk data *open* dengan menggunakan model LSTM terbaik dengan satu *hidden layer*, 125 *neuron hidden layer*, 100 *epochs*, dan jenis *optimizer* Adam dapat dilihat pada Gambar 6.6. Nilai MAPE yang diperoleh dari peramalan data *open* tersebut ialah sebesar 1.342%. Sedangkan, nilai RMSE yang diperoleh dari peramalan data *open* tersebut ialah sebesar 2.086.



Gambar 6.6. Grafik Hasil Peramalan Data *Open* Chevron Corporation

6.7.2 Hasil Peramalan Data *Low*

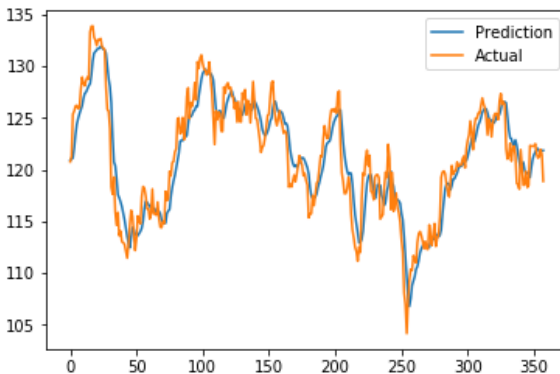
Hasil peramalan data *testing* Chevron Corporation untuk data *low* dengan menggunakan model LSTM terbaik dengan satu *hidden layer*, 125 *neuron hidden layer*, 100 *epochs*, dan jenis *optimizer* Adam dapat dilihat pada Gambar 6.7. Nilai MAPE yang diperoleh dari peramalan data *low* tersebut ialah sebesar 1.543%. Sedangkan, nilai RMSE yang diperoleh dari peramalan data *low* tersebut ialah sebesar 2.533.



Gambar 6.7. Grafik Hasil Peramalan Data Low Chevron Corporation

6.7.3 Hasil Peramalan Data High

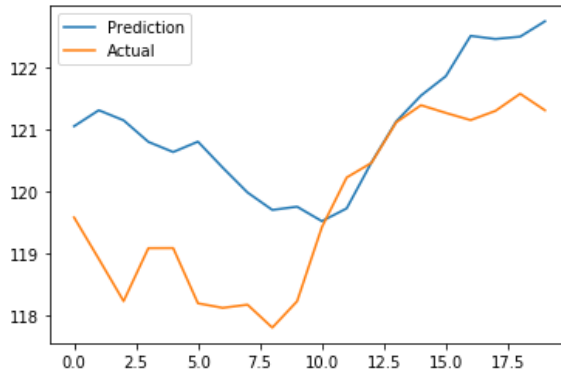
Hasil peramalan data *testing* Chevron Corporation untuk data *high* dengan menggunakan model LSTM terbaik dengan satu *hidden layer*, 125 *neuron hidden layer*, 100 *epochs*, dan jenis *optimizer* Adam dapat dilihat pada Gambar 6.8. Nilai MAPE yang diperoleh dari peramalan data *high* tersebut ialah sebesar 1.374%. Sedangkan, nilai RMSE yang diperoleh dari peramalan data *high* tersebut ialah sebesar 2.114.



Gambar 6.8. Grafik Hasil Peramalan Data High Chevron Corporation

6.8 Hasil Peramalan Masa Mendatang

Hasil peramalan data harga saham Chevron Corporation untuk satu bulan kedepan dengan menggunakan model LSTM terbaik dengan satu *hidden layer*, 125 *neuron hidden layer*, 100 *epochs*, dan jenis *optimizer* Adam dapat dilihat pada Gambar 6.9.




Gambar 6.9. Grafik Perbandingan Data Aktual dan Prediksi untuk Hasil Peramalan Data Harga Saham Chevron 1 Bulan Kedepan

Pada Gambar 6.9 dapat dilihat bahwa garis berwarna *orange* menunjukkan data aktual dari data harga saham harian Chevron Corporation. Sedangkan garis berwarna biru muda menunjukkan hasil peramalan dari data harga saham harian Chevron Corporation untuk satu bulan kedepan. Grafik diatas diperoleh dengan satu kali menjalankan model. Nilai MAPE yang diperoleh dari peramalan data harga saham harian Chevron Corporation untuk satu bulan kedepan tersebut ialah sebesar 1.108%. Sedangkan, nilai RMSE yang diperoleh ialah sebesar 1.576.

6.9 Hasil Peramalan dengan Data Saham Lain


Hasil peramalan data harga saham perusahaan lain dengan menggunakan model LSTM terbaik dengan satu *hidden layer*, 125 *neuron hidden layer*, 100 *epochs*, dan jenis *optimizer* Adam dapat dilihat pada Gambar 6.10, Gambar 6.11, dan Gambar

6.12. Dimana Gambar 6.10 merupakan grafik hasil peramalan menggunakan data harga saham harian milik Starbucks Corporation, Gambar 6.11 merupakan grafik hasil peramalan menggunakan data harga saham harian milik Apple Inc, dan Gambar 6.12 merupakan grafik hasil peramalan menggunakan data harga saham harian milik Sidomulyo.




Gambar 6.10. Grafik Perbandingan Data Aktual dan Prediksi untuk Hasil Peramalan Data Harga Saham Starbucks Corporation

Pada Gambar 6.10 dapat dilihat bahwa garis berwarna *orange* menunjukkan data aktual dari data harga saham harian Starbucks Corporation. Sedangkan garis berwarna biru muda menunjukkan hasil peramalan dari data harga saham harian Starbucks Corporation. Grafik diatas diperoleh dengan satu kali menjalankan model. Nilai MAPE yang diperoleh dari peramalan data harga saham harian Starbucks Corporation tersebut ialah sebesar 2.359%. Sedangkan, nilai RMSE yang diperoleh ialah sebesar 1.578.



Gambar 6.11. Grafik Perbandingan Data Aktual dan Prediksi untuk Hasil Peramalan Data Harga Saham Apple Inc.

Pada Gambar 6.11 dapat dilihat bahwa garis berwarna *orange* menunjukkan data aktual dari data harga saham harian Apple Inc. Sedangkan garis berwarna biru muda menunjukkan hasil peramalan dari data harga saham harian Apple Inc. Grafik diatas diperoleh dengan satu kali menjalankan model. Nilai MAPE yang diperoleh dari peramalan data harga saham harian Apple Inc. tersebut ialah sebesar 2.712%. Sedangkan, nilai RMSE yang diperoleh ialah sebesar 4.561.




Gambar 6.12. Grafik Perbandingan Data Aktual dan Prediksi untuk Hasil Peramalan Data Harga Saham Sidomulyo

Pada Gambar 6.12 dapat dilihat bahwa garis berwarna *orange* menunjukkan data aktual dari data harga saham harian Sidomulyo. Sedangkan garis berwarna biru muda menunjukkan hasil peramalan dari data harga saham harian Sidomulyo. Grafik diatas diperoleh dengan satu kali menjalankan model. Nilai SMAPE yang diperoleh dari peramalan data harga saham harian Sidomulyo tersebut ialah sebesar 7.819%. Sedangkan, nilai RMSE yang diperoleh ialah sebesar 36.212.

6.10 Hasil Peramalan dengan 12 *Timewindow*

Hasil peramalan data *testing* Chevron Corporation untuk data *close* dengan menggunakan model LSTM 12 *timewindow* dengan satu *hidden layer*, 125 *neuron hidden layer*, 100 *epochs*, dan jenis *optimizer* Adam dapat dilihat pada Gambar 6.13.




Gambar 6.13. Grafik Hasil Peramalan Data Close Chevron Corporation dengan 12 *Timewindow*

Pada Gambar 6.13 dapat dilihat bahwa garis berwarna *orange* menunjukkan data aktual dari data harga saham harian Chevron Corporation. Sedangkan garis berwarna biru muda menunjukkan hasil peramalan dari data harga saham harian Chevron Corporation. Grafik diatas diperoleh dengan satu kali menjalankan model. Nilai MAPE yang diperoleh dari peramalan data harga saham harian Chevron Corporation dengan menggunakan model LSTM 12 *timewindow* ialah

sebesar 1.394%. Sedangkan, nilai RMSE yang diperoleh ialah sebesar 2.203. Model LSTM 12 *timewindow* tersebut juga dijalankan sebanyak 10 kali percobaan dimana nilai rata-rata MAPE yang diperoleh ialah sebesar 1.381% dan nilai rata-rata RMSE yang diperoleh ialah sebesar 2.188. Untuk detail percobaannya dapat dilihat pada Lampiran B.

6.11 Hasil Peramalan dengan Model Simple RNN

Hasil peramalan data *testing* Chevron Corporation untuk data *close* dengan menggunakan model Simple RNN dengan satu *hidden layer*, 125 *neuron hidden layer*, 100 *epochs*, dan jenis *optimizer* Adam dapat dilihat pada Gambar 6.14.



Gambar 6.14. Grafik Hasil Peramalan Data Chevron Corporation dengan Model Simple RNN

Pada Gambar 6.14 dapat dilihat bahwa garis berwarna *orange* menunjukkan data aktual dari data harga saham harian Chevron Corporation. Sedangkan garis berwarna biru muda menunjukkan hasil peramalan dari data harga saham harian Chevron Corporation. Grafik diatas diperoleh dengan satu kali menjalankan model. Nilai MAPE yang diperoleh dari peramalan data harga saham harian Chevron Corporation dengan menggunakan model Simple RNN ialah sebesar 1.814%. Sedangkan, nilai RMSE yang diperoleh ialah sebesar 2.726.

6.12 Hasil Perbandingan Nilai MAPE dan RMSE

Hasil perbandingan akurasi dari nilai MAPE dan RMSE terhadap peramalan harga saham harian dengan menggunakan model LSTM dapat dilihat pada Tabel 6.2.

Tabel 6.2. Hasil Perbandingan Nilai MAPE dan RMSE

Peramalan	RMSE	MAPE
Data testing Chevron Corporation (20 timewindow)	2.397	1.501%
Data testing Chevron Corporation (12 timewindow)	2.188	1.381%
Chevron Corporation (1 bulan kedepan)	1.576	1.108%
Starbucks Corporation	1.578	2.359%
Apple Inc	4.561	2.712%
Sidomulyo	36.212	7.819% (SMAPE)
Data testing Chevron Corporation (Simple RNN)	2.726	1.814%

BAB VII

KESIMPULAN DAN SARAN

Pada bab ini dijelaskan mengenai kesimpulan dari semua proses yang telah dilakukan dan saran yang dapat diberikan untuk pengembangan yang lebih baik.

7.1 Kesimpulan

Berikut ini merupakan kesimpulan yang dapat diambil dari penelitian terhadap peramalan harga saham harian Chevron Corporation dengan menggunakan Metode Long Short-Term Memory (LSTM):

1. Peramalan dengan menggunakan Metode Long Short-Term Memory (LSTM) cocok digunakan untuk meramalkan data dengan periode waktu yang panjang.
2. Peramalan dengan menggunakan Metode Long Short-Term Memory (LSTM) dapat meramalkan data harga saham harian dengan hasil akurasi yang sangat baik berdasarkan nilai rata-rata MAPE *testing* yang diperoleh yaitu dibawah 10%.
3. Hasil peramalan harga saham dengan menggunakan satu *hidden layer* menghasilkan nilai MAPE dan RMSE yang lebih kecil dibandingkan dengan hasil peramalan dengan menggunakan dua *hidden layer*.
4. Model LSTM terbaik yang diperoleh dari penelitian ini ialah model LSTM dengan satu *hidden layer*, 125 *neuron hidden layer*, 100 *epochs*, dan jenis *optimizer* Adam dengan nilai rata-rata MAPE *testing* sebesar 1.501% dan nilai rata-rata RMSE *testing* sebesar 2.397.
5. Hasil peramalan data harga saham harian Chevron Corporation untuk satu bulan kedepan menghasilkan akurasi yang sangat baik dimana nilai MAPE yang dihasilkan sebesar 1.108% dan nilai RMSE sebesar 1.576.
6. Berdasarkan hasil peramalan data harga saham harian perusahaan lain yaitu Starbucks Corporation, Apple Inc., dan Sidomulyo dengan menggunakan model LSTM

terbaik yang telah diperoleh tersebut dapat dikatakan bahwa akurasi hasil peramalan yang dihasilkan sangat baik. Dimana nilai MAPE yang dihasilkan untuk data Starbucks Corporation sebesar 2.359%, nilai MAPE untuk data Apple Inc sebesar 2.712%, dan nilai SMAPE untuk data Sidomulyo sebesar 7.819%.

7. Pada penelitian ini, hasil peramalan harga saham harian Chevron Corporation dengan 12 *timewindow* menghasilkan akurasi yang lebih baik dibandingkan hasil peramalan saham harian dengan 20 *timewindow* dimana nilai MAPE yang diperoleh sebesar 1.394% dan RMSE sebesar 2.203.
8. Berdasarkan hasil perbandingan nilai MAPE dan RMSE yang diperoleh dari model LSTM dan model Simple RNN, dapat dinyatakan bahwa memang benar LSTM menghasilkan akurasi peramalan yang lebih baik dibanding model Simple RNN. Dimana nilai MAPE yang diperoleh dari model LSTM ialah sebesar 1.501%, sedangkan nilai MAPE yang diperoleh dari model Simple RNN ialah sebesar 1.814%.

7.2 Saran

Berdasarkan penelitian tugas akhir yang telah dilakukan ini, berikut merupakan saran yang dapat digunakan untuk menyempurnakan penelitian terhadap Peramalan Harga Saham dengan Menggunakan Metode Long Short-Term Memory (LSTM) RNN:

1. Adanya penggantian terhadap rasio pembagian data *training* dan data *testing* yang digunakan untuk melakukan peramalan.
2. Adanya penggantian terhadap data yang digunakan untuk melakukan peramalan yaitu menjadi data harga saham dengan periode waktu yang lebih panjang.
3. Adanya penggantian terhadap jumlah *timewindow* yang digunakan untuk meramalkan harga saham.

DAFTAR PUSTAKA

- [1] K. Ali, “Analisis Faktor yang Mempengaruhi Struktur Modal serta Pengaruhnya terhadap Harga Saham Perusahaan Real Estate yang Go Public di Bursa Efek Indonesia,” *J. Manaj. dan Kewirausahaan*, pp. 38–45, 2009.
- [2] Y. Appa, “Pengaruh Inflasi dan Kurs Rupiah/Dolar Amerika Terhadap Indeks Harga Saham Gabungan (IHSG) di Bursa Efek Indonesia (BEI),” *eJournal Adm. Bisnis*, vol. 2, no. 4, pp. 498–512, 2014.
- [3] E. Mala, S. Rochman, A. Djunaidy, T. Informatika, and F. T. Informasi, “Prediksi harga saham yang mempertimbangkan faktor eksternal menggunakan jaringan saraf tiruan,” vol. 1, no. 2, pp. 5–11, 2014.
- [4] D. Shah, W. Campbell, and F. H. Zulkernine, “A Comparative Study of LSTM and DNN for Stock Market Forecasting,” *Proc. - 2018 IEEE Int. Conf. Big Data, Big Data 2018*, no. December, pp. 4148–4155, 2019.
- [5] R. Murtaza, P. Harshal, and V. Shraddha, “Predicting Stock Prices Using LSTM,” *Int. J. Sci. Res.*, vol. 6, no. 4, pp. 2319–7064, 2015.
- [6] N. Sari, “Makalah Metode Peramalan,” pp. 1–12, 1999.
- [7] M. Wildan, P. Aldi, and A. Aditsania, “Analisis dan Implementasi Long Short Term Memory Neural Network untuk

Prediksi Harga Bitcoin,” e-Proceeding Eng., vol. 5, no. 2, pp. 3548–3555, 2018.

[8] K. Chen, Y. Zhou, and F. Dai, “A LSTM-based method for stock returns prediction: A case study of China stock market,” Proc. - 2015 IEEE Int. Conf. Big Data, IEEE Big Data 2015, pp. 2823–2824, 2015.

[9] C. Sang and M. Di Pierro, “Improving trading technical analysis with TensorFlow Long Short-Term Memory (LSTM) Neural Network,” J. Financ. Data Sci., vol. 5, no. 1, pp. 1–11, 2018.

BIODATA PENULIS



Penulis bernama Isvania Almira Janitra, lahir di Jakarta pada tanggal 6 Januari 1998, merupakan anak pertama dari dua bersaudara. Penulis telah menempuh jenjang pendidikan formal di beberapa sekolah, yaitu: SD Negeri 7 Mataram (2004-2010), SMP Negeri 2 Mataram (2010-2013), dan SMA Negeri 5 Mataram (2013-2016). Penulis melanjutkan pendidikan sarjana di Departemen Sistem

Informasi Fakultas Teknologi Elektro dan Informatika Cerdas (FTEIC) Institut Teknologi Sepuluh Nopember (ITS) pada tahun 2016 yang terdaftar sebagai mahasiswa dengan NRP 05211640000017.

Selama menjadi mahasiswa, penulis aktif mengikuti organisasi kemahasiswaan, seperti Himpunan Mahasiswa Sistem Informasi (HMSI) untuk periode HMSI Evolve (2017-2018) sebagai Staf Divisi Kaderisasi Departemen HRD Transform dan HMSI Rumah Karya (2018-2019) sebagai Kepala Divisi Kaderisasi Departemen HRD Revise, serta BEM FTIK ASASI periode 2018-2019 sebagai Kepala Divisi Internal Departemen IA. Penulis juga aktif di beberapa kegiatan kepanitiaan, seperti FTIF Festival 2017 sebagai Staf Acara Exhibition, Information Systems Expo 2017 sebagai Staf Acara & *liaison officer*, Information Systems Expo 2018 sebagai Koordinator Event ICON, Gerigi ITS 2017 sebagai Fasilitator Inti *Liaison Officer*, dan kegiatan kepanitiaan lainnya.

Penulis melaksanakan kerja praktik di PT. Chevron Pacific Indonesia sebagai *data scientist*. Pada saat melaksanakan kerja praktik, penulis mengerjakan *project* “Peramalan Data (*Data Science Challenge*) dengan Menggunakan Random Forest”.

Penulis dapat dihubungi melalui e-mail vanialmirajntr@gmail.com.

Halaman ini sengaja dikosongkan

LAMPIRAN A. Detail Percobaan Model

1 Hidden Layer

Model 1

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	50	25	2.557	3.128	1.914	2.037
2	Adam	50	25	2.452	3.128	1.846	2.041
3	Adam	50	25	2.619	3.151	1.971	2.056
4	Adam	50	25	2.240	2.802	1.667	1.793
5	Adam	50	25	2.664	3.321	2.001	2.136
6	Adam	50	25	2.433	2.897	1.823	1.892
7	Adam	50	25	2.678	3.274	2.021	2.151
8	Adam	50	25	2.468	2.907	1.844	1.875
9	Adam	50	25	2.506	2.961	1.873	1.897
10	Adam	50	25	2.628	3.271	1.972	2.126
Average				2.525	3.084	1.893	2.000

Model 2

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	75	25	2.505	2.980	1.872	1.938
2	Adam	75	25	2.622	3.158	1.964	2.062
3	Adam	75	25	2.818	3.497	2.109	2.293
4	Adam	75	25	2.700	3.160	2.022	2.061
5	Adam	75	25	2.565	3.046	1.907	1.961
6	Adam	75	25	2.733	3.297	2.048	2.161
7	Adam	75	25	2.546	3.154	1.916	2.040
8	Adam	75	25	2.329	2.819	1.735	1.802
9	Adam	75	25	2.570	3.118	1.918	2.003
10	Adam	75	25	2.359	2.961	1.770	1.915
Average				2.575	3.119	1.926	2.024

Model 3

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	100	25	2.583	3.156	1.937	2.036
2	Adam	100	25	2.650	3.201	1.988	2.067
3	Adam	100	25	2.562	3.111	1.925	2.006
4	Adam	100	25	2.556	3.131	1.918	2.010
5	Adam	100	25	2.583	3.145	1.940	2.038
6	Adam	100	25	2.474	3.034	1.860	1.977
7	Adam	100	25	2.664	3.229	2.010	2.103
8	Adam	100	25	2.641	3.184	1.974	2.070
9	Adam	100	25	2.643	3.221	2.002	2.100
10	Adam	100	25	2.596	3.190	1.950	2.080
Average				2.595	3.160	1.950	2.049

Model 4

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	125	25	2.543	3.086	1.911	1.997
2	Adam	125	25	2.639	3.221	1.980	2.081
3	Adam	125	25	2.499	3.095	1.881	2.015
4	Adam	125	25	2.682	3.296	2.015	2.144
5	Adam	125	25	2.523	2.991	1.886	1.933
6	Adam	125	25	2.516	3.076	1.885	1.987
7	Adam	125	25	2.706	3.323	2.036	2.167
8	Adam	125	25	2.618	3.128	1.968	2.032
9	Adam	125	25	2.564	3.149	1.933	2.601
10	Adam	125	25	2.637	3.201	1.982	2.078
Average				2.593	3.157	1.948	2.104

Model 5

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	50	50	2.457	2.623	1.916	1.663
2	Adam	50	50	2.242	2.605	1.697	1.614
3	Adam	50	50	2.182	2.590	1.629	1.625
4	Adam	50	50	2.482	2.704	1.920	1.692
5	Adam	50	50	2.260	2.500	1.734	1.566
6	Adam	50	50	2.239	2.582	1.687	1.608
7	Adam	50	50	2.472	2.567	1.943	1.621
8	Adam	50	50	2.371	2.619	1.804	1.630
9	Adam	50	50	2.278	2.627	1.731	1.642
10	Adam	50	50	2.408	2.584	1.860	1.616
Average				2.339	2.600	1.792	1.628

Model 6

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	75	50	2.585	2.743	2.005	1.726
2	Adam	75	50	2.610	2.644	2.057	1.673
3	Adam	75	50	2.511	2.581	1.981	1.635
4	Adam	75	50	2.498	2.568	1.974	1.609
5	Adam	75	50	2.561	2.615	2.028	1.641
6	Adam	75	50	2.570	2.559	2.036	1.620
7	Adam	75	50	2.393	2.652	1.829	1.655
8	Adam	75	50	2.282	2.565	1.751	1.592
9	Adam	75	50	2.602	2.632	2.067	1.648
10	Adam	75	50	2.572	2.669	2.023	1.683
Average				2.518	2.623	1.975	1.648

Model 7

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	100	50	2.541	2.721	1.969	1.715
2	Adam	100	50	2.328	2.547	1.782	1.604
3	Adam	100	50	2.589	2.691	2.034	1.693
4	Adam	100	50	2.525	2.613	1.990	1.647
5	Adam	100	50	2.444	2.608	1.903	1.649
6	Adam	100	50	2.35	2.622	1.823	1.635
7	Adam	100	50	2.337	2.634	1.786	1.641
8	Adam	100	50	2.529	2.605	1.995	1.637
9	Adam	100	50	2.556	2.675	2.001	1.683
10	Adam	100	50	2.470	2.629	1.939	1.648
Average				2.467	2.635	1.922	1.655

Model 8

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	125	50	2.465	2.608	1.930	1.637
2	Adam	125	50	2.564	2.607	2.038	1.648
3	Adam	125	50	2.434	2.662	1.881	1.661
4	Adam	125	50	2.403	2.637	1.866	1.650
5	Adam	125	50	2.537	2.748	1.978	1.724
6	Adam	125	50	2.408	2.652	1.853	1.661
7	Adam	125	50	2.220	2.603	1.668	1.628
8	Adam	125	50	2.385	2.505	1.853	1.567
9	Adam	125	50	2.404	2.642	1.867	1.651
10	Adam	125	50	2.41	2.68	1.847	1.689
Average				2.423	2.634	1.878	1.652

Model 9

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	50	75	2.431	2.582	1.914	1.618
2	Adam	50	75	2.399	3.477	1.770	2.477
3	Adam	50	75	2.291	2.407	1.804	1.522
4	Adam	50	75	2.447	2.554	1.938	1.585
5	Adam	50	75	2.426	2.374	1.955	1.482
6	Adam	50	75	2.342	2.414	1.853	1.504
7	Adam	50	75	2.326	2.399	1.818	1.503
8	Adam	50	75	2.409	2.484	1.919	1.547
9	Adam	50	75	2.248	2.309	1.762	1.441
10	Adam	50	75	2.343	2.487	1.835	1.586
Average				2.366	2.549	1.857	1.627

Model 10

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	75	75	2.034	2.266	1.552	1.414
2	Adam	75	75	2.450	2.560	1.929	1.626
3	Adam	75	75	2.559	2.469	2.062	1.551
4	Adam	75	75	2.533	2.491	2.031	1.562
5	Adam	75	75	2.583	2.515	2.081	1.589
6	Adam	75	75	2.466	2.551	1.956	1.590
7	Adam	75	75	2.636	2.508	2.132	1.597
8	Adam	75	75	2.487	2.552	1.966	1.608
9	Adam	75	75	2.472	2.511	1.966	1.575
10	Adam	75	75	2.578	2.546	2.064	1.608
Average				2.480	2.497	1.974	1.572

Model 11

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	100	75	2.394	2.455	1.884	1.539
2	Adam	100	75	2.496	2.516	1.984	1.583
3	Adam	100	75	2.501	2.556	1.983	1.603
4	Adam	100	75	2.502	2.569	1.976	1.616
5	Adam	100	75	2.401	2.441	1.914	1.526
6	Adam	100	75	2.611	2.520	2.104	1.586
7	Adam	100	75	2.454	2.445	1.960	1.530
8	Adam	100	75	2.907	2.586	2.412	1.65
9	Adam	100	75	3.052	1.689	2.545	1.709
10	Adam	100	75	2.452	2.474	1.947	1.554
Average				2.577	2.425	2.071	1.590

Model 12

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	125	75	2.567	2.481	2.073	1.559
2	Adam	125	75	2.653	2.560	2.156	1.614
3	Adam	125	75	2.547	2.555	2.029	1.598
4	Adam	125	75	2.510	2.508	1.997	1.578
5	Adam	125	75	2.648	2.558	2.146	1.61
6	Adam	125	75	2.570	2.523	2.065	1.584
7	Adam	125	75	2.603	2.553	2.096	1.609
8	Adam	125	75	2.518	2.531	2.001	1.595
9	Adam	125	75	2.590	2.497	2.088	1.572
10	Adam	125	75	2.720	2.609	2.206	1.647
Average				2.593	2.538	2.086	1.597

Model 13

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	50	100	2.149	2.294	1.671	1.438
2	Adam	50	100	2.281	2.377	1.791	1.492
3	Adam	50	100	2.148	2.261	1.661	1.422
4	Adam	50	100	2.115	2.296	1.686	1.435
5	Adam	50	100	2.846	3.041	2.318	2.121
6	Adam	50	100	2.270	2.389	1.768	1.501
7	Adam	50	100	2.560	2.484	2.081	1.566
8	Adam	50	100	2.301	2.364	1.808	1.478
9	Adam	50	100	2.353	2.392	1.872	1.497
10	Adam	50	100	2.302	2.401	1.825	1.494
Average				2.333	2.430	1.848	1.544

Model 14

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	75	100	2.356	2.455	1.865	1.550
2	Adam	75	100	2.353	2.374	1.871	1.483
3	Adam	75	100	2.271	2.333	1.791	1.467
4	Adam	75	100	2.240	2.292	1.764	1.438
5	Adam	75	100	2.380	2.371	1.904	1.494
6	Adam	75	100	3.135	2.765	2.649	1.801
7	Adam	75	100	2.152	2.339	1.676	1.466
8	Adam	75	100	2.381	2.385	1.898	1.489
9	Adam	75	100	2.321	2.393	1.837	1.496
10	Adam	75	100	2.440	2.415	1.952	1.510
Average				2.403	2.412	1.921	1.519

Model 15

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	100	100	2.569	2.465	2.077	1.553
2	Adam	100	100	1.955	2.276	1.464	1.427
3	Adam	100	100	2.122	2.301	1.637	1.435
4	Adam	100	100	2.529	2.400	2.051	1.505
5	Adam	100	100	2.331	2.363	1.85	1.478
6	Adam	100	100	2.385	2.360	1.913	1.473
7	Adam	100	100	2.598	2.494	2.124	1.580
8	Adam	100	100	3.138	2.709	2.655	1.739
9	Adam	100	100	2.479	2.429	1.997	1.520
10	Adam	100	100	2.923	2.583	2.441	1.651
Average				2.503	2.438	2.021	1.536

Model 16

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	125	100	2.192	2.291	1.729	1.426
2	Adam	125	100	2.436	2.421	1.939	1.521
3	Adam	125	100	2.435	2.428	1.947	1.517
4	Adam	125	100	2.366	2.370	1.877	1.480
5	Adam	125	100	2.387	2.408	1.887	1.508
6	Adam	125	100	2.484	2.480	1.983	1.560
7	Adam	125	100	2.507	2.45	2.023	1.542
8	Adam	125	100	2.253	2.349	1.763	1.471
9	Adam	125	100	2.573	2.465	2.085	1.546
10	Adam	125	100	2.079	2.309	1.596	1.442
Average				2.371	2.397	1.883	1.501

Model 17

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	50	25	3.116	3.919	2.371	2.578
2	Adamax	50	25	3.466	4.240	2.656	2.826
3	Adamax	50	25	3.396	3.991	2.591	2.669
4	Adamax	50	25	2.989	3.829	2.270	2.519
5	Adamax	50	25	3.282	4.010	2.496	2.656
6	Adamax	50	25	3.331	4.170	2.543	2.794
7	Adamax	50	25	3.163	3.905	2.396	2.586
8	Adamax	50	25	3.606	4.450	2.763	3.011
9	Adamax	50	25	2.863	3.703	2.183	2.44
10	Adamax	50	25	3.456	4.169	2.637	2.798
Average				3.267	4.039	2.491	2.688

Model 18

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	75	25	3.355	4.061	2.561	2.698
2	Adamax	75	25	3.082	3.833	2.337	2.540
3	Adamax	75	25	3.080	3.83	2.343	2.543
4	Adamax	75	25	3.446	4.295	2.637	2.899
5	Adamax	75	25	3.228	4.053	2.462	2.702
6	Adamax	75	25	2.750	3.559	2.071	2.347
7	Adamax	75	25	3.215	4.004	2.438	2.646
8	Adamax	75	25	3.259	4.066	2.487	2.711
9	Adamax	75	25	3.385	4.177	2.593	2.786
10	Adamax	75	25	3.259	3.949	2.488	2.629
Average				3.206	3.983	2.442	2.650

Model 19

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	100	25	3.294	4.096	2.502	2.752
2	Adamax	100	25	3.468	4.326	2.650	2.892
3	Adamax	100	25	2.975	3.732	2.261	2.473
4	Adamax	100	25	3.570	4.355	2.729	2.915
5	Adamax	100	25	3.145	3.892	2.386	2.589
6	Adamax	100	25	3.170	4.143	2.412	2.737
7	Adamax	100	25	3.095	3.719	2.340	2.475
8	Adamax	100	25	3.191	3.938	2.424	2.611
9	Adamax	100	25	3.345	4.095	2.546	2.732
10	Adamax	100	25	3.263	3.975	2.483	2.629
Average				3.252	4.027	2.473	2.681

Model 20

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	125	25	3.684	4.595	2.824	3.060
2	Adamax	125	25	2.976	3.609	2.252	2.380
3	Adamax	125	25	3.297	4.133	2.516	2.767
4	Adamax	125	25	3.164	3.789	2.404	2.508
5	Adamax	125	25	3.133	3.849	2.385	2.579
6	Adamax	125	25	3.157	3.780	2.394	2.499
7	Adamax	125	25	3.355	4.151	2.558	2.759
8	Adamax	125	25	3.409	4.286	2.600	2.843
9	Adamax	125	25	3.353	4.182	2.560	2.789
10	Adamax	125	25	3.326	4.260	2.543	2.831
Average				3.285	4.063	2.504	2.702

Model 21

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	50	50	2.860	3.472	2.136	2.271
2	Adamax	50	50	2.387	2.779	1.785	1.824
3	Adamax	50	50	3.034	3.835	2.313	2.546
4	Adamax	50	50	2.781	3.460	2.117	2.295
5	Adamax	50	50	2.840	3.626	2.143	2.414
6	Adamax	50	50	3.154	3.947	2.393	2.597
7	Adamax	50	50	2.902	3.477	2.186	2.311
8	Adamax	50	50	3.310	4.083	2.540	2.727
9	Adamax	50	50	3.051	3.704	2.300	2.447
10	Adamax	50	50	2.680	3.205	2.019	2.086
Average				2.900	3.559	2.193	2.352

Model 22

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	75	50	2.446	2.971	1.831	1.930
2	Adamax	75	50	2.885	3.497	2.171	2.306
3	Adamax	75	50	2.881	3.443	2.179	2.282
4	Adamax	75	50	2.752	3.410	2.057	2.247
5	Adamax	75	50	2.853	3.455	2.157	2.275
6	Adamax	75	50	3.019	3.803	2.286	2.507
7	Adamax	75	50	2.881	3.389	2.164	2.219
8	Adamax	75	50	3.105	3.766	2.351	2.496
9	Adamax	75	50	2.836	3.409	2.134	2.233
10	Adamax	75	50	2.853	3.449	2.166	2.276
Average				2.851	3.459	2.150	2.277

Model 23

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	100	50	2.972	3.674	2.255	2.420
2	Adamax	100	50	3.000	3.690	2.255	2.434
3	Adamax	100	50	3.192	3.837	2.422	2.532
4	Adamax	100	50	3.168	3.910	2.407	2.589
5	Adamax	100	50	2.952	3.690	2.231	2.418
6	Adamax	100	50	2.781	3.422	2.099	2.253
7	Adamax	100	50	3.011	3.649	2.283	2.415
8	Adamax	100	50	2.926	3.617	2.191	2.388
9	Adamax	100	50	3.258	3.975	2.477	2.627
10	Adamax	100	50	2.603	3.182	1.946	2.098
Average				2.986	3.665	2.257	2.417

Model 24

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	125	50	3.077	3.778	2.331	2.507
2	Adamax	125	50	2.903	3.526	2.197	2.334
3	Adamax	125	50	2.658	3.280	1.998	2.151
4	Adamax	125	50	2.700	3.341	2.026	2.192
5	Adamax	125	50	2.961	3.646	2.233	2.406
6	Adamax	125	50	2.914	3.513	2.192	2.318
7	Adamax	125	50	2.661	3.269	2.018	2.150
8	Adamax	125	50	2.861	3.466	2.148	2.269
9	Adamax	125	50	2.744	3.418	2.059	2.254
10	Adamax	125	50	2.946	3.667	2.222	2.407
Average				2.843	3.490	2.142	2.299

Model 25

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	50	75	2.512	3.116	1.882	2.032
2	Adamax	50	75	2.581	3.132	1.922	2.054
3	Adamax	50	75	2.436	2.677	1.806	1.700
4	Adamax	50	75	3.070	3.779	2.315	2.493
5	Adamax	50	75	2.584	3.230	1.930	2.098
6	Adamax	50	75	2.349	2.811	1.759	1.806
7	Adamax	50	75	2.918	3.399	2.206	2.222
8	Adamax	50	75	2.716	3.415	2.038	2.249
9	Adamax	50	75	2.846	3.378	2.133	2.266
10	Adamax	50	75	2.371	2.614	1.741	1.710
Average				2.638	3.155	1.973	2.063

Model 26

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	75	75	2.844	3.483	2.135	2.287
2	Adamax	75	75	2.407	2.795	1.803	1.815
3	Adamax	75	75	2.924	3.674	2.210	2.430
4	Adamax	75	75	2.626	3.201	1.962	2.085
5	Adamax	75	75	2.846	2.469	2.134	2.281
6	Adamax	75	75	2.587	3.177	1.936	2.056
7	Adamax	75	75	2.724	3.386	2.033	2.216
8	Adamax	75	75	2.629	3.252	1.974	2.094
9	Adamax	75	75	2.562	3.058	1.912	1.986
10	Adamax	75	75	2.698	3.196	2.004	2.072
Average				2.685	3.169	2.010	2.132

Model 27

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	100	75	2.505	3.016	1.863	1.948
2	Adamax	100	75	2.364	2.763	1.755	1.778
3	Adamax	100	75	2.657	3.172	1.996	2.101
4	Adamax	100	75	2.678	3.256	2.011	2.154
5	Adamax	100	75	2.641	3.230	1.987	2.117
6	Adamax	100	75	2.665	3.228	2.005	2.119
7	Adamax	100	75	2.254	2.671	1.665	1.711
8	Adamax	100	75	2.678	3.246	2.010	2.120
9	Adamax	100	75	2.451	2.990	1.825	1.955
10	Adamax	100	75	2.826	3.482	2.119	2.280
Average				2.572	3.105	1.924	2.028

Model 28

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	125	75	2.388	2.802	1.761	1.792
2	Adamax	125	75	2.531	2.988	1.895	1.948
3	Adamax	125	75	2.664	3.153	1.987	2.067
4	Adamax	125	75	2.328	2.698	1.710	1.703
5	Adamax	125	75	2.470	2.978	1.839	1.941
6	Adamax	125	75	2.527	3.075	1.888	2.005
7	Adamax	125	75	2.384	2.830	1.768	1.834
8	Adamax	125	75	2.488	2.907	1.837	1.876
9	Adamax	125	75	2.615	3.164	1.966	2.064
10	Adamax	125	75	2.573	3.219	1.930	2.110
Average				2.497	2.981	1.858	1.934

Model 29

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	50	100	2.583	3.072	1.932	1.996
2	Adamax	50	100	2.455	3.009	1.837	1.933
3	Adamax	50	100	2.525	3.191	1.892	2.086
4	Adamax	50	100	2.667	2.934	1.981	1.916
5	Adamax	50	100	2.119	2.581	1.556	1.620
6	Adamax	50	100	2.597	2.872	1.918	1.853
7	Adamax	50	100	2.300	2.928	1.722	1.910
8	Adamax	50	100	2.238	2.749	1.649	1.757
9	Adamax	50	100	2.250	2.578	1.644	1.629
10	Adamax	50	100	2.630	3.108	1.950	2.013
Average				2.436	2.902	1.808	1.871

Model 30

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	75	100	2.251	2.817	1.661	1.789
2	Adamax	75	100	2.366	2.964	1.770	1.923
3	Adamax	75	100	2.272	2.708	1.677	1.742
4	Adamax	75	100	2.294	2.692	1.685	1.725
5	Adamax	75	100	2.231	2.639	1.641	1.666
6	Adamax	75	100	2.441	2.853	1.803	1.831
7	Adamax	75	100	2.407	2.910	1.771	1.850
8	Adamax	75	100	2.286	2.642	1.689	1.694
9	Adamax	75	100	2.349	2.734	1.714	1.732
10	Adamax	75	100	2.411	2.859	1.789	1.857
Average				2.331	2.782	1.720	1.781

Model 31

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	100	100	2.227	2.645	1.644	1.675
2	Adamax	100	100	2.395	2.795	1.763	1.800
3	Adamax	100	100	2.308	2.783	1.710	1.796
4	Adamax	100	100	2.128	2.513	1.571	1.606
5	Adamax	100	100	2.189	2.605	1.604	1.664
6	Adamax	100	100	2.381	2.804	1.759	1.796
7	Adamax	100	100	2.264	2.715	1.671	1.741
8	Adamax	100	100	2.248	2.637	1.661	1.667
9	Adamax	100	100	2.225	2.545	1.628	1.638
10	Adamax	100	100	2.133	2.437	1.559	1.526
Average				2.250	2.648	1.657	1.691

Model 32

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	125	100	2.274	2.715	1.678	1.730
2	Adamax	125	100	2.054	2.443	1.519	1.531
3	Adamax	125	100	2.352	2.755	1.733	1.765
4	Adamax	125	100	2.189	2.669	1.612	1.672
5	Adamax	125	100	2.235	2.714	1.655	1.730
6	Adamax	125	100	2.197	2.643	1.619	1.660
7	Adamax	125	100	2.162	2.623	1.584	1.645
8	Adamax	125	100	2.362	2.825	1.749	1.808
9	Adamax	125	100	2.360	2.864	1.750	1.834
10	Adamax	125	100	2.237	2.787	1.661	1.793
Average				2.242	2.704	1.656	1.717

Model 33

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	50	25	4.240	2.977	3.597	1.927
2	RMSprop	50	25	3.854	2.994	3.191	1.945
3	RMSprop	50	25	3.575	2.755	2.949	1.781
4	RMSprop	50	25	3.868	2.924	3.224	1.900
5	RMSprop	50	25	4.376	3.159	3.681	2.065
6	RMSprop	50	25	3.925	3.024	3.264	1.985
7	RMSprop	50	25	4.071	3.045	3.412	1.968
8	RMSprop	50	25	4.016	2.944	3.392	1.909
9	RMSprop	50	25	4.312	3.122	3.648	2.033
10	RMSprop	50	25	3.712	2.800	3.087	1.826
Average				3.995	2.974	3.345	1.934

Model 34

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	75	25	4.046	2.887	3.419	1.869
2	RMSprop	75	25	4.029	2.899	3.389	1.907
3	RMSprop	75	25	4.308	3.018	3.657	1.979
4	RMSprop	75	25	4.146	3.063	3.478	2.009
5	RMSprop	75	25	4.155	2.972	3.501	1.944
6	RMSprop	75	25	4.498	3.166	3.841	2.072
7	RMSprop	75	25	4.450	3.116	3.804	2.041
8	RMSprop	75	25	3.999	2.986	3.332	1.955
9	RMSprop	75	25	4.310	3.076	3.657	2.014
10	RMSprop	75	25	4.047	2.846	3.455	1.850
Average				4.199	3.003	3.553	1.964

Model 35

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	100	25	4.116	2.976	3.468	1.961
2	RMSprop	100	25	4.453	3.053	3.807	1.997
3	RMSprop	100	25	4.421	3.187	3.755	2.092
4	RMSprop	100	25	4.393	3.103	3.747	2.032
5	RMSprop	100	25	4.292	3.153	3.614	2.071
6	RMSprop	100	25	4.469	3.130	3.799	2.056
7	RMSprop	100	25	4.578	3.205	3.899	2.106
8	RMSprop	100	25	4.523	3.129	3.863	2.052
9	RMSprop	100	25	4.320	3.135	3.656	2.060
10	RMSprop	100	25	4.367	3.151	3.703	2.068
Average				4.393	3.122	3.731	2.050

Model 36

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	125	25	4.781	3.283	4.098	2.155
2	RMSprop	125	25	4.672	3.273	3.983	2.139
3	RMSprop	125	25	4.504	3.114	3.844	2.045
4	RMSprop	125	25	4.452	3.145	3.798	2.066
5	RMSprop	125	25	4.490	3.180	3.810	2.084
6	RMSprop	125	25	4.533	3.162	3.869	2.085
7	RMSprop	125	25	4.307	3.088	3.625	2.031
8	RMSprop	125	25	4.465	3.175	3.779	2.101
9	RMSprop	125	25	4.403	3.100	3.739	2.044
10	RMSprop	125	25	4.446	3.166	3.772	2.070
Average				4.505	3.169	3.832	2.082

Model 37

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	50	50	3.164	2.553	2.627	1.646
2	RMSprop	50	50	3.626	2.829	3.049	1.822
3	RMSprop	50	50	3.359	2.613	2.819	1.670
4	RMSprop	50	50	3.319	2.645	2.768	1.695
5	RMSprop	50	50	3.641	2.670	3.058	1.714
6	RMSprop	50	50	3.160	2.626	2.615	1.689
7	RMSprop	50	50	3.315	2.615	2.767	1.667
8	RMSprop	50	50	3.244	2.647	2.678	1.708
9	RMSprop	50	50	3.517	2.699	2.945	1.742
10	RMSprop	50	50	3.130	2.584	2.583	1.655
Average				3.348	2.648	2.791	1.701

Model 38

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	75	50	3.428	2.655	2.863	1.710
2	RMSprop	75	50	3.330	2.687	2.762	1.742
3	RMSprop	75	50	4.022	2.820	3.436	1.833
4	RMSprop	75	50	3.241	2.585	2.676	1.666
5	RMSprop	75	50	3.631	2.737	3.058	1.771
6	RMSprop	75	50	3.257	2.628	2.698	1.691
7	RMSprop	75	50	3.441	2.619	2.877	1.693
8	RMSprop	75	50	3.649	2.697	3.089	1.740
9	RMSprop	75	50	3.462	2.696	2.899	1.746
10	RMSprop	75	50	3.378	2.676	2.810	1.735
Average				3.484	2.680	2.917	1.733

Model 39

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	100	50	3.665	2.719	3.089	1.757
2	RMSprop	100	50	3.531	2.691	2.960	1.733
3	RMSprop	100	50	3.523	2.713	2.953	1.750
4	RMSprop	100	50	3.631	2.720	3.058	1.764
5	RMSprop	100	50	3.537	2.696	2.973	1.754
6	RMSprop	100	50	3.653	2.765	3.064	1.788
7	RMSprop	100	50	3.323	2.649	2.759	1.712
8	RMSprop	100	50	3.613	2.749	3.031	1.777
9	RMSprop	100	50	3.625	2.703	3.048	1.757
10	RMSprop	100	50	3.486	2.696	2.915	1.755
Average				3.559	2.710	2.985	1.755

Model 40

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	125	50	3.715	2.709	3.140	1.751
2	RMSprop	125	50	3.661	2.796	3.059	1.825
3	RMSprop	125	50	3.552	2.697	2.975	1.748
4	RMSprop	125	50	3.454	2.704	2.870	1.765
5	RMSprop	125	50	3.766	2.805	3.184	1.816
6	RMSprop	125	50	3.376	2.724	2.801	1.767
7	RMSprop	125	50	3.630	2.713	3.039	1.756
8	RMSprop	125	50	3.427	2.693	2.857	1.752
9	RMSprop	125	50	3.669	2.712	3.098	1.754
10	RMSprop	125	50	3.845	2.778	3.259	1.791
Average				3.610	2.733	3.028	1.773

Model 41

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	50	75	2.878	2.603	2.352	1.692
2	RMSprop	50	75	2.891	2.522	2.361	1.623
3	RMSprop	50	75	2.467	2.712	1.955	1.806
4	RMSprop	50	75	2.648	2.335	2.157	1.502
5	RMSprop	50	75	2.584	2.728	2.066	1.786
6	RMSprop	50	75	2.791	2.545	2.273	1.654
7	RMSprop	50	75	2.778	2.610	2.256	1.702
8	RMSprop	50	75	2.833	2.456	2.322	1.558
9	RMSprop	50	75	2.507	2.777	2.012	1.862
10	RMSprop	50	75	2.628	2.890	2.115	1.948
Average				2.701	2.618	2.187	1.713

Model 42

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	75	75	2.430	2.768	1.937	1.875
2	RMSprop	75	75	2.854	2.589	2.321	1.672
3	RMSprop	75	75	2.523	2.703	2.008	1.797
4	RMSprop	75	75	2.895	2.645	2.370	1.747
5	RMSprop	75	75	2.860	2.758	2.337	1.814
6	RMSprop	75	75	2.756	2.669	2.240	1.748
7	RMSprop	75	75	2.863	2.526	2.349	1.639
8	RMSprop	75	75	2.728	2.605	2.210	1.701
9	RMSprop	75	75	2.645	2.451	2.135	1.579
10	RMSprop	75	75	2.584	2.668	2.071	1.750
Average				2.714	2.638	2.198	1.732

Model 43

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	100	75	2.975	2.654	2.440	1.738
2	RMSprop	100	75	2.720	2.698	2.201	1.779
3	RMSprop	100	75	2.852	2.648	2.331	1.735
4	RMSprop	100	75	2.890	2.655	2.360	1.740
5	RMSprop	100	75	2.814	2.704	2.296	1.779
6	RMSprop	100	75	3.000	2.717	2.456	1.784
7	RMSprop	100	75	2.606	2.829	2.077	1.895
8	RMSprop	100	75	2.841	2.702	2.324	1.778
9	RMSprop	100	75	2.598	2.963	2.094	2.018
10	RMSprop	100	75	2.898	2.642	2.360	1.714
Average				2.819	2.721	2.294	1.796

Model 44

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	125	75	2.817	2.803	2.291	1.858
2	RMSprop	125	75	2.608	2.881	2.097	1.947
3	RMSprop	125	75	2.908	2.686	2.373	1.765
4	RMSprop	125	75	2.816	2.673	2.296	1.759
5	RMSprop	125	75	2.582	2.771	2.072	1.853
6	RMSprop	125	75	2.697	2.813	2.190	1.881
7	RMSprop	125	75	2.797	2.652	2.283	1.743
8	RMSprop	125	75	2.830	2.729	2.309	1.804
9	RMSprop	125	75	2.886	2.637	2.356	1.720
10	RMSprop	125	75	3.041	2.750	2.504	1.811
Average				2.798	2.740	2.277	1.814

Model 45

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	50	100	2.554	2.673	2.069	1.812
2	RMSprop	50	100	2.821	2.577	2.304	1.665
3	RMSprop	50	100	2.453	2.694	1.965	1.796
4	RMSprop	50	100	2.555	2.564	2.052	1.670
5	RMSprop	50	100	2.704	2.636	2.206	1.728
6	RMSprop	50	100	2.496	2.608	2.011	1.719
7	RMSprop	50	100	2.313	3.143	1.806	2.179
8	RMSprop	50	100	2.424	2.892	1.927	1.954
9	RMSprop	50	100	2.249	3.111	1.746	2.148
10	RMSprop	50	100	4.611	3.395	4.127	2.257
Average				2.718	2.829	2.221	1.893

Model 46

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	75	100	2.703	2.904	2.205	1.961
2	RMSprop	75	100	2.734	2.674	2.235	1.758
3	RMSprop	75	100	2.397	2.848	1.911	1.934
4	RMSprop	75	100	2.783	2.805	2.276	1.860
5	RMSprop	75	100	2.616	2.816	2.116	1.878
6	RMSprop	75	100	2.507	2.638	2.024	1.741
7	RMSprop	75	100	2.507	2.782	2.011	1.851
8	RMSprop	75	100	2.818	2.653	2.317	1.750
9	RMSprop	75	100	2.484	2.876	1.985	1.946
10	RMSprop	75	100	2.417	2.981	1.926	2.035
Average				2.597	2.798	2.101	1.871

Model 47

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	100	100	2.878	2.557	2.363	1.647
2	RMSprop	100	100	2.602	2.677	2.107	1.777
3	RMSprop	100	100	2.497	3.074	1.992	2.107
4	RMSprop	100	100	2.489	3.214	1.982	2.218
5	RMSprop	100	100	2.578	2.917	2.087	1.984
6	RMSprop	100	100	2.474	2.574	1.979	1.638
7	RMSprop	100	100	2.520	2.943	2.014	1.995
8	RMSprop	100	100	2.834	2.691	2.325	1.777
9	RMSprop	100	100	2.584	2.875	2.091	1.938
10	RMSprop	100	100	2.842	2.647	2.335	1.742
Average				2.630	2.817	2.128	1.882

Model 48

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	125	100	2.516	3.018	2.011	2.051
2	RMSprop	125	100	2.602	2.942	2.102	1.989
3	RMSprop	125	100	2.605	2.978	2.110	2.018
4	RMSprop	125	100	2.912	2.791	2.404	1.853
5	RMSprop	125	100	2.620	2.881	2.115	1.944
6	RMSprop	125	100	2.459	2.951	1.971	2.019
7	RMSprop	125	100	2.735	2.896	2.229	1.955
8	RMSprop	125	100	2.806	2.726	2.306	1.811
9	RMSprop	125	100	2.630	2.893	2.126	1.948
10	RMSprop	125	100	2.838	2.696	2.332	1.783
Average				2.672	2.877	2.171	1.937

2 Hidden Layer

Model 49

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	50	25	2.786	3.341	2.113	2.151
2	Adam	50	25	2.786	3.343	2.116	2.166
3	Adam	50	25	2.788	3.360	2.110	2.184
4	Adam	50	25	2.672	3.255	2.017	2.091
5	Adam	50	25	2.689	3.325	2.027	2.156
6	Adam	50	25	2.791	3.408	2.123	2.204
7	Adam	50	25	2.822	3.460	2.133	2.236
8	Adam	50	25	2.784	3.366	2.133	2.175
9	Adam	50	25	2.867	3.503	2.172	2.275
10	Adam	50	25	2.733	3.409	2.098	2.204
Average				2.772	3.377	2.104	2.184

Model 50

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	75	25	2.747	3.326	2.081	2.143
2	Adam	75	25	2.724	3.236	2.070	2.064
3	Adam	75	25	2.688	3.206	2.038	2.039
4	Adam	75	25	2.764	3.377	2.105	2.163
5	Adam	75	25	2.744	3.177	2.106	2.007
6	Adam	75	25	2.843	3.513	2.162	2.261
7	Adam	75	25	2.739	3.307	2.086	2.095
8	Adam	75	25	2.850	3.503	2.167	2.257
9	Adam	75	25	2.728	3.135	2.086	1.993
10	Adam	75	25	2.656	3.192	2.019	2.039
Average				2.748	3.297	2.092	2.106

Model 51

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	100	25	2.956	3.285	2.296	2.079
2	Adam	100	25	2.991	3.161	2.340	1.998
3	Adam	100	25	2.985	3.208	2.329	2.029
4	Adam	100	25	2.935	3.199	2.286	2.022
5	Adam	100	25	2.968	3.237	2.319	2.041
6	Adam	100	25	2.933	3.194	2.285	2.019
7	Adam	100	25	2.932	3.200	2.292	2.019
8	Adam	100	25	2.971	3.172	2.318	1.997
9	Adam	100	25	2.970	3.116	2.333	1.964
10	Adam	100	25	2.766	3.070	2.136	1.932
Average				2.941	3.184	2.293	2.010

Model 52

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	125	25	2.967	3.257	2.319	2.060
2	Adam	125	25	2.935	3.146	2.301	1.976
3	Adam	125	25	2.947	3.198	2.306	2.006
4	Adam	125	25	3.019	3.308	2.364	2.084
5	Adam	125	25	2.970	3.200	2.328	2.027
6	Adam	125	25	3.005	3.243	2.351	2.056
7	Adam	125	25	2.924	3.17	2.292	2.000
8	Adam	125	25	3.003	3.335	2.342	2.106
9	Adam	125	25	3.034	3.314	2.376	2.093
10	Adam	125	25	2.959	3.282	2.308	2.074
Average				2.976	3.245	2.329	2.048

Model 53

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	50	50	2.382	2.598	1.826	1.629
2	Adam	50	50	2.374	2.631	1.822	1.645
3	Adam	50	50	2.374	2.606	1.827	1.632
4	Adam	50	50	2.393	2.631	1.829	1.654
5	Adam	50	50	2.472	2.649	1.908	1.656
6	Adam	50	50	2.344	2.598	1.787	1.631
7	Adam	50	50	2.118	2.575	1.573	1.617
8	Adam	50	50	2.207	2.608	1.657	1.634
9	Adam	50	50	2.417	2.669	1.855	1.668
10	Adam	50	50	2.418	2.642	1.852	1.645
Average				2.350	2.621	1.794	1.641

Model 54

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	75	50	2.154	2.594	1.586	1.625
2	Adam	75	50	2.514	2.690	1.969	1.683
3	Adam	75	50	2.486	2.753	1.917	1.727
4	Adam	75	50	2.523	2.698	1.972	1.689
5	Adam	75	50	2.122	2.609	1.556	1.631
6	Adam	75	50	2.428	2.618	1.871	1.635
7	Adam	75	50	2.211	2.633	1.644	1.656
8	Adam	75	50	2.187	2.66	1.603	1.672
9	Adam	75	50	2.477	2.63	1.926	1.644
10	Adam	75	50	2.813	2.690	2.249	1.689
Average				2.392	2.658	1.829	1.665

Model 55

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	100	50	2.693	2.821	2.139	1.793
2	Adam	100	50	2.430	2.634	1.876	1.654
3	Adam	100	50	2.618	2.718	2.062	1.706
4	Adam	100	50	2.611	2.76	2.049	1.740
5	Adam	100	50	2.560	2.651	2.017	1.674
6	Adam	100	50	2.367	2.655	1.821	1.661
7	Adam	100	50	2.600	2.702	2.051	1.695
8	Adam	100	50	2.557	2.672	2.012	1.679
9	Adam	100	50	2.536	2.727	1.967	1.715
10	Adam	100	50	2.532	2.684	1.975	1.676
Average				2.550	2.702	1.997	1.699

Model 56

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	125	50	2.349	2.668	1.800	1.672
2	Adam	125	50	2.098	2.548	1.544	1.595
3	Adam	125	50	2.498	2.666	1.948	1.681
4	Adam	125	50	2.491	2.681	1.936	1.683
5	Adam	125	50	2.271	2.578	1.73	1.630
6	Adam	125	50	2.443	2.616	1.893	1.656
7	Adam	125	50	2.555	2.686	1.998	1.687
8	Adam	125	50	2.702	2.764	2.141	1.75
9	Adam	125	50	2.625	2.739	2.074	1.725
10	Adam	125	50	2.401	2.681	1.845	1.683
Average				2.443	2.663	1.891	1.676

Model 57

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	50	75	2.432	2.473	1.909	1.548
2	Adam	50	75	2.313	2.512	1.780	1.583
3	Adam	50	75	2.331	2.563	1.797	1.600
4	Adam	50	75	2.223	2.446	1.710	1.543
5	Adam	50	75	2.310	2.476	1.786	1.552
6	Adam	50	75	2.359	2.488	1.827	1.570
7	Adam	50	75	2.230	2.418	1.722	1.516
8	Adam	50	75	2.186	2.399	1.664	1.512
9	Adam	50	75	2.216	2.438	1.697	1.529
10	Adam	50	75	2.003	2.331	1.477	1.471
Average				2.260	2.454	1.737	1.542

Model 58

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	75	75	2.298	2.568	1.776	1.611
2	Adam	75	75	2.111	2.522	1.544	1.596
3	Adam	75	75	2.452	2.53	1.925	1.587
4	Adam	75	75	2.438	2.578	1.908	1.617
5	Adam	75	75	2.395	2.502	1.878	1.565
6	Adam	75	75	3.050	2.882	2.518	1.844
7	Adam	75	75	2.443	2.588	1.905	1.620
8	Adam	75	75	2.033	2.429	1.510	1.515
9	Adam	75	75	2.498	2.464	1.965	1.563
10	Adam	75	75	2.362	2.512	1.836	1.570
Average				2.408	2.558	1.877	1.609

Model 59

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	100	75	2.437	2.557	1.916	1.601
2	Adam	100	75	2.572	2.576	2.052	1.615
3	Adam	100	75	2.256	2.654	1.707	1.736
4	Adam	100	75	2.742	2.679	2.211	1.694
5	Adam	100	75	2.698	2.643	2.173	1.665
6	Adam	100	75	2.686	2.618	2.156	1.641
7	Adam	100	75	2.712	2.676	2.188	1.691
8	Adam	100	75	2.979	2.743	2.452	1.738
9	Adam	100	75	2.498	2.606	1.963	1.627
10	Adam	100	75	2.595	2.589	2.075	1.626
Average				2.618	2.634	2.089	1.663

Model 60

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	125	75	2.357	2.502	1.842	1.566
2	Adam	125	75	3.390	3.368	2.805	2.344
3	Adam	125	75	2.611	2.706	2.095	1.705
4	Adam	125	75	2.543	2.637	2.021	1.656
5	Adam	125	75	2.507	2.579	1.986	1.614
6	Adam	125	75	2.517	2.637	1.990	1.660
7	Adam	125	75	2.261	2.496	1.741	1.560
8	Adam	125	75	2.329	2.519	1.808	1.579
9	Adam	125	75	2.858	2.964	2.283	2.012
10	Adam	125	75	2.040	2.452	1.515	1.538
Average				2.541	2.686	2.009	1.723

Model 61

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	50	100	2.147	2.354	1.657	1.478
2	Adam	50	100	3.059	2.493	2.540	1.593
3	Adam	50	100	3.239	3.996	2.620	2.891
4	Adam	50	100	2.016	2.425	1.484	1.546
5	Adam	50	100	2.246	2.671	1.696	1.766
6	Adam	50	100	2.202	2.413	1.702	1.520
7	Adam	50	100	2.789	3.047	2.226	2.108
8	Adam	50	100	1.968	2.291	1.489	1.425
9	Adam	50	100	2.693	2.554	2.199	1.602
10	Adam	50	100	1.929	2.318	1.423	1.467
Average				2.429	2.656	1.904	1.740

Model 62

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	75	100	2.180	2.372	1.681	1.506
2	Adam	75	100	2.036	2.343	1.538	1.478
3	Adam	75	100	2.108	2.488	1.545	1.603
4	Adam	75	100	2.705	2.548	2.203	1.597
5	Adam	75	100	2.439	2.660	1.925	1.682
6	Adam	75	100	2.289	3.391	1.682	2.382
7	Adam	75	100	1.993	2.452	1.463	1.574
8	Adam	75	100	2.428	2.474	1.926	1.551
9	Adam	75	100	3.520	2.798	3.016	1.797
10	Adam	75	100	1.963	2.327	1.464	1.467
Average				2.366	2.585	1.844	1.664

Model 63

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	100	100	1.958	2.382	1.432	1.521
2	Adam	100	100	3.036	3.062	2.475	2.105
3	Adam	100	100	2.557	2.936	2.011	1.851
4	Adam	100	100	3.704	3.212	3.197	2.135
5	Adam	100	100	2.336	2.460	1.824	1.544
6	Adam	100	100	2.070	2.382	1.576	1.522
7	Adam	100	100	2.280	2.417	1.779	1.518
8	Adam	100	100	2.036	2.440	1.534	1.540
9	Adam	100	100	1.887	2.347	1.383	1.471
10	Adam	100	100	2.026	2.428	1.472	1.549
Average				2.389	2.607	1.868	1.676

Model 64

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	125	100	2.333	2.490	1.825	1.564
2	Adam	125	100	2.641	2.558	2.140	1.614
3	Adam	125	100	2.393	2.520	1.885	1.577
4	Adam	125	100	2.352	2.436	1.856	1.534
5	Adam	125	100	2.005	2.399	1.483	1.517
6	Adam	125	100	2.040	2.387	1.523	1.507
7	Adam	125	100	2.424	2.453	1.904	1.579
8	Adam	125	100	2.461	2.434	1.956	1.554
9	Adam	125	100	2.025	2.358	1.519	1.478
10	Adam	125	100	2.705	3.412	2.080	2.146
Average				2.338	2.545	1.817	1.607

Model 65

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	50	25	3.190	3.982	2.432	2.663
2	Adamax	50	25	3.211	4.071	2.460	2.727
3	Adamax	50	25	3.392	4.235	2.598	2.838
4	Adamax	50	25	3.389	4.265	2.598	2.858
5	Adamax	50	25	3.469	4.342	2.66	2.919
6	Adamax	50	25	3.321	4.189	2.548	2.816
7	Adamax	50	25	3.349	4.204	2.566	2.824
8	Adamax	50	25	3.334	4.224	2.554	2.829
9	Adamax	50	25	3.337	4.248	2.551	2.838
10	Adamax	50	25	3.329	4.193	2.559	2.821
Average				3.332	4.195	2.553	2.813

Model 66

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	75	25	3.312	4.207	2.529	2.805
2	Adamax	75	25	3.359	4.208	2.566	2.808
3	Adamax	75	25	3.262	4.124	2.490	2.753
4	Adamax	75	25	3.288	4.142	2.510	2.758
5	Adamax	75	25	3.212	4.030	2.450	2.687
6	Adamax	75	25	3.258	4.083	2.483	2.719
7	Adamax	75	25	3.300	4.135	2.519	2.766
8	Adamax	75	25	3.279	4.132	2.505	2.759
9	Adamax	75	25	3.228	4.032	2.455	2.688
10	Adamax	75	25	3.323	4.160	2.543	2.777
Average				3.282	4.125	2.505	2.752

Model 67

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	100	25	3.254	4.071	2.487	2.709
2	Adamax	100	25	3.311	4.146	2.528	2.750
3	Adamax	100	25	3.214	4.020	2.450	2.671
4	Adamax	100	25	3.272	4.103	2.494	2.734
5	Adamax	100	25	3.217	4.012	2.452	2.660
6	Adamax	100	25	3.203	4.037	2.442	2.678
7	Adamax	100	25	3.280	4.114	2.503	2.734
8	Adamax	100	25	3.313	4.148	2.529	2.756
9	Adamax	100	25	3.158	3.884	2.401	2.569
10	Adamax	100	25	3.081	3.792	2.340	2.511
Average				3.230	4.033	2.463	2.677

Model 68

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	125	25	3.162	3.945	2.407	2.619
2	Adamax	125	25	3.108	3.913	2.367	2.580
3	Adamax	125	25	3.126	3.93	2.383	2.599
4	Adamax	125	25	3.155	3.942	2.402	2.609
5	Adamax	125	25	3.232	4.039	2.460	2.673
6	Adamax	125	25	3.237	4.046	2.467	2.686
7	Adamax	125	25	3.092	3.856	2.350	2.544
8	Adamax	125	25	3.180	3.918	2.419	2.596
9	Adamax	125	25	3.293	4.109	2.513	2.726
10	Adamax	125	25	3.044	3.801	2.311	2.504
Average				3.163	3.950	2.408	2.614

Model 69

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	50	50	3.046	3.782	2.309	2.490
2	Adamax	50	50	2.967	3.530	2.247	2.33
3	Adamax	50	50	2.866	3.565	2.164	2.344
4	Adamax	50	50	2.888	3.552	2.182	2.340
5	Adamax	50	50	2.867	3.596	2.166	2.364
6	Adamax	50	50	2.936	3.702	2.216	2.433
7	Adamax	50	50	3.055	3.880	2.317	2.552
8	Adamax	50	50	3.174	3.927	2.411	2.601
9	Adamax	50	50	3.187	3.998	2.423	2.644
10	Adamax	50	50	3.194	3.928	2.430	2.603
Average				3.018	3.746	2.287	2.470

Model 70

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	75	50	2.851	3.566	2.155	2.332
2	Adamax	75	50	2.911	3.618	2.200	2.371
3	Adamax	75	50	2.991	3.721	2.265	2.450
4	Adamax	75	50	3.089	3.827	2.343	2.525
5	Adamax	75	50	2.818	3.474	2.118	2.279
6	Adamax	75	50	2.955	3.647	2.236	2.400
7	Adamax	75	50	2.940	3.650	2.220	2.401
8	Adamax	75	50	3.029	3.720	2.297	2.447
9	Adamax	75	50	2.935	3.644	2.220	2.400
10	Adamax	75	50	2.913	3.559	2.202	2.337
Average				2.943	3.643	2.226	2.394

Model 71

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	100	50	2.756	3.434	2.078	2.248
2	Adamax	100	50	2.876	3.528	2.173	2.318
3	Adamax	100	50	2.535	3.013	1.886	1.947
4	Adamax	100	50	2.761	3.421	2.079	2.242
5	Adamax	100	50	2.850	3.499	2.150	2.288
6	Adamax	100	50	3.000	3.741	2.276	2.461
7	Adamax	100	50	2.851	3.521	2.150	2.313
8	Adamax	100	50	2.776	3.372	2.089	2.205
9	Adamax	100	50	2.796	3.453	2.108	2.257
10	Adamax	100	50	2.866	3.526	2.164	2.317
Average				2.807	3.451	2.115	2.260

Model 72

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	125	50	2.787	3.393	2.105	2.221
2	Adamax	125	50	2.625	3.145	1.972	2.035
3	Adamax	125	50	2.794	3.432	2.108	2.243
4	Adamax	125	50	2.637	3.156	1.980	2.059
5	Adamax	125	50	2.810	3.454	2.113	2.261
6	Adamax	125	50	2.741	3.373	2.061	2.203
7	Adamax	125	50	2.743	3.380	2.066	2.209
8	Adamax	125	50	2.822	3.473	2.133	2.274
9	Adamax	125	50	2.857	3.564	2.156	2.335
10	Adamax	125	50	2.770	3.449	2.089	2.260
Average				2.759	3.382	2.078	2.210

Model 73

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	50	75	2.724	3.211	2.041	2.092
2	Adamax	50	75	2.488	2.833	1.844	1.810
3	Adamax	50	75	2.707	3.396	2.043	2.214
4	Adamax	50	75	2.208	2.386	1.485	1.506
5	Adamax	50	75	2.653	3.229	1.992	2.094
6	Adamax	50	75	2.541	3.075	1.903	1.995
7	Adamax	50	75	2.553	3.042	1.911	1.963
8	Adamax	50	75	2.228	2.564	1.632	1.614
9	Adamax	50	75	2.582	3.172	1.935	2.057
10	Adamax	50	75	2.540	3.005	1.894	1.946
Average				2.522	2.991	1.868	1.929

Model 74

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	75	75	2.326	2.719	1.717	1.726
2	Adamax	75	75	2.424	2.752	1.793	1.734
3	Adamax	75	75	2.346	2.831	1.728	1.790
4	Adamax	75	75	2.622	3.166	1.963	2.046
5	Adamax	75	75	2.190	2.640	1.615	1.672
6	Adamax	75	75	2.437	2.817	1.806	1.822
7	Adamax	75	75	2.408	2.875	1.784	1.834
8	Adamax	75	75	2.489	2.981	1.858	1.918
9	Adamax	75	75	2.585	3.132	1.923	2.000
10	Adamax	75	75	2.366	2.71	1.752	1.722
Average				2.419	2.862	1.794	1.826

Model 75

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	100	75	2.286	2.650	1.688	1.671
2	Adamax	100	75	2.342	2.695	1.736	1.704
3	Adamax	100	75	2.089	2.540	1.544	1.595
4	Adamax	100	75	2.336	2.736	1.737	1.741
5	Adamax	100	75	2.265	2.645	1.668	1.664
6	Adamax	100	75	2.442	2.859	1.814	1.843
7	Adamax	100	75	2.265	2.752	1.675	1.723
8	Adamax	100	75	2.379	2.837	1.760	1.809
9	Adamax	100	75	2.161	2.555	1.593	1.607
10	Adamax	100	75	2.142	2.498	1.562	1.562
Average				2.271	2.677	1.678	1.692

Model 76

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	125	75	2.163	2.477	1.588	1.564
2	Adamax	125	75	2.262	2.63	1.669	1.643
3	Adamax	125	75	2.173	2.545	1.603	1.598
4	Adamax	125	75	2.243	2.672	1.654	1.67
5	Adamax	125	75	2.196	2.538	1.617	1.588
6	Adamax	125	75	2.137	2.606	1.593	1.617
7	Adamax	125	75	2.255	2.602	1.671	1.624
8	Adamax	125	75	2.307	2.711	1.707	1.706
9	Adamax	125	75	2.167	2.562	1.602	1.602
10	Adamax	125	75	2.136	2.55	1.576	1.595
Average				2.204	2.589	1.628	1.621

Model 77

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	50	100	2.231	2.616	1.644	1.647
2	Adamax	50	100	2.282	2.683	1.683	1.689
3	Adamax	50	100	2.310	2.697	1.705	1.695
4	Adamax	50	100	2.336	2.672	1.726	1.660
5	Adamax	50	100	2.169	2.555	1.595	1.608
6	Adamax	50	100	2.152	2.532	1.585	1.589
7	Adamax	50	100	2.182	2.518	1.610	1.593
8	Adamax	50	100	2.300	2.690	1.696	1.681
9	Adamax	50	100	2.181	2.514	1.605	1.585
10	Adamax	50	100	2.364	2.798	1.750	1.787
Average				2.251	2.628	1.660	1.653

Model 78

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	75	100	2.115	2.446	1.557	1.536
2	Adamax	75	100	2.162	2.555	1.603	1.605
3	Adamax	75	100	2.084	2.438	1.539	1.531
4	Adamax	75	100	2.207	2.561	1.630	1.603
5	Adamax	75	100	2.135	2.493	1.576	1.561
6	Adamax	75	100	2.202	2.580	1.628	1.620
7	Adamax	75	100	2.076	2.445	1.536	1.558
8	Adamax	75	100	2.166	2.519	1.590	1.583
9	Adamax	75	100	2.121	2.499	1.566	1.558
10	Adamax	75	100	2.193	2.575	1.614	1.624
Average				2.146	2.511	1.584	1.578

Model 79

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	100	100	2.103	2.439	1.567	1.551
2	Adamax	100	100	2.131	2.461	1.594	1.560
3	Adamax	100	100	2.164	2.568	1.599	1.602
4	Adamax	100	100	2.158	2.499	1.612	1.590
5	Adamax	100	100	2.062	2.344	1.536	1.484
6	Adamax	100	100	2.040	2.315	1.547	1.472
7	Adamax	100	100	2.037	2.405	1.519	1.528
8	Adamax	100	100	2.036	2.372	1.523	1.502
9	Adamax	100	100	2.036	2.377	1.516	1.482
10	Adamax	100	100	2.208	2.68	1.635	1.675
Average				2.098	2.446	1.565	1.545

Model 80

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adamax	125	100	2.140	2.424	1.622	1.535
2	Adamax	125	100	2.152	2.423	1.620	1.525
3	Adamax	125	100	2.180	2.508	1.634	1.588
4	Adamax	125	100	2.162	2.462	1.644	1.551
5	Adamax	125	100	2.186	2.538	1.635	1.601
6	Adamax	125	100	2.144	2.46	1.606	1.554
7	Adamax	125	100	2.183	2.511	1.636	1.584
8	Adamax	125	100	2.109	2.432	1.585	1.544
9	Adamax	125	100	2.140	2.389	1.614	1.523
10	Adamax	125	100	2.103	2.466	1.570	1.548
Average				2.150	2.461	1.617	1.555

Model 81

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	50	25	4.115	3.303	3.411	2.155
2	RMSprop	50	25	3.872	3.056	3.203	1.988
3	RMSprop	50	25	4.030	3.233	3.339	2.103
4	RMSprop	50	25	3.816	3.024	3.157	1.976
5	RMSprop	50	25	3.785	2.936	3.140	1.900
6	RMSprop	50	25	3.971	3.126	3.301	2.032
7	RMSprop	50	25	4.060	3.197	3.378	2.086
8	RMSprop	50	25	4.121	3.288	3.429	2.136
9	RMSprop	50	25	4.145	3.303	3.452	2.157
10	RMSprop	50	25	4.155	3.256	3.457	2.120
Average				4.007	3.172	3.327	2.065

Model 82

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	75	25	4.140	3.222	3.441	2.108
2	RMSprop	75	25	4.176	3.241	3.483	2.117
3	RMSprop	75	25	4.233	3.251	3.537	2.120
4	RMSprop	75	25	4.082	3.170	3.399	2.068
5	RMSprop	75	25	4.271	3.320	3.562	2.172
6	RMSprop	75	25	3.968	3.099	3.296	2.021
7	RMSprop	75	25	4.077	3.140	3.390	2.046
8	RMSprop	75	25	3.807	2.985	3.142	1.969
9	RMSprop	75	25	4.309	3.354	3.61	2.194
10	RMSprop	75	25	3.932	2.997	3.264	1.958
Average				4.100	3.178	3.412	2.077

Model 83

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	100	25	4.252	3.255	3.558	2.131
2	RMSprop	100	25	4.163	3.174	3.477	2.084
3	RMSprop	100	25	4.400	3.341	3.692	2.187
4	RMSprop	100	25	4.317	3.326	3.606	2.186
5	RMSprop	100	25	4.355	3.295	3.650	2.162
6	RMSprop	100	25	4.322	3.315	3.615	2.173
7	RMSprop	100	25	4.205	3.161	3.515	2.072
8	RMSprop	100	25	4.338	3.300	3.635	2.167
9	RMSprop	100	25	4.174	3.161	3.487	2.069
10	RMSprop	100	25	3.995	2.986	3.329	1.959
Average				4.252	3.231	3.556	2.119

Model 84

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	125	25	4.450	3.375	3.731	2.229
2	RMSprop	125	25	4.395	3.322	3.684	2.196
3	RMSprop	125	25	4.263	3.226	3.570	2.126
4	RMSprop	125	25	4.464	3.355	3.749	2.209
5	RMSprop	125	25	4.356	3.293	3.648	2.174
6	RMSprop	125	25	4.512	3.389	3.799	2.235
7	RMSprop	125	25	4.544	3.408	3.826	2.255
8	RMSprop	125	25	4.389	3.298	3.679	2.177
9	RMSprop	125	25	4.469	3.368	3.753	2.225
10	RMSprop	125	25	4.467	3.358	3.752	2.209
Average				4.431	3.339	3.719	2.204

Model 85

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	50	50	2.991	2.672	2.423	1.749
2	RMSprop	50	50	2.945	2.543	2.402	1.640
3	RMSprop	50	50	3.689	2.844	3.111	1.828
4	RMSprop	50	50	4.656	3.232	4.071	2.087
5	RMSprop	50	50	2.916	2.582	2.360	1.676
6	RMSprop	50	50	3.535	2.746	2.965	1.766
7	RMSprop	50	50	3.440	2.787	2.856	1.803
8	RMSprop	50	50	3.156	2.893	2.548	1.939
9	RMSprop	50	50	3.217	3.572	2.655	1.657
10	RMSprop	50	50	4.061	2.786	3.495	1.786
Average				3.461	2.866	2.889	1.793

Model 86

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	75	50	3.334	2.747	2.751	1.801
2	RMSprop	75	50	3.310	2.759	2.719	1.803
3	RMSprop	75	50	3.031	2.718	2.463	1.775
4	RMSprop	75	50	3.165	2.701	2.593	1.753
5	RMSprop	75	50	3.141	2.652	2.572	1.724
6	RMSprop	75	50	3.323	2.781	2.734	1.817
7	RMSprop	75	50	3.154	2.816	2.573	1.852
8	RMSprop	75	50	3.434	2.734	2.851	1.760
9	RMSprop	75	50	3.460	2.777	2.873	1.808
10	RMSprop	75	50	3.280	2.698	2.701	1.756
Average				3.263	2.738	2.683	1.785

Model 87

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	100	50	3.547	2.842	2.947	1.869
2	RMSprop	100	50	3.514	2.808	2.912	1.840
3	RMSprop	100	50	3.385	2.823	2.789	1.855
4	RMSprop	100	50	3.572	2.855	2.970	1.875
5	RMSprop	100	50	3.351	2.870	2.754	1.891
6	RMSprop	100	50	3.434	2.843	2.838	1.865
7	RMSprop	100	50	3.280	2.800	2.690	1.847
8	RMSprop	100	50	3.469	2.842	2.874	1.870
9	RMSprop	100	50	3.606	2.889	2.992	1.902
10	RMSprop	100	50	3.639	2.892	3.031	1.906
Average				3.480	2.846	2.880	1.872

Model 88

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	125	50	3.619	2.933	3.006	1.938
2	RMSprop	125	50	3.705	2.942	3.095	1.942
3	RMSprop	125	50	3.629	2.893	3.027	1.905
4	RMSprop	125	50	3.543	2.897	2.934	1.913
5	RMSprop	125	50	3.716	2.923	3.106	1.926
6	RMSprop	125	50	3.460	2.864	2.863	1.897
7	RMSprop	125	50	3.626	2.885	3.023	1.903
8	RMSprop	125	50	3.781	2.969	3.158	1.966
9	RMSprop	125	50	3.679	2.955	3.062	1.951
10	RMSprop	125	50	3.484	2.903	2.882	1.912
Average				3.624	2.916	3.016	1.925

Model 89

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	50	75	2.447	2.562	1.925	1.696
2	RMSprop	50	75	2.431	2.760	1.910	1.850
3	RMSprop	50	75	2.773	2.560	2.241	1.648
4	RMSprop	50	75	2.606	2.719	2.072	1.806
5	RMSprop	50	75	2.736	2.527	2.209	1.632
6	RMSprop	50	75	2.826	2.572	2.293	1.661
7	RMSprop	50	75	2.643	2.732	2.112	1.811
8	RMSprop	50	75	2.902	2.595	2.366	1.672
9	RMSprop	50	75	2.519	2.894	1.988	1.948
10	RMSprop	50	75	2.545	2.742	2.029	1.835
Average				2.643	2.666	2.115	1.756

Model 90

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	75	75	2.655	2.924	2.125	1.974
2	RMSprop	75	75	2.719	2.907	2.190	1.964
3	RMSprop	75	75	2.562	3.135	2.035	2.145
4	RMSprop	75	75	2.650	2.955	2.130	2.001
5	RMSprop	75	75	2.643	2.853	2.108	1.920
6	RMSprop	75	75	2.692	2.837	2.157	1.899
7	RMSprop	75	75	2.639	2.920	2.118	1.970
8	RMSprop	75	75	2.671	2.995	2.134	2.024
9	RMSprop	75	75	2.634	2.866	2.102	1.923
10	RMSprop	75	75	2.581	2.992	2.043	2.037
Average				2.645	2.938	2.114	1.986

Model 91

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	100	75	2.785	3.064	2.250	2.074
2	RMSprop	100	75	2.689	3.04	2.159	2.067
3	RMSprop	100	75	2.861	3.032	2.333	2.048
4	RMSprop	100	75	2.760	2.976	2.224	2.009
5	RMSprop	100	75	2.788	2.923	2.264	1.963
6	RMSprop	100	75	2.698	2.93	2.167	1.970
7	RMSprop	100	75	2.704	2.988	2.180	2.021
8	RMSprop	100	75	2.680	3.026	2.150	2.048
9	RMSprop	100	75	2.674	3.138	2.151	2.153
10	RMSprop	100	75	2.799	2.996	2.270	2.021
Average				2.744	3.011	2.215	2.037

Model 92

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	125	75	2.759	3.137	2.221	2.143
2	RMSprop	125	75	2.843	3.098	2.316	2.104
3	RMSprop	125	75	2.783	3.114	2.257	2.126
4	RMSprop	125	75	2.833	3.130	2.293	2.131
5	RMSprop	125	75	2.857	3.131	2.312	2.125
6	RMSprop	125	75	2.817	3.033	2.292	2.053
7	RMSprop	125	75	2.782	3.167	2.252	2.162
8	RMSprop	125	75	2.948	3.092	2.408	2.09
9	RMSprop	125	75	2.821	3.080	2.284	2.092
10	RMSprop	125	75	2.263	3.249	2.086	2.245
Average				2.771	3.123	2.272	2.127

Model 93

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	50	100	2.243	2.769	1.747	1.882
2	RMSprop	50	100	2.317	2.863	1.828	1.952
3	RMSprop	50	100	2.239	2.790	1.746	1.894
4	RMSprop	50	100	2.343	2.768	1.852	1.867
5	RMSprop	50	100	2.249	2.805	1.754	1.902
6	RMSprop	50	100	2.300	2.855	1.800	1.939
7	RMSprop	50	100	2.322	2.789	1.812	1.867
8	RMSprop	50	100	2.289	2.897	1.786	1.976
9	RMSprop	50	100	2.452	2.977	1.949	2.031
10	RMSprop	50	100	2.376	2.900	1.881	1.966
Average				2.313	2.841	1.916	2.028

Model 94

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	75	100	2.406	3.403	1.876	2.392
2	RMSprop	75	100	2.441	3.366	1.915	2.344
3	RMSprop	75	100	2.402	3.302	1.888	2.304
4	RMSprop	75	100	2.462	3.185	1.943	2.200
5	RMSprop	75	100	2.418	3.278	1.897	2.277
6	RMSprop	75	100	2.495	3.433	1.966	2.394
7	RMSprop	75	100	2.405	3.348	1.888	2.343
8	RMSprop	75	100	2.438	3.075	1.925	2.111
9	RMSprop	75	100	2.465	3.374	1.935	2.354
10	RMSprop	75	100	2.435	3.427	1.905	2.405
Average				2.437	3.319	1.914	2.312

Model 95

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	100	100	2.488	3.379	1.964	2.363
2	RMSprop	100	100	2.450	3.437	1.910	2.410
3	RMSprop	100	100	2.567	3.355	2.052	2.334
4	RMSprop	100	100	2.493	3.277	1.983	2.281
5	RMSprop	100	100	2.498	3.503	1.952	2.463
6	RMSprop	100	100	2.516	3.326	1.989	2.312
7	RMSprop	100	100	2.465	3.397	1.937	2.377
8	RMSprop	100	100	2.596	3.229	2.073	2.226
9	RMSprop	100	100	2.525	3.363	2.002	2.345
10	RMSprop	100	100	2.538	3.398	2.014	2.366
Average				2.514	3.366	1.988	2.348

Model 96

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	RMSprop	125	100	2.568	3.452	2.034	2.413
2	RMSprop	125	100	2.588	3.423	2.057	2.382
3	RMSprop	125	100	2.514	3.387	1.990	2.369
4	RMSprop	125	100	2.556	3.524	2.017	2.464
5	RMSprop	125	100	2.572	3.377	2.060	2.344
6	RMSprop	125	100	2.531	3.513	1.988	2.464
7	RMSprop	125	100	2.522	3.454	1.997	2.422
8	RMSprop	125	100	2.549	3.452	2.023	2.409
9	RMSprop	125	100	2.522	3.441	1.985	2.407
10	RMSprop	125	100	2.639	3.325	2.116	2.294
Average				2.556	3.435	2.027	2.397

LAMPIRAN B. Detail Percobaan Model LSTM
12 Timewindow

Running	Optimizer	Jumlah Neuron	Jumlah Epoch	RMSE Training	RMSE Testing	MAPE Training	MAPE Testing
1	Adam	125	100	2.175	2.205	1.705	1.396
2	Adam	125	100	2.132	2.183	1.677	1.374
3	Adam	125	100	2.192	2.206	1.728	1.393
4	Adam	125	100	2.216	2.210	1.752	1.396
5	Adam	125	100	2.168	2.189	1.706	1.383
6	Adam	125	100	2.185	2.194	1.723	1.386
7	Adam	125	100	2.208	2.247	1.740	1.417
8	Adam	125	100	2.179	2.163	1.719	1.371
9	Adam	125	100	1.965	2.081	1.510	1.301
10	Adam	125	100	2.183	2.203	1.712	1.394
Average				2.160	2.188	1.697	1.381