



TUGAS AKHIR - KS 141501

PERAMALAN HARGA SAHAM BERDASARKAN FAKTOR MAKROEKONOMI MENGGUNAKAN ARSITEKTUR LONG SHORT-TERM MEMORY (STUDI KASUS: PT ASTRA INTERNATIONAL TBK.)

STOCK PRICE FORECASTING BASED ON MACROECONOMIC FACTOR USING LONG SHORT-TERM MEMORY ARCHITECTURE (CASE STUDY: PT ASTRA INTERNATIONAL TBK.)

MUSLIKH ANNUR MEIVIANANDA
NRP 05211640000092

Dosen Pembimbing :
Edwin Riksakomara, S.Kom., MT.
Faizal Mahananto, S.Kom., M.Eng., Ph.D.

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



ITS
Institut
Teknologi
Sepuluh Nopember

TUGAS AKHIR - KS 141501

PERAMALAN HARGA SAHAM BERDASARKAN FAKTOR MAKROEKONOMI MENGGUNAKAN ARSITEKTUR LONG SHORT-TERM MEMORY (STUDI KASUS: PT ASTRA INTERNATIONAL TBK.)

**MUSLIKH ANNUR MEIVIANANDA
NRP 0521164000092**

Dosen Pembimbing :
Edwin Riksakomara, S.Kom., MT.
Faizal Mahananto, S.Kom., M.Eng., Ph.D.

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



ITS
Institut
Teknologi
Sepuluh Nopember

TUGAS AKHIR - KS 141501

STOCK PRICE FORECASTING BASED ON MACROECONOMIC FACTOR USING LONG SHORT-TERM MEMORY ARCHITECTURE (CASE STUDY: PT ASTRA INTERNATIONAL TBK.)

MUSLIKH ANNUR MEIVIANANDA
NRP 05211640000092

SUPERVISOR :
Edwin Riksakomara, S.Kom., MT.
Faizal Mahananto, S.Kom., M.Eng., Ph.D.

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

LEMBAR PENGESAHAN

PERAMALAN HARGA SAHAM BERDASARKAN FAKTOR MAKROEKONOMI MENGGUNAKAN ARSITEKTUR LONG SHORT-TERM MEMORY (STUDI KASUS: PT ASTRA INTERNATIONAL TBK.)

TUGAS AKHIR

Disusun Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer (S.Kom)
pada

Departemen Sistem Informasi
Fakultas Teknologi Elektro dan Informatika Cerdas (ELECTICS)
Institut Teknologi Sepuluh Nopember

Oleh

Muslikh Annur Meiviananda
05211640000092

Surabaya, 14 Agustus 2020

Kepala Departemen Sistem Informasi

[Signature]
Dr. Mulyahidin, ST., MT.
NIP. 197010102003121001



LEMBAR PERSETUJUAN

PERAMALAN HARGA SAHAM BERDASARKAN FAKTOR MAKROEKONOMI MENGGUNAKAN ARSITEKTUR LONG SHORT-TERM MEMORY (STUDI KASUS: PT ASTRA INTERNATIONAL TBK.)

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 :

MUSLIKH ANNUR MEIVIANANDA

NRP. 0521164000092

Disetujui Tim Penguji

Tanggal Ujian
Periode Wisuda

: 15 Mei 2020

: 122

Edwin Riksakomara, S.Kom., MT.


(Pembimbing I)

Faizal Mahananto, S.Kom., M.Eng., Ph.D.


(Pembimbing II)

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


(Penguji I)

Raras Tyasnurita, S.Kom., M.BA., Ph.D.


(Penguji II)

PERAMALAN HARGA SAHAM BERDASARKAN FAKTOR MAKROEKONOMI MENGGUNAKAN ARSITEKTUR LONG SHORT-TERM MEMORY (STUDI KASUS: PT ASTRA INTERNATIONAL TBK.)

Nama Mahasiswa : Muslikh Annur Meiviananda
NRP : 05211640000092
Jurusan : Sistem Informasi FTEIC-ITS
Pembimbing 1 : Edwin Riksakomara, S.Kom., MT.
Pembimbing 2 : Faizal Mahananto, S.Kom., M.Eng, Ph.D

ABSTRAK

Investasi saham merupakan hal yang cukup menjanjikan untuk saat ini dan di masa yang akan datang. Besarnya benefit yang ditawarkan mendorong berbagai kalangan untuk mempertimbangkan investasi pada saham perusahaan. Hal tersebut dibuktikan dengan adanya peningkatan jumlah investor di Bursa Efek Indonesia (BEI) sebanyak 26% dari Juli 2015 hingga Juli 2016. Meskipun dirasa menjanjikan, terdapat banyak indikator yang mempengaruhi harga saham seperti sentimen perusahaan dan faktor makroekonomi yang beragam. Indikator seperti nilai tukar USD/IDR termasuk dalam faktor makroekonomi yang mempengaruhi harga saham perusahaan di beberapa kasus. Salah satu perusahaan dengan sentimen positif di mata masyarakat adalah PT Astra International Tbk (Astra). Astra merupakan perusahaan multinasional diversifikasi dengan tujuh segmen usaha. Astra sudah terdaftar di BEI sejak tahun 1990. Kategori saham Astra termasuk blue-chip stocks yang mana perusahaan dengan label tersebut adalah perusahaan bereputasi tinggi dengan pendapatan stabil dan konsisten dalam membayar dividen. Peramalan harga saham Astra akan membantu para investor yang ingin menanamkan modal dalam ketepatan pengambilan keputusan. Pengambilan keputusan yang baik membuat para investor dapat maksimalkan benefit dari investasi saham yakni capital gain dan dividen.

Sudah banyak metode untuk meramalkan data saham yang bersifat non-linear salah satunya Recurrent Neural Network (RNN). RNN merupakan jenis arsitektur Neural Network yang pemrosesannya dipanggil berulang-ulang. RNN terbukti sangat baik dalam memproses input berupa data time series seperti data saham. Pada penelitian kali ini, diajukan salah satu solusi yang merupakan arsitektur RNN yakni Long Short-Term Memory (LSTM). LSTM merupakan pembelajaran berbasis gradien dengan tiga gates yakni input, forget dan output.

Performa model LSTM pada peramalan harga saham Astra menggunakan faktor makroekonomi berupa nilai tukar USD/IDR menunjukkan performa yang sangat baik dibuktikan dengan Mean Absolute Percentage Error (MAPE) yang kecil. Model dengan akurasi terbaik yang dihasilkan menunjukkan peramalan saham tanpa faktor makroekonomi menghasilkan MAPE 1,3465% dan dengan faktor makroekonomi menghasilkan MAPE 1,3512%. Hasil peramalan juga menunjukkan faktor makroekonomi tidak berdampak pada performa yang lebih baik.

Kata kunci: Peramalan, Harga Saham, Makroekonomi, Long Short-Term Memory, Mean Absolute Percentage Error.

**STOCK PRICE FORECASTING BASED ON
MACROECONOMIC FACTOR USING
LONG SHORT-TERM MEMORY ARCHITECTURE
(CASE STUDY: PT ASTRA INTERNATIONAL TBK.)**

Name	: Muslikh Annur Meiviananda
NRP	: 05211640000092
Department	: Information Systems ELECTICS-ITS
Supervisor 1	: Edwin Riksakomara, S.Kom., MT.
Supervisor 2	: Faizal Mahananto, S.Kom., M.Eng, Ph.D

ABSTRACT

Stock investment is quite promising for now and in the future. The amount of benefits offered encourages various groups to consider investing in company shares. This is evidenced by an increase in the number of investors in the Indonesia Stock Exchange (IDX) by 26% from July 2015 to July 2016. Although it is considered promising, there are many indicators that affect stock prices such as corporate sentiment and various macroeconomic factors. Indicators such as the USD / IDR exchange rate are included in macroeconomic factors that affect the company's stock price in some cases. One company with positive sentiment in the eyes of the public is PT Astra International Tbk (Astra). Astra is a diversified multinational company with seven business segments. Astra has been listed on the IDX since 1990. Astra's share category includes blue-chip stocks in which companies with that label are highly-reputed companies with stable income and are consistent in paying dividends. Astra's stock price forecasting will help investors who want to invest capital in the accuracy of decision making. Good decision making allows investors to maximize the benefits of stock investments, namely capital gains and dividends.

There have been many methods for predicting non-linear stock data, one of which is the Recurrent Neural Network (RNN). RNN is a type of Neural Network architecture whose processing is

called repeatedly. RNN has proven to be very good in processing input in the form of time series data such as stock data. In this study, a solution which is an RNN architecture is proposed, namely Long Short-Term Memory (LSTM). LSTM is a gradient-based learning with three gates namely input, forget and output.

The LSTM model's performance on Astra's stock price forecasting using macroeconomic factors in the form of the USD/IDR exchange rate shows excellent performance as evidenced by the small Mean Absolute Percentage Error (MAPE). The best model produced shows stock forecasting without macroeconomic factors produces MAPE 1.3465% and with macroeconomic factors produces MAPE 1.3512%. Forecasting results also show that macroeconomic factors do not have an impact on better performance.

Keywords: *Forecasting, Stock Price, Macroeconomic, Long Short-Term Memory, Mean Absolute Percentage Error.*

SURAT PERNYATAAN BEBAS PLAGIARISME

Saya yang bertandatangan di bawah ini:

Nama : Muslikh Annur Meiviananda
NRP : 05211640000092
Tempat / Tanggal lahir : Semarang / 25 Mei 1999
Fakultas / Departemen : FTEIC / Sistem Informasi
Nomor Telp / Hp / Email : 081230994641 / muslikhannurm@gmail.com
Dengan ini menyatakan dengan sesungguhnya bahwa penelitian/makalah/tugas akhir saya yang berjudul:
PERAMALAN HARGA SAHAM BERDASARKAN FAKTOR MAKROEKONOMI MENGGUNAKAN ARSITEKTUR LONG SHORT-TERM MEMORY (STUDI KASUS: PT ASTRA INTERNATIONAL TBK.)

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.



Halaman ini sengaja dikosongkan

KATA PENGANTAR

Puji dan syukur penulis tuturkan ke hadirat Allah SWT, Tuhan Semesta Alam yang telah memberikan karunia dan hidayah-Nya kepada penulis sehingga penulis mendapatkan kelancaran dalam menyelesaikan tugas akhir dengan judul:

PERAMALAN HARGA SAHAM BERDASARKAN FAKTOR MAKROEKONOMI MENGGUNAKAN ARSITEKTUR LONG SHORT-TERM MEMORY (STUDI KASUS: PT ASTRA INTERNATIONAL TBK.)

Terima kasih penulis sampaikan kepada pihak-pihak yang telah mendukung, memberikan saran, motivasi, semangat, dan bantuan baik berupa material maupun moril demi tercapainya tujuan pembuatan tugas akhir ini. Tugas akhir ini tidak akan pernah terwujud tanpa bantuan dan dukungan dari berbagai pihak yang sudah meluangkan waktu, tenaga dan pikirannya. Secara khusus penulis akan menyampaikan ucapan terima kasih yang sebanyak-banyaknya kepada :

1. Bapak Agus Marsudiono dan Ibu Asriati selaku kedua orang tua dari penulis serta Mbak Syl, Mbak Devi dan Dek Salma selaku saudara kandung yang selalu memberi dukungan.
2. Bapak Dr. Mudjahidin, S.T., M.T. selaku Kepala Departemen Sistem Informasi FTEIC ITS Surabaya.
3. Bapak Edwin Riksakomara, S.Kom., MT. dan Bapak Faizal Mahananto, S.Kom., M.Eng., Ph.D. selaku dosen pembimbing dan sebagai narasumber yang senantiasa meluangkan waktu, memberikan ilmu dan petunjuk, serta memotivasi untuk kelancaran tugas akhir penulis.
4. Bapak Ahmad Mukhlason, S.Kom., M.Sc., Ph.D. dan Ibu Raras Tyasnurita, S.Kom., M.B.A., Ph.D. selaku dosen penguji yang telah memberikan *feedback* berupa saran dan kritik untuk kebaikan penggerjaan tugas akhir.

5. Segenap dosen dan karyawan Departemen Sistem Informasi FTEIC ITS yang telah memberikan ilmu yang bermanfaat.
6. Teman 222 yakni Repa, Alana, Oki, Athma dan Ilham yang merupakan *circle* terdekat penulis sejak mahasiswa baru hingga sampai saat ini kami lulus bersama.
7. Teman Data Science SI terutama Wildan, Krisna dan Berta yang membuat penulis belajar banyak tentang ilmu data hingga menyabet beberapa prestasi di tahun keempat.
8. Mas Gamal selaku Kakak Pendamping sekaligus Kadep saya yang memberi saya banyak wawasan perkuliahan.
9. Segenap anggota SWF Prosperous HMSI ITS yang membersamai penulis dalam mensejahterakan mahasiswa.
10. Segenap anggota IT Dev. ISE 2018 yang membersamai penulis dalam belajar bersinergi dalam kepanitiaan.
11. Berbagai pihak yang tidak bisa disebutkan satu persatu yang turut serta mendukung penulis menyelesaikan Studi.

Penyusunan laporan 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, 15 Mei 2020

Penulis

DAFTAR ISI

ABSTRAK	v
ABSTRACT	vii
SURAT PERNYATAAN BEBAS PLAGIARISME	ix
KATA PENGANTAR.....	xi
DAFTAR ISI	xiii
DAFTAR GAMBAR	xvii
DAFTAR TABEL	xix
DAFTAR KODE PROGRAM.....	xxi
BAB I PENDAHULUAN	1
1.1. Latar Belakang	1
1.2. Rumusan Masalah	3
1.3. Batasan Permasalahan	4
1.4. Tujuan Penelitian.....	4
1.5. Manfaat Penelitian.....	4
1.6. Relevansi	4
BAB II TINJAUAN PUSTAKA.....	7
2.1. Penelitian Sebelumnya	7
2.2. Landasan Teori	12
2.2.1. Peramalan Time Series	12
2.2.2. Saham	13
2.2.3. Nilai Tukar Mata Uang.....	13
2.2.4. <i>Long-Short Term Memory (LSTM)</i>	13
2.2.4.1. Notasi LSTM	15
2.2.4.2. <i>Cell State</i>	16
2.2.4.3. <i>Forget Gate</i>	17
2.2.4.4. <i>Input Gate</i>	17
2.2.4.5. <i>Output Gate</i>	18
2.2.5. <i>Mean Absolute Percentage Error (MAPE)</i>	19
BAB III METODOLOGI PENELITIAN.....	21
3.1. Metodologi	21
3.2. Uraian Metodologi	22
3.2.1. Studi Literatur.....	22
3.2.2. Pengambilan Data.....	22

3.2.3.	Pra-Pemrosesan Data.....	22
3.2.3.1.	Standarisasi Data	22
3.2.3.2.	Penggabungan Data	23
3.2.3.3.	Pengikhtisaran Data.....	23
3.2.3.4.	Eliminasi Fitur	23
3.2.3.5.	Pemeriksaan <i>Missing Value</i>	23
3.2.3.6.	Pembagian Data.....	23
3.2.3.7.	Normalisasi Fitur	23
3.2.4.	Pembentukan Model.....	24
3.2.4.1.	Struktur Data Masukan dan Luaran.....	24
3.2.4.2.	Membangun Arsitektur LSTM	24
3.2.5.	Peramalan Model.....	24
3.2.6.	Evaluasi Model.....	25
3.2.6.1.	Evaluasi dengan MAPE.....	25
3.2.6.2.	<i>Tuning Parameter</i> dan Analisa Hasil	25
3.2.6.3.	Skenario Pengujian Model Terbaik	25
3.2.7.	Penyusunan Buku Tugas Akhir	26
BAB IV PERANCANGAN	27	
4.1.	Rancangan Pengambilan Data.....	27
4.2.	Rancangan Pra-pemrosesan Data	28
4.2.1.	Rancangan Standarisasi Data.....	28
4.2.2.	Rancangan Penggabungan Data	28
4.2.3.	Rancangan Pengikhtisaran Data	29
4.2.4.	Rancangan Eliminasi Fitur	29
4.2.5.	Rancangan Pemeriksaan <i>Missing Value</i>	29
4.2.6.	Rancangan Pembagian Data	30
4.2.7.	Rancangan Normalisasi Fitur	30
4.3.	Rancangan Pembentukan Model	31
4.3.1.	Rancangan Struktur Data Masukan dan Luaran ..	31
4.3.2.	Rancangan Arsitektur LSTM	32
4.4.	Rancangan Peramalan Model	35
4.5.	Rancangan Evaluasi Model	35
4.5.1.	Rancangan Evaluasi dengan MAPE	35
4.5.2.	Rancangan <i>Tuning Parameter</i>	36
4.5.3.	Rancangan Skenario Pengujian Model Terbaik ..	40

4.5.3.1.	Skenario Proporsi Pembagian Data	40
4.5.3.2.	Skenario Penggunaan <i>Dataset Lain</i>	40
4.5.3.3.	Skenario Perbandingan Metode.....	41
4.5.3.4.	Skenario Data Masa Depan	41
BAB V IMPLEMENTASI		43
5.1.	Lingkungan Implementasi.....	43
5.2.	Pengambilan Data.....	44
5.3.	Pra-Pemrosesan Data.....	46
5.3.1.	Standarisasi Data	46
5.3.2.	Penggabungan Data.....	48
5.3.3.	Pengikhtisaran Data.....	49
5.3.1.1.	Uji Korelasi	49
5.3.1.2.	Pengamatan Tren.....	50
5.3.4.	Eliminasi Fitur.....	50
5.3.5.	Pemeriksaan <i>Missing Value</i>	51
5.3.6.	Pembagian Data.....	51
5.3.6.1.	Pembagian Data Kasus Univariat	51
5.3.1.4.	Pembagian Data Kasus Multivariat	52
5.3.7.	Normalisasi Fitur	52
5.4.	Pembentukan Model.....	53
5.4.1.	Struktur Data Masukan dan Luaran.....	53
5.4.1.1.	Struktur Data Univariat	53
5.4.1.2.	Struktur Data Multivariat	54
5.4.2.	Pembentukan Arsitektur LSTM	56
5.5.	Peramalan Model.....	58
5.6.	Evaluasi Model.....	60
5.6.1.	Evaluasi dengan MAPE.....	60
5.6.2.	<i>Tuning Parameter</i>	60
5.6.3.	Skenario Pengujian Model Terbaik	61
5.6.3.1.	Skenario Proporsi Pembagian Data	61
5.6.3.2.	Skenario Penggunaan Dataset Lain	61
5.6.3.3.	Skenario Perbandingan Metode	62
BAB VI HASIL DAN PEMBAHASAN.....		63
6.1.	Hasil Pengambilan Data	63
6.1.1.	Data Nilai Tukar USD/IDR	63

6.1.2.	Data Harga Saham	64
6.2.	Hasil Pra-Pemrosesan Data	67
6.2.1.	Hasil Standarisasi Data	67
6.2.2.	Hasil Penggabungan Data	67
6.2.3.	Hasil Pengikhitasaran Data	68
6.2.3.1.	Hasil Uji Korelasi	68
6.2.3.2.	Hasil Pengamatan Tren	70
6.2.4.	Hasil Eliminasi Fitur	71
6.2.5.	Hasil Pemeriksaan <i>Missing Value</i>	72
6.2.6.	Hasil Pembagian Data	74
6.2.6.1.	Hasil Pembagian Data Kasus Univariat	74
6.2.6.2.	Hasil Pembagian Data Kasus Multivariat	74
6.2.7.	Hasil Normalisasi Fitur	74
6.3.	Hasil Peramalan Data Univariat	75
6.3.1.	Hasil Pembentukan Struktur Data Univariat	75
6.3.2.	Hasil <i>Tuning Parameter</i> Univariat	76
6.4.	Hasil Peramalan Data Multivariat	83
6.4.1.	Hasil Pembentukan Struktur Data Multivariat	83
6.4.2.	Hasil <i>Tuning Parameter</i> Multivariat	84
6.5.	Perbandingan Model Univariat dan Multivariat	90
6.5.1.	Hasil Pemilihan Model Terbaik Univariat	91
6.5.2.	Hasil Pemilihan Model Terbaik Multivariat	93
6.5.3.	Visualisasi Eksperimen dan Perbandingan	95
6.6.	Hasil Skenario Proporsi Pembagian Data	96
6.7.	Hasil Skenario Penggunaan <i>Dataset</i> Lain	99
6.8.	Hasil Skenario Perbandingan Metode	103
6.9.	Hasil Skenario Data Masa Depan	105
6.10.	Kesimpulan Hasil dan Pembahasan	107
BAB VII	KESIMPULAN DAN SARAN	111
7.1.	Kesimpulan	111
7.2.	Saran	112
DAFTAR PUSTAKA	113	
BIODATA PENULIS	117	
LAMPIRAN A	119	
LAMPIRAN B	163	

DAFTAR GAMBAR

Gambar 1.1. <i>Roadmap</i> Penelitian RDIB	5
Gambar 2.1. Perbedaan <i>Neuron</i> pada ANN dan RNN	14
Gambar 2.2. Struktur <i>Recurrent Neural Network</i> [14].....	14
Gambar 2.3. Struktur <i>Long Short-Term Memory</i> [16]	15
Gambar 2.4. Notasi LSTM [14]	15
Gambar 2.5. <i>Cell State</i> LSTM [16]	16
Gambar 2.6. <i>Forget Gate</i> LSTM [16]	17
Gambar 2.7. <i>Forget Gate</i> LSTM [16]	17
Gambar 2.8. Operasi <i>Cell State</i> LSTM [16].....	18
Gambar 2.9. <i>Output Gate</i> LSTM [16].....	18
Gambar 3.1. Metodologi Tugas Akhir	21
Gambar 4.1. Ilustrasi <i>Timestep</i>	31
Gambar 4.2. Arsitektur <i>Recurrent Model Univariat</i>	33
Gambar 4.3. Arsitektur <i>Recurrent Model Multivariat</i>	33
Gambar 4.4. Kerja <i>Hidden Node</i> Univariat.....	34
Gambar 4.5. Kerja <i>Hidden Node</i> Multivariat	34
Gambar 5.1. Grafik Saham ASII dan Nilai Tukar.....	44
Gambar 5.2. Grafik Saham KAEF dan SMGR	45
Gambar 6.1. Grafik Nilai Tukar USD/IDR	64
Gambar 6.2. Grafik Seluruh Fitur Saham.....	66
Gambar 6.3. Hasil Standarisasi Fitur Harga.....	67
Gambar 6.4. <i>Correlation Plot</i> Variabel <i>Dataframe</i> Gabungan ...	68
Gambar 6.5. <i>Correlation Plot</i> Variable Setiap <i>Dataframe</i>	69
Gambar 6.6. <i>Correlation Plot</i> untuk Fitur <i>Closed Price</i>	69
Gambar 6.7. <i>Stacked Line Chart</i> untuk Fitur <i>Closed Price</i>	70
Gambar 6.8. Pengecekan <i>Missing Value</i> sebelum <i>Treatment</i>	72
Gambar 6.9. Pengecekan <i>Missing Value</i> setelah <i>Treatment</i>	73
Gambar 6.10. Model Terbaik Setiap <i>Timestep</i> Univariat	91
Gambar 6.11. Performa Model Terbaik Univariat	92
Gambar 6.12. Arsitektur Model Terbaik Univariat	92
Gambar 6.13. Model Terbaik Setiap <i>Timestep</i> Multivariat.....	93
Gambar 6.14. Performa Model Terbaik Multivariat	94
Gambar 6.15. Arsitektur Model Terbaik Multivariat	94

Gambar 6.16. Ikhtisar Model Terbaik Setiap <i>Timestep</i>	95
Gambar 6.17. Performa Skenario ‘ <i>Test Set 0.2</i> ’ Univariat	96
Gambar 6.18. Performa Skenario ‘ <i>Test Set 0.4</i> ’ Univariat	97
Gambar 6.19. Performa Skenario ‘ <i>Test Set 0.2</i> ’ Multivariat	97
Gambar 6.20. Performa Skenario ‘ <i>Test Set 0.4</i> ’ Multivariat	98
Gambar 6.21. Ikhtisar Skenario Proporsi Pembagian Data	98
Gambar 6.22. Performa Skenario ‘Data KAEF’ Univariat.....	100
Gambar 6.23. Performa Skenario ‘Data SMGR’ Univariat.....	100
Gambar 6.24. Performa Skenario ‘Data KAEF’ Multivariat.....	101
Gambar 6.25. Performa Skenario ‘Data SMGR’ Multivariat....	101
Gambar 6.26. Ikhtisar Skenario Penggunaan Data.....	102
Gambar 6.27. Performa Skenario ‘Metode GRU’ Univariat.....	103
Gambar 6.28. Performa Skenario ‘Metode ‘GRU’ Multivariat.	104
Gambar 6.29. Ikhtisar Skenario Perbandingan Metode.....	104
Gambar 6.30. Performa Skenario Data Kedepan Univariat	106
Gambar 6.31. Performa Skenario Data Kedepan Multivariat....	106
Gambar 6.32. Ikhtisar Skenario Data Masa Depan	107

DAFTAR TABEL

Tabel 2.1. Literatur 1	7
Tabel 2.2. Literatur 2	8
Tabel 2.3. Literatur 3	9
Tabel 2.4. Literatur 4	10
Tabel 2.5. Literatur 5	11
Tabel 4.1. Parameter yang Digunakan [22].....	36
Tabel 4.2. Nilai Parameter yang Digunakan	38
Tabel 5.1. Spesifikasi <i>Hardware</i>	43
Tabel 5.2. <i>Library</i> Yang Digunakan	43
Tabel 5.3. Ikhtisar Karakter Saham 6 Desember 2019.....	46
Tabel 6.1. Tampilan Tabel Nilai Tukar USD/IDR	63
Tabel 6.2. Tampilan Tabel Harga Saham ASII	64
Tabel 6.3. Tampilan Tabel Harga Saham KAEF	65
Tabel 6.4. Tampilan Tabel Harga Saham SMGR.....	65
Tabel 6.5. Ikhtisar Karakter Saham 30 September 2019	66
Tabel 6.6. Hasil Penggabungan Semua Variabel <i>Dataframe</i>	68
Tabel 6.7. Pengamatan Tren 30 September 2019.....	70
Tabel 6.8. Pratinjau <i>Dataframe</i> setelah <i>Feature Selection</i>	71
Tabel 6.9. Pengecekan <i>Missing Value</i> dalam <i>Dataframe</i>	72
Tabel 6.10. Pengisian <i>Missing Value</i> dalam <i>Dataframe</i>	73
Tabel 6.11. Hasil Pembagian Data Univariat	74
Tabel 6.12. Hasil Pembagian Data Multivariat	74
Tabel 6.13. Hasil <i>Feature Scaling</i>	74
Tabel 6.14. Struktur <i>Training Set</i> Univariat <i>Multi-timestep</i>	75
Tabel 6.15. Struktur <i>Test Set</i> Univariat <i>Multi-timestep</i>	75
Tabel 6.16. Hasil <i>Tuning Parameter 1 Timestep</i> Univariat.....	76
Tabel 6.17. Hasil <i>Tuning Parameter 2 Timestep</i> Univariat.....	77
Tabel 6.18. Hasil <i>Tuning Parameter 3 Timestep</i> Univariat.....	78
Tabel 6.19. Hasil <i>Tuning Parameter 4 Timestep</i> Univariat.....	79
Tabel 6.20. Hasil <i>Tuning Parameter 5 Timestep</i> Univariat.....	80
Tabel 6.21. Hasil <i>Tuning Parameter 6 Timestep</i> Univariat.....	81
Tabel 6.22. Hasil <i>Tuning Parameter 7 Timestep</i> Univariat.....	82
Tabel 6.23. Struktur <i>Training Set</i> Multivariat <i>Multi-timestep</i>	83

Tabel 6.24. Struktur <i>Test Set</i> Multivariat <i>Multi-timestep</i>	83
Tabel 6.25. Hasil <i>Tuning Parameter 1 Timestep</i> Multivariat.....	84
Tabel 6.26. Hasil <i>Tuning Parameter 2 Timestep</i> Multivariat.....	85
Tabel 6.27. Hasil <i>Tuning Parameter 3 Timestep</i> Multivariat.....	86
Tabel 6.28. Hasil <i>Tuning Parameter 4 Timestep</i> Multivariat.....	87
Tabel 6.29. Hasil <i>Tuning Parameter 5 Timestep</i> Multivariat.....	88
Tabel 6.30. Hasil <i>Tuning Parameter 6 Timestep</i> Multivariat.....	89
Tabel 6.31. Hasil <i>Tuning Parameter 7 Timestep</i> Multivariat.....	90
Tabel 6.32. Model Terbaik Setiap <i>Timestep</i> Kasus Univariat.....	91
Tabel 6.33. Model Terbaik Setiap <i>Timestep</i> Kasus Multivariat ..	93
Tabel 6.34. Model Terbaik Univariat dan Multivariat	95
Tabel 6.35. Evaluasi Skenario Proporsi Pembagian Data	96
Tabel 6.36. Evaluasi Skenario Penggunaan <i>Dataset Lain</i>	99
Tabel 6.37. Evaluasi Skenario Perbandingan Metode	103
Tabel 6.38. Evaluasi Skenario Penggunaan Data Masa Depan .	105

DAFTAR KODE PROGRAM

Kode Program 5.1. <i>Load Libraries</i>	47
Kode Program 5.2. <i>Load</i> dan Standarisasi Data.....	47
Kode Program 5.3. Pengecekan Tipe Data.....	48
Kode Program 5.4. Penggabungan Data.....	48
Kode Program 5.5. Membuat <i>Correlation Plot</i>	49
Kode Program 5.6. Membuat <i>Stacked Line Chart</i>	50
Kode Program 5.7. <i>Feature Selection</i>	50
Kode Program 5.8. Pengisian <i>Missing Values</i>	51
Kode Program 5.9. Inisiasi Proporsi Test Set.....	51
Kode Program 5.10. <i>Splitting</i> Data Univariat	51
Kode Program 5.11. <i>Splitting</i> Data Multivariat.....	52
Kode Program 5.12. <i>Feature Scaling</i>	52
Kode Program 5.13. Struktur <i>Training Set</i> Univariat.....	53
Kode Program 5.14. Struktur <i>Test Set</i> Univariat.....	54
Kode Program 5.15. Struktur <i>Training Set</i> Multivariat.....	55
Kode Program 5.16. Struktur <i>Test Set</i> Multivariat	56
Kode Program 5.17. Inisiasi Variabel untuk Nilai Parameter	56
Kode Program 5.18. Arsitektur Model Univariat	57
Kode Program 5.19. Arsitektur Model Multivariat	57
Kode Program 5.20. <i>Stacked Line Chart</i> pada <i>Training Loss</i>	58
Kode Program 5.21. Peramalan Univariat pada <i>Test Set</i>	58
Kode Program 5.22. Peramalan Multivariat pada <i>Test Set</i>	59
Kode Program 5.23. <i>Stacked Line Chart</i> Hasil Prediksi	60
Kode Program 5.24. <i>Method Metriks Evaluasi MAPE</i>	60
Kode Program 5.25. Mengubah Nilai Parameter Variabel.....	61
Kode Program 5.26. Skenario Proporsi <i>Train:Test</i>	61
Kode Program 5.27. Skenario Penggunaan Saham Lain	62
Kode Program 5.28. <i>Library Penggunaan Metode Lain</i>	62
Kode Program 5.29. Skenario Metode Lain.....	62

Halaman ini sengaja dikosongkan

BAB I

PENDAHULUAN

Bab pendahuluan berisi identifikasi yang meliputi latar belakang, rumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian, relevansi tugas akhir. Diharapkan dari bab ini dapat memberi gambaran umum mengenai permasalahan dan pemecahan permasalahan dalam penelitian tugas akhir.

1.1. Latar Belakang

Investasi Saham merupakan hal yang cukup menjanjikan untuk saat ini dan di masa yang akan datang, tak ayal hal tersebut membuat semakin banyak orang yang ingin berinvestasi di pasar modal. Hal tersebut dibuktikan dengan jumlah investor di Bursa Efek Indonesia (BEI) yang tercatat mengalami peningkatan sebanyak 26% dari Juli 2015 hingga Juli 2016 [1]. Dengan kondisi pasar yang setiap saat siap melakukan penjualan maupun pembelian, Saham merupakan surat berharga yang bersifat *liquid* [2]. Investor membutuhkan informasi terkait kondisi pasar modal termasuk faktor-faktor lain yang mungkin akan berpengaruh terhadap kondisi di pasar modal.

Fluktuasi harga saham dipengaruhi berbagai macam hal. Hal ini yang membuat teknik peramalan saham menjadi tugas sulit bagi para investor. Salah satu indikator yang mempengaruhi pergerakan harga saham adalah indikator makroekonomi seperti nilai tukar mata uang rupiah terhadap dollar (USD/IDR). Nilai tukar mata uang atau biasa disebut kurs adalah jumlah mata uang lokal tertentu yang dibutuhkan untuk membeli satu unit mata uang mancanegara atau sebaliknya [3]. Kondisi pasar modal Indonesia juga tidak dapat terlepas dari perusahaan multinasional yang umumnya melakukan transaksi perdagangan menggunakan nilai tukar USD/IDR sehingga perubahan nilai tukar USD/IDR dapat mempengaruhi pergerakan saham.

Di bursa saham, terdapat label saham yang memiliki sentimen positif di mata para Investor dengan sebutan *blue chip*. Dengan label tersebut artinya suatu perusahaan memiliki sentimen perihal fundamental dan kinerja yang baik, memiliki pengelolaan yang profesional, serta bergerak pada segmen industri yang dibutuhkan khalayak sehingga praktis berpengaruh terhadap pertumbuhan kapital [4]. Hal tersebut memungkinkan investor rutin mendapatkan benefit berupa dividen. Salah satu contoh perusahaan dengan label *blue chip* adalah PT. Astra International Tbk (Astra) yang merupakan perusahaan multinasional diversifikasi dengan ratusan ribu karyawan dan ratusan anak perusahaan yang bergerak dalam 7 segmen industri yang dibutuhkan. Astra sendiri telah terdaftar di Bursa Efek Indonesia (BEI) sejak 1990 [5]. Namun meski demikian, meramalkan saham *holding company* dengan banyak anak perusahaan juga menjadi tantangan tersendiri karena nilai sahamnya juga dipengaruhi oleh berbagai kondisi industri dari masing-masing anak perusahaan.

Dengan kemajuan teknologi dan berbagai *tools* yang ada, peluang untuk mendapatkan kekayaan yang stabil dari transaksi saham meningkat dan akan membantu para ahli untuk menemukan indikator yang paling informatif untuk membuat peramalan yang lebih baik [6]. Peramalan harga saham Astra dengan mempertimbangkan faktor makroekonomi akan membantu investor dalam meningkatkan ketepatan pengambilan keputusan. Pengambilan keputusan yang baik membuat investor dapat maksimalkan benefit investasi saham yakni keuntungan penjualan di atas pembelian yang disebut *capital gain* dan pembagian keuntungan berdasarkan kepemilikan saham yang dimiliki yang disebut dividen, terutama bagi mereka yang merupakan investor pemula. Dengan permasalahan terbut, maka solusinya data saham dari PT. Astra International Tbk. (ASII.JK) dan data nilai tukar mata uang rupiah terhadap dollar (USDIDR=X) akan dibuat model peramalannya sehingga manfaat tersebut dapat diwujudkan.

Sudah banyak metode untuk meramalkan saham. Karakter data *time series* saham yang non-linear membuatnya cocok untuk dimodelkan dengan model *Neural Network*. *Recurrent Neural Network* (RNN) merupakan jenis arsitektur *Neural Network* dimana pemrosesannya dipanggil berulang-ulang [7]. Penelitian ini mengajukan salah satu solusi yang merupakan arsitektur dari RNN yang cukup populer saat ini yakni *Long Short-Term Memory* (LSTM) untuk meramalkan harga saham.

LSTM merupakan pembelajaran berbasis gradien dengan tiga gates yakni *input*, *forget* dan *output*. LSTM saat ini banyak digunakan dan telah terbukti bekerja dengan baik di berbagai kasus. Salah satu contoh kasus yang telah dilakukan terhadap karakter data yang mirip dengan karakter data saham adalah penelitian terkait peramalan jumlah wisatawan di Pulau Lombok menggunakan LSTM yang mendapat hasil yang baik dengan RMSE yang kecil untuk rentang dari data yang ada [8].

Berdasarkan penelitian yang telah diuraikan, peramalan menggunakan LSTM mendapatkan hasil yang dapat dikatakan bagus. Diharapkan keakuratan peramalan harga saham Astra menggunakan Metode LSTM dalam penelitian ini dapat memberi banyak manfaat terutama para investor dalam memperoleh informasi untuk pengambilan keputusan.

1.2. Rumusan Masalah

Berdasarkan uraian latar belakang, maka rumusan masalah yang menjadi fokus dan diselesaikan dalam tugas akhir ini antara lain:

1. Bagaimana penerapan metode *Long Short-Term Memory* pada peramalan harga saham?
2. Bagaimana performa metode *Long Short-Term Memory* untuk peramalan harga saham?

1.3. Batasan Permasalahan

Berdasarkan uraian rumusan permasalahan, maka batasan masalah dalam penelitian ini antara lain:

1. Metode yang digunakan adalah Long Short-Term Memory dengan nama arsitektur LSTM pada *Recurrent Layers*.
2. Data saham dan data nilai tukar USD/IDR yang digunakan dalam membuat model peramalan adalah data *close price* harian pada saat hari kerja. Data diambil dari situs *Investing* dengan periode mulai dari Oktober 2014 (Awal Kuartal 4) hingga September 2019 (Akhir Kuartal 3).

1.4. Tujuan Penelitian

Berikut merupakan tujuan penelitian tugas akhir ini berdasarkan pemaparan latar belakang dan rumusan masalah:

1. Menganalisis penerapan metode LSTM dan mendapatkan model dengan akurasi terbaik untuk peramalan saham.
2. Mengetahui performa atau akurasi model dengan metode LSTM untuk peramalan harga saham.

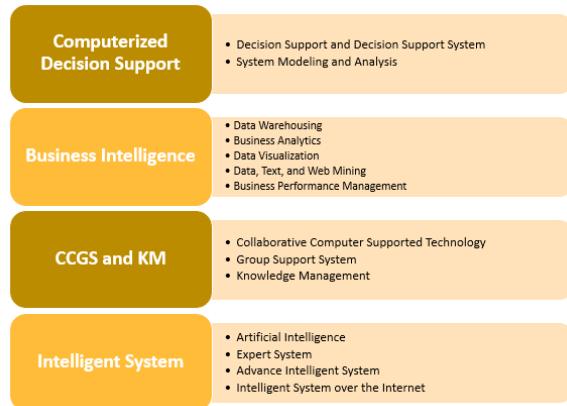
1.5. Manfaat Penelitian

Manfaat yang diharapkan dari tugas akhir ini adalah:

1. Sebagai tambahan informasi untuk pengambilan keputusan bagi investor dalam melakukan transaksi di pasar modal.
2. Dapat memberikan saran dan pembanding untuk pengembangan metode penelitian di masa mendatang.

1.6. Relevansi

Bila dikaitkan dengan Roadmap penelitian Laboratorium RDIB, maka topik ini masuk kedalam sub-bagian *Business Analytics*, *Data Mining* dan *Data Visualization* dalam bagian *Business Intelligence* seperti yang ditunjukkan pada Gambar 1.1.



Gambar 1.1. *Roadmap* Penelitian RDIB

Pemahaman terkait peramalan data *time series* dipelajari di mata kuliah Teknik Peramalan. Metode LSTM yang merupakan bagian spesifik dari *Neural Network* dipelajari di mata kuliah Analitika Bisnis. Perihal teknik mengambil data, memahami data, pemrosesan data, pembentukan hingga evaluasi model dipelajari di mata kuliah Penggalian Data.

Halaman ini sengaja dikosongkan

BAB II

TINJAUAN PUSTAKA

Bab tinjauan pustaka berisi penelitian sebelumnya yang dijadikan acuan dalam penggerjaan tugas akhir dan juga berisi dasar teori untuk menunjang penelitian tugas akhir.

2.1. Penelitian Sebelumnya

Tabel 2.1 hingga Tabel 2.4 menampilkan daftar penelitian sebelumnya yang mendasari tugas akhir ini.

Tabel 2.1. Literatur 1

1. Multi Time Steps Prediction Dengan Recurrent Neural Network Long Short-Term Memory [8]
Penulis/Tahun/Sumber : Ahmad Ashril Rizal, Siti Soraya; 2018
Deskripsi : Penelitian ini berfokus pada peramalan jumlah wisatawan di Pulau Lombok untuk memaksimalkan pertumbuhan perekonomian dari sektor pariwisata. Adapun metode yang digunakan adalah RNN dengan arsitektur LSTM dengan dan tanpa <i>multi-timesteps</i> . Sehingga terbentuk dua model dan akan dievaluasi dan dibandingkan menggunakan metrik evaluasi RMSE.
Kelebihan : Menggunakan struktur data <i>multi-timesteps</i> yang cukup sesuai dengan karakter model LSTM. Struktur data tersebut berfungsi untuk masukan dan luaran yang digunakan. Selain itu runtutan metodologi dan alur berpikir dalam memproses data dijelaskan dengan cukup baik sekaligus didapatkan hasil yang baik dalam peramalan jumlah wisatawan.

Kekurangan :

Kurangnya eksperimen terkait ekstraksi fitur karena penelitian ini hanya menggunakan satu fitur yakni “*Tourist Arrival*”. Hasil dari kunjungan wisata sebelumnya menjadi input untuk hasil kunjungan wisata saat ini sebagaimana RNN bekerja.

Keterkaitan dengan Tugas Akhir :

Keterkaitan penelitian tersebut dengan tugas akhir adalah dapat diimplementasikannya runtutan metodologi mengingat metode yang digunakan sama serta memiliki karakter data yang mirip meskipun lingkup permasalahan yang diramalkan berbeda. Sehingga pemrosesan data dari awal hingga akhir dari penelitian ini dapat menjadi referensi untuk implementasi dalam tugas akhir.

Tabel 2.2. Literatur 2

2. Predicting Stock Prices Using LSTM [6]
Penulis/Tahun/Sumber :
Murtaza Roondiwala, Harshal Patel, Shraddha Varma; 2015
Deskripsi :
Penelitian ini berfokus pada peramalan saham NIFTY 50. Adapun metode yang digunakan adalah LSTM dengan berbagai macam eksperimen penggunaan fitur. Dengan arsitektur model yang dijelaskan, model terbaik didapatkan dengan parameter 500 <i>epoch</i> dengan tingkat kebaikan model menggunakan metrik evaluasi RMSE sebesar 0.00859.
Kelebihan :
Nilai RMSE yang dihasilkan cukup rendah membuktikan bahwa arsitektur yang dibentuk sudah cukup baik. Selain itu dilakukan eksperimen atau skenario dengan melibatkan 2 sampai dengan 4 fitur kedalam model serta percobaan jumlah <i>epoch</i> yang berbeda.

Kekurangan :

Tidak mencoba menggunakan peramalan hanya dengan menggunakan satu fitur saja. Meskipun dengan empat fitur dirasa luaran peramalan cukup baik, sejatinya model dapat menerima masukan cukup dengan satu fitur saja mengingat korelasi semua fitur sangat tinggi dan dapat diwakilkan.

Keterkaitan dengan Tugas Akhir :

Keterkaitan penelitian tersebut dengan tugas akhir adalah dapat diimplementasikannya analisa berbasis eksperimen dengan atau tanpa fitur tertentu. Yang membedakan adalah tugas akhir ini menggunakan satu fitur terkait saham kedalam model dengan dan tanpa data historis terkait nilai tukar mata uang USD/IDR untuk melihat perbandingan tingkat kebaikan model diantara keduanya.

Tabel 2.3. Literatur 3

3. Prediksi Harga Saham menggunakan Recurrent Neural Network [9]
Penulis/Tahun/Sumber : M Abdul Dwiyanto, Esmeralda C. Djamal, Asri Maspupah; 2015
Deskripsi : Penelitian ini berfokus pada peramalan harga saham menggunakan metode RNN dengan Arsitektur LSTM dengan berbagai eksperimen parameter model seperti <i>optimizer</i> , <i>learning rate</i> dan <i>epoch</i> . Model yang dibuat dievaluasi menggunakan <i>model accuracy</i> dan <i>model loss</i> pada sampel <i>test set</i> .
Kelebihan : Kombinasi eksperimen parameter berupa <i>optimizer</i> , <i>learning rate</i> dan <i>epoch</i> sehingga tercipta banyak model untuk dikomparasikan guna mendapatkan model LSTM terbaik.

Kekurangan :

Terlalu banyak fitur yang digunakan untuk dimasukkan kedalam model, terdapat ekstraksi fitur yang mungkin kurang diperlukan seperti “rata-rata” yang merepresentasikan fitur dengan korelasi yang sangat kuat terhadap masing-masing fitur data saham. Seharusnya fitur yang memiliki korelasi mendekati 1 seperti pada kebanyakan fitur pada saham dapat diwakilkan satu fitur saja.

Keterkaitan dengan Tugas Akhir :

Penggunaan metode LSTM berbasis eksperimen penyetelan parameter dapat diimplementasikan kedalam tugas akhir, adapun kombinasi parameter terbaik dapat menjadi acuan untuk membangun salah satu penyetelan parameter LSTM pada data saham yang akan dianalisis dalam tugas akhir.

Tabel 2.4. Literatur 4

4. Analisis Dampak Variabel Makro Ekonomi Terhadap Indeks Saham Syariah Indonesia [10]

Penulis/Tahun/Sumber :

Siti Aisyah Suciningtias, Rizki Khoiroh; 2013

Deskripsi :

Penelitian ini menganalisa dampak variabel makroekonomi seperti inflasi, nilai tukar USD/IDR, Sertifikat Bank Indonesia Syariah (SBIS) , harga minyak dunia terhadap Indeks Saham Syariah Indonesia (ISSI) menggunakan Regresi Linear Berganda.

Variabel direpresentasikan dengan Fitur atau fitur. Didapatkan hasil bahwa Fitur inflasi dan nilai tukar USD/IDR memiliki pengaruh negatif signifikan sementara SBIS dan harga minyak dunia tidak memiliki pengaruh yang signifikan terhadap ISSI.

Kelebihan :
Membandingkan setiap Fitur makroekonomi sebagai Fitur yang dianalisa dampaknya terhadap ISSI sehingga dapat mengetahui Fitur makroekonomi yang memiliki pengaruh signifikan terhadap harga saham yakni inflasi dan nilai tukar USD/IDR
Kekurangan :
Analisa yang dilakukan adalah analisa dampak fitur independen terhadap fitur dependen, tidak untuk meramalkan fitur dependen itu sendiri. Meskipun sedikit berbeda dengan konteks penelitian tugas akhir ini, literatur tersebut memberikan insight terkait Fitur makroekonomi apa yang mempengaruhi saham.

Tabel 2.5. Literatur 5

5. Wind Speed Forecasting Method Based On Deep Learning Strategy Using Empirical Wavelet Transform, Long Short-Term Memory Neural Network nd Elman Neural Network [11]
Penulis/Tahun/Sumber :
Hui Liu, Xi-wei Mi, Yan-fei Li; 2018

Deskripsi :
Penelitian ini adalah terkait peramalan kecepatan angin dalam bentuk data time series yang ditujukan untuk pengoptimalan fungsi <i>intelligent wind power systems</i> dengan beberapa metode. Dengan metode utama menggunakan <i>Empirical Wavelet Transform, Long</i>

Short-Term Memory Neural Network, Elman Neural Network dan lainnya adalah metode *hybrid*. Peramalan kecepatan angin ini memiliki berbagai hasil evaluasi yang salah satunya menggunakan LSTM dengan metrik MAPE terbaik sebesar 6,7%.

Kelebihan :

Dalam penelitian ini menggunakan banyak metode (hingga 10 metode termasuk metode *hybrid*), banyak metrik evaluasi (3 metrik yakni MAPE, MAE dan RMSE) serta *multi-timestep* untuk fitur dependen dan independennya (hingga 3 *timestep*). Hal ini berguna untuk *benchmark* bagi penelitian berikutnya.

Kekurangan :

Dalam penelitian ini kurang terdapat detail terkait penjelasan skenario parameter model yang digunakan.

Keterkaitan dengan Tugas Akhir :

Keterkaitan penelitian tersebut dengan tugas akhir adalah terdapat penggunaan metode serta metrik evaluasi yang sama untuk sesama kasus data *time series* sehingga hasilnya dapat digunakan menjadi tolok ukur baik tidaknya model untuk penelitian ini.

2.2. Landasan Teori

Landasan teori berisi teori-teori yang digunakan dalam pelaksanaan penelitian tugas akhir. Dalam landasan teori, acuan yang digunakan adalah berdasarkan penelitian dan buku.

2.2.1. Peramalan Time Series

Peramalan *time series* adalah metode peramalan dengan analisa pola hubungan tiap Fitur atau fitur yang dipekirakan dengan himpunan data terurut dalam waktu. Peramalan data *time series* perlu memperhatikan tipe atau pola data. Secara umum terdapat empat macam pola data *time series* yaitu horizontal, trend, musiman, dan siklis [12]. Berbagai macam pola data dalam peramalan *time series* tersebut akan menentukan metode peramalan yang akan digunakan.

2.2.2. Saham

Saham merupakan surat berharga yang menunjukkan bagian kepemilikan suatu badan terhadap suatu perusahaan. Sehingga ketika seseorang memiliki saham perusahaan tertentu berarti ia berhak atas aset dan pendapatan sebesar porsi saham yang ditanamkan melalui pasar modal.

Saham memiliki perkiraan yang bersifat *liquid* dikarenakan kondisi pasar dapat setiap saat melakukan penjualan atau pembelian. Indeks harga saham juga dipengaruhi oleh banyak sekali faktor. Para investor menggunakan saham sebagai investasi dengan melakukan penjualan di atas harga beli disaat yang tepat sehingga dapat menghasilkan *capital gain*, atau dengan mendapatkan proporsi keuntungan yang dibagikan dari profit perusahaan yang disebut dengan dividen [13].

2.2.3. Nilai Tukar Mata Uang

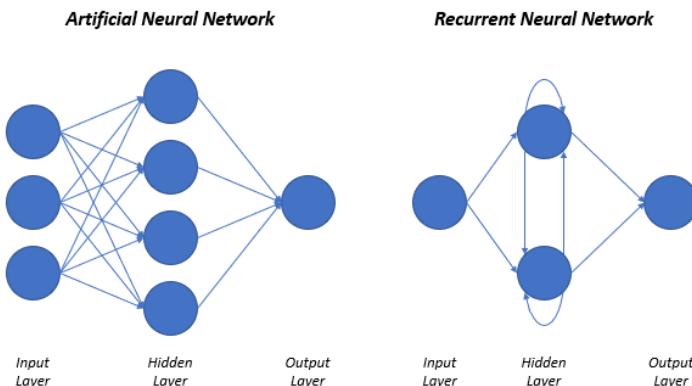
Nilai tukar mata uang atau kurs adalah sejumlah mata uang tertentu yang dapat ditukarkan ke mata uang yang lain, bisa dari lokal ke mancanegara atau sebaliknya. Nilai tukar mata uang merupakan bagian dari proses valuta asing [3].

Istilah yang umum digunakan dalam fluktuasi nilai tukar mata uang adalah apresiasi dan depreseiasi. Apresiasi adalah ketika nilai mata uang lokal lebih tinggi dari pada nilai mata uang asing, sementara depresiasi adalah sebaliknya. Kedua hal tersebut kerap dikaitkan terhadap inflasi dan deflasi dimana terdapat fluktuasi harga barang disebabkan oleh fluktuasi nilai mata uang lokal. Pergerakan nilai tukar mata uang memiliki pengaruh strategis terhadap aspek perekonomian seperti inflasi, kinerja ekspor-impor dan kondisi pasar modal [14].

2.2.4. Long-Short Term Memory (LSTM)

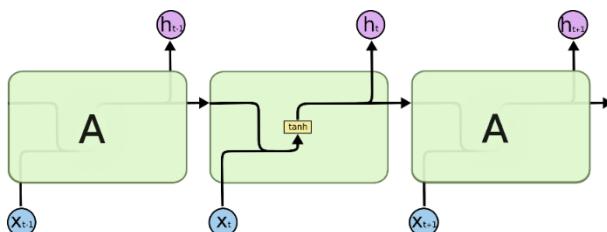
Long Short-Term Memory (LSTM) adalah salah satu arsitektur *Recurrent Neural Network* (RNN) yang ditemukan oleh Hochreiter dan Schmidhuber pada tahun 1997 [15]. Dibandingkan dengan *Artificial Neural Network* (ANN), RNN menjadikan *output* saat ini sebagai *input* untuk unit berikutnya.

Dengan menggunakan koneksi berulang maka informasi akan berputar disamping jaringan dalam waktu yang lama, hal ini membuatnya bagus untuk memproses data sekuensial. Perbandingan dapat dilihat pada Gambar 2.1.



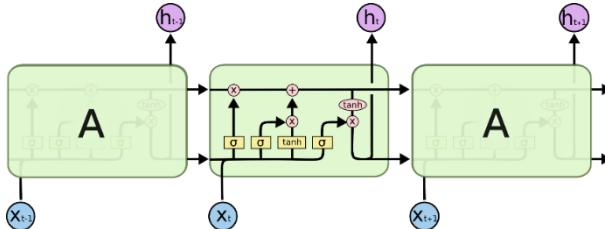
Gambar 2.1. Perbedaan *Neuron* pada ANN dan RNN

RNN telah diterapkan pada bidang pembelajaran mesin seperti peramalan *time series*, *Natural Language Processing* (NLP) dan data sekuensial lain. [7]. Lebih jelas tentang arsitektur modul RNN ditunjukkan pada Gambar 2.2.



Gambar 2.2. Struktur *Recurrent Neural Network* [14]

LSTM dirancang untuk mengatasi masalah gradien yang menghilang (*vanishing gradient*) pada RNN dengan memisahkan memori dan representasi output dengan adanya *cell state* yang membentang sepanjang *repeating module*. RNN dikenal memiliki masalah pada *long-term dependencies*.

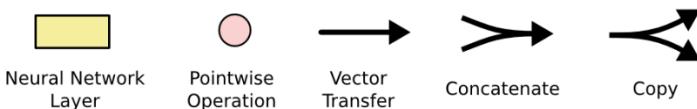


Gambar 2.3. Struktur Long Short-Term Memory [16]

Prediksi RNN pada *current state* tidak mengandalkan memori sebagaimana yang LSTM gunakan. Dengan kelebihan tersebut, LSTM banyak digunakan. Arsitektur LSTM ditunjukkan pada Gambar 2.3. Berbeda dengan RNN yang memiliki modul berulang yang cukup simpel seperti satu buah tanh *layer*, LSTM memiliki banyak *layer* yang berinteraksi secara khusus.

2.2.4.1. Notasi LSTM

Notasi yang akan dijelaskan digunakan untuk lebih memahami bagaimana informasi akan mengalir dan dioperasikan dalam kerangka arsitektur LSTM tertera pada notasi di Gambar 2.4.

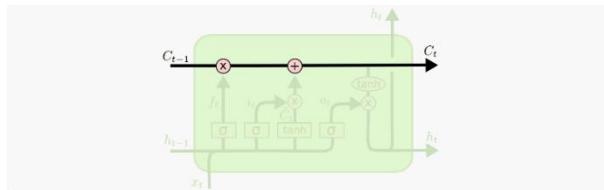


Gambar 2.4. Notasi LSTM [14]

Setiap garis yang ada disebut dengan vektor transfer yang menyalurkan informasi dari output modul sebelumnya (h_{t-1}), masukan dari modul itu sendiri (x_t) dan juga memori yang dihasilkan dari modul sebelumnya (C_{t-1}). Dari garis vektor transfer yang ada, bisa terjadi *concatenate* (penggabungan) dan juga *copy* (duplikasi). Lingkaran berwarna merah muda merepresentasikan *pointwise operation* yang mengoperasikan dua informasi yang dipertemukan seperti *addition* (penambahan vektor) dan *multiplication* (perkalian vektor). Kotak berwarna kuning adalah *learned neural network layer* yang masing-masing terdapat fungsi aktivasi.

2.2.4.2. Cell State

Kunci dari LSTM adalah garis horizontal bernama *cell state* yang membentang di atas arsitektur modul LSTM. *Cell state* mengalami beberapa interaksi linear yakni berupa operasi *pointwise* hasil dari *gate* lain untuk dioperasikan. *Cell state* dalam LSTM ditunjukkan pada Gambar 2.5.



Gambar 2.5. Cell State LSTM [16]

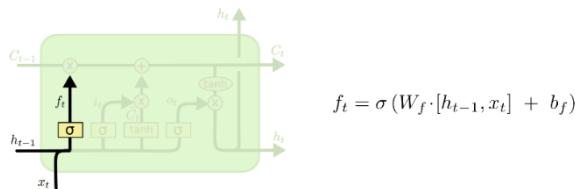
Informasi dapat terus mengalir dengan atau tanpa perubahan, karena LSTM memiliki kemampuan untuk menghapus atau menambahkan informasi kedalam *cell state*, yang secara diatur oleh struktur bernama *gates*. Interaksi *cell state* dengan tiga *gates* LSTM inilah yang membedakannya dengan RNN dimana *cell state* akan menyimpan informasi seperti halnya memori dari interval sebelumnya yang akan mempengaruhi luaran modul.

Gates sendiri adalah objek yang secara opsional membiarkan informasi terus mengalir. *Gates* terdiri atas sigmoid (σ) sebagai *neural net layer* dan operasi *pointwise multiplication*. LSTM memiliki tiga buah *gates* untuk melindungi dan mengontrol isi dari *cell state*. Luaran dari sigmoid *layer* adalah antara 0 dan 1, mendeskripsikan tiap informasi yang ada bisa terus mengalir atau tidak. Luaran fungsi sigmoid “0” merepresentasikan “tidak ada informasi yang dapat diteruskan” sementara “1” merepresentasikan “semua informasi dapat diteruskan”

Hasil dari *cell state* atau memori ini nantinya akan mengalami duplikasi ke modul berikutnya (C_t) dan disatu sisi juga dioperasikan dengan hasil dari *output gate* modul saat ini yang menghasilkan luaran yang akan diteruskan ke modul berikutnya (h_t).

2.2.4.3. Forget Gate

Forget gate layer memastikan informasi mana yang tidak akan diteruskan dari *cell state* lama. Luaran dari *forget gate* ini adalah nilai 1 atau 0 yang kemudian akan dikombinasikan dengan setiap informasi yang ada di *cell state* lama (C_{t-1}) seperti yang ditunjukkan pada Gambar 2.6.

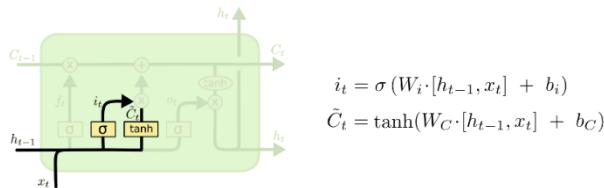


Gambar 2.6. *Forget Gate LSTM* [16]

Nilai 1 atau 0 tersebut adalah bobot yang didapatkan dari fungsi sigmoid *forget gate layer* yang dinyatakan dalam f_t terhadap *input* (x_t) dan *output repeating module* sebelumnya (h_{t-1}).

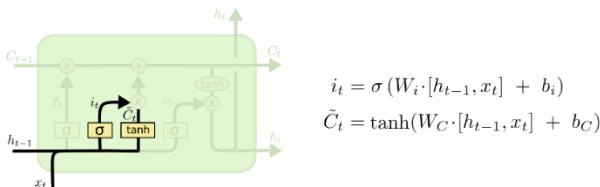
2.2.4.4. Input Gate

Input gate layer memastikan informasi baru yang didapatkan dari dua fungsi aktivasi dapat masuk kedalam *cell state* lama. Terdiri atas dua tahap dimana dari vektor informasi dari x_t dan h_{t-1} akan mengalami duplikasi dan masuk ke dua fungsi yakni fungsi sigmoid dan tanh. Fungsi sigmoid *input gate* yang dinyatakan dengan i_t memutuskan informasi mana yang akan diperbarui berupa nilai 1 atau 0, sementara fungsi tanh yang dinyatakan dengan C'_t adalah vektor untuk kandidat nilai yang baru. Kedua fungsi ditunjukkan pada Gambar 2.7.



Gambar 2.7. *Forget Gate LSTM* [16]

Tahap berikutnya adalah *update* informasi *cell state* lama (C_{t-1}) untuk diteruskan menjadi *cell state* baru (C_t) dari modul saat ini. Vektor *forget gate* (f_t) dikalikan dengan *cell state* lama (C_{t-1}) untuk melupakan informasi yang tidak perlu dan kemudian menambahkannya dengan hasil perkalian dari vektor *input gate* (i_t) dan vektor kandidat nilai baru (C'_t) yang kemudian menjadi *cell state* saat ini seperti yang ditunjukkan pada Gambar 2.8.

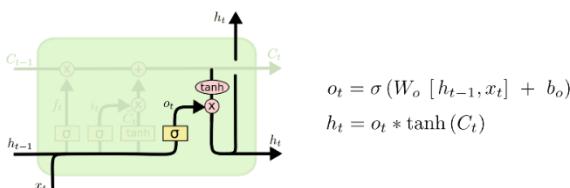


Gambar 2.8. Operasi *Cell State* LSTM [16]

C_t yang merepresentasikan informasi baru yang diingat dalam *cell state* akan diteruskan dan diduplikasi yakni untuk menjadi memori di *repeating module* berikutnya dan akan digunakan pula untuk menghasilkan *output*.

2.2.4.5. Output Gate

Output gate layer memastikan terdapat output dari repeating module saat ini yang dinyatakan dalam h_t . h_t adalah kombinasi dari *cell state* (C_t) dan fungsi sigmoid *output gate layer* yang dinyatakan dalam o_t .



Gambar 2.9. *Output Gate* LSTM [16]

Seperti yang ditunjukkan pada Gambar 2.9, masukan berupa vektor informasi akan masuk ke *output gate layer* dengan fungsi sigmoid dan akan menghasilkan vektor bernilai 1 atau 0 sebagai representasi informasi apa saja dari *cell state* yang akan

diteruskan menjadi *output* untuk *state* saat ini. Sementara *cell state* baru (C_t) akan melalui fungsi tanh untuk memaksa nilainya menjadi antara -1 atau 1. Kemudian terjadi operasi perkalian antara keduanya menghasilkan vektor h_t yang kemudian akan mengalami duplikasi untuk output dari *module* saat ini dan untuk masukan *repeating module* berikutnya.

2.2.5. Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) merupakan bentuk yang ekuivalen dari MAE. Persamaannya terlihat mirip dengan MAE, namun persentase pada MAPE menggambarkan evaluasi nilai peramalan dengan mempertimbangkan nilai aktual [17].

Keterangan:

$$MAPE = \frac{100\%}{n} \sum \left| \frac{y - y'}{y} \right|$$

y	=	Nilai aktual
y'	=	Nilai prediksi
n	=	Jumlah data

MAPE menggambarkan sejauh apa selisih prediksi model terhadap nilai aktual. Persentase dalam MAPE membuat interpretasi yang jelas mengingat persentase lebih mudah membuat orang untuk membayangkan nilai error. MAPE juga memiliki kelebihan dimana evaluasi ini tahan terhadap *outlier*. Kelemahannya adalah bahwa MAPE tidak bisa digunakan bila terdapat nilai 0 atau terdapat *missing value* pada data aktual.

Semakin kecil MAPE yang diperoleh maka model dapat dikatakan semakin bagus karena persentase yang kecil mewakili nilai *error* yang kecil jika dibandingkan dengan nilai aktual.

Halaman ini sengaja dikosongkan

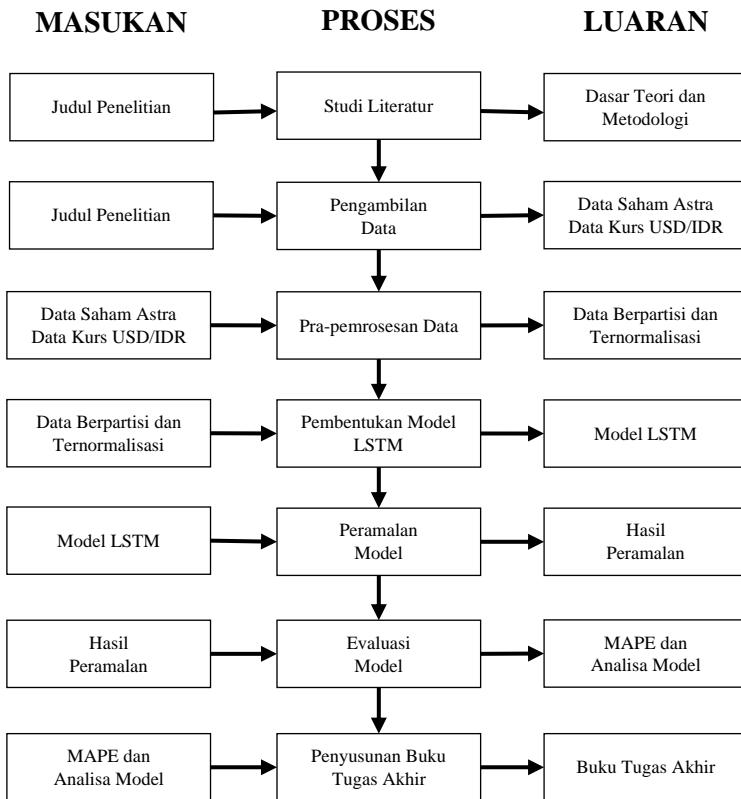
BAB III

METODOLOGI PENELITIAN

Bab metodologi berisi penjelasan terkait bagaimana alur dari penelitian tugas akhir berserta penjelasan setiap tahapan dalam melakukan penelitian tugas akhir.

3.1. Metodologi

Alur penelitian yang meliputi *input*, proses, serta *output* yang dihasilkan ditunjukkan pada Gambar 3.1.



Gambar 3.1. Metodologi Tugas Akhir

3.2. Uraian Metodologi

Berikut merupakan uraian dari metodologi yang digambarkan dalam diagram pada bagian sebelumnya. Metodologi yang digunakan pada penelitian ini menggunakan metode *Long Short-Term Memory*.

3.2.1. Studi Literatur

Pada tahap studi literatur dilakukan studi pustaka terkait studi kasus yang dijadikan objek penelitian yakni PT Astra International Tbk. Setelah memahami objek studi kasus yang diangkat di tugas akhir, dilakukan studi pustaka terkait lingkup permasalahan yang akan dipecahkan yakni peramalan harga saham, Fitur yang mempengaruhi yakni faktor makroekonomi berupa nilai tukar USD/IDR, metode yang digunakan yakni *Long Short-Term Memory* (LSTM) dan tingkat kebaikan model yakni *Mean Absolute Percentage Error* (MAPE).

3.2.2. Pengambilan Data

Semua sumber data baik nilai tukar USD/IDR dan saham diambil dari situs *Investing*. Data yang digunakan adalah data harian untuk hari kerja dengan rentang lima tahun dari Oktober 2014 hingga September 2019 untuk kedua data tersebut.

Untuk melakukan pemodelan diambil data historis nilai tukar USD/IDR dan saham Astra. Untuk menguji kualitas model dengan MAPE terbaik diambil data saham lain dengan karakter data yang berbeda baik dari segi rentang nilai data dan tren.

3.2.3. Pra-Pemrosesan Data

Tahap ini memiliki luaran berupa data dalam keadaan sudah bersih dan sudah berbentuk partisi yang ternormalisasi sehingga dapat mengoptimalkan kinerja model untuk peramalan.

3.2.3.1. Standarisasi Data

Tahap ini dilakukan untuk memastikan tipe data yang digunakan untuk semua fitur adalah benar agar data dapat diproses dengan baik oleh program sehingga keseluruhan proses dapat berjalan.

3.2.3.2. Penggabungan Data

Semua *dataset* yang sudah standar nilainya akan digabungkan menggunakan *key* berupa tanggal yang sudah standar dengan mekanisme *join*. *Key* yang menjadi referensi adalah data Kurs.

3.2.3.3. Pengikhtisaran Data

Setelah data sudah standar dan digabungkan berikutnya adalah melakukan pengikhtisaran untuk memahami data secara komprehensif. Umumnya dilakukan visualisasi untuk melihat kecenderungan dengan menggunakan plot tertentu.

3.2.3.4. Eliminasi Fitur

Tahap eliminasi fitur dilakukan untuk memastikan bahwa fitur yang digunakan cukup efisien untuk membangun model. Tahap ini biasa disebut dengan *feature selection* yang mana prosesnya adalah mengeleminiasi fitur yang tidak diperlukan.

3.2.3.5. Pemeriksaan *Missing Value*

Setelah data dari dua sumber berbeda digabungkan pada tahap rekayasa fitur dengan menggunakan *key* yang ada, dilakukan pemeriksaan apakah terdapat *missing value* dan dilakukan *treatment* yang sesuai. Hal ini dilakukan karena 2 hal yakni karena metrik evaluasi MAPE tidak dapat dilakukan bila nilai aktual terdapat *missing value* dan tahap ini membuat pembentukan model lebih optimal.

3.2.3.6. Pembagian Data

Setelah data telah bersih melalui serangkaian tahap pra-pemrosesan data, tahap ini dilakukan untuk membagi data menjadi dua bagian yakni *training set* untuk pemodelan dan *test set* untuk validasi peramalan.

3.2.3.7. Normalisasi Fitur

Tahap pada pra-pemrosesan data diakhiri dengan normalisasi atau *feature scaling* untuk memastikan rentang nilai tiap fitur berada pada rentang yang sama pada interval yang ditentukan sehingga data yang diproses dapat tahan terhadap *outliers*.

3.2.4. Pembentukan Model

Setelah pra-pemrosesan data menghasilkan data bersih untuk diolah, dilakukan pembentukan model LSTM yang terbagi atas membangun struktur data dan membangun arsitektur.

3.2.4.1. Struktur Data Masukan dan Luaran

Di tahap ini dilakukan desain dari masukan dan luaran dari data yang akan dilatih dan diprediksi. Di awal perlu menentukan banyaknya *timestep* yang diperlukan. *Timestep* yang ditentukan adalah berapa waktu kebelakang yang akan digunakan untuk dapat diprediksi suatu luaran, tiap satu *timestep* merepresentasikan satu titik waktu. Sehingga masukan dalam struktur data disini adalah berupa fitur berisi nilai saham dan nilai tukar mata uang sebanyak *timestep* yang diperlukan. Sementara luaran adalah nilai satu hari setelah nilai saham di *timestep* paling akhir. Nantinya tiap luaran akan menjadi masukan untuk data berikutnya di timestep paling akhir.

Setelah itu struktur data yang dibangun perlu diubah menyesuaikan dengan bentuk yang dapat diterjemahkan oleh model yakni dengan *reshape* struktur data.

3.2.4.2. Membangun Arsitektur LSTM

Arsitektur di sini memiliki banyak komponen meliputi masukan, banyaknya lapisan, regularisasi, luaran dan lain-lain. Setiap komponen itu sendiri berisi beberapa parameter. Selain itu terdapat komponen untuk melakukan *compile* arsitektur dan *fitting* model sehingga suatu model dapat memprediksi *test set*.

3.2.5. Peramalan Model

Di tahap ini dilakukan peramalan terhadap partisi *test set* yang sudah dibagi di tahap pra-pemrosesan data. Model LSTM yang dibuat akan melakukan fungsi peramalan terhadap fitur independen sehingga dihasilkan luaran berupa nilai peramalan harga saham yang nantinya akan dibandingkan dengan nilai aktual harga saham melalui sebuah visualisasi.

3.2.6. Evaluasi Model

Tahap ini mengukur hasil prediksi menggunakan metrik yang ditentukan terhadap model yang telah dibentuk.

3.2.6.1. Evaluasi dengan MAPE

Evaluasi model dilakukan dengan menggunakan MAPE terhadap dua hasil peramalan dengan model peramalan saham tanpa faktor makroekonomi dan model prediksi saham dengan faktor makroekonomi. Kedua hasil akan dibandingkan untuk dilakukan *post-analysis*. Tahap ini dapat dilakukan berulang kali tergantung pada *tuning parameter* berikutnya.

3.2.6.2. Tuning Parameter dan Analisa Hasil

Tahap ini membuat pelatihan model menjadi iteratif. Suatu model dapat diubah tiap parameternya sehingga didapatkan hasil evaluasi yang berbeda. Diharapkan dari penyetelan parameter ini akan didapatkan model dengan MAPE terbaik. Kemudian analisa akhir dilakukan untuk menganalisa tiap hasil evaluasi yang didapatkan dengan model yang sudah melalui fase *tuning parameter*.

3.2.6.3. Skenario Pengujian Model Terbaik

Setelah mendapatkan model dengan MAPE terbaik dilakukan pengujian apakah model benar-benar dapat dikatakan *robust* untuk menangani berbagai macam karakteristik data. Terdapat tiga buah skenario seperti yang diuraikan sebagai berikut.

- **Skenario Proporsi Pembagian Data**

Skenario ini dilakukan untuk mengetahui apakah terdapat kecenderungan bahwa proporsi pelatihan dan validasi model akan mempengaruhi tingkat kebaikan model.

- **Skenario Penggunaan Dataset Lain**

Skenario ini dilakukan untuk mengetahui apakah model LSTM terbaik yang telah dibangun dapat menangani permasalahan pada data saham lain yang memiliki karakteristik yang berbeda.

- **Skenario Perbandingan Metode**

Skenario ini dilakukan untuk membandingkan performa parameter model LSTM terbaik jika dibandingkan dengan metode lain dengan arsitektur yang sama.

- **Skenario Data Masa Depan**

Skenario ini dilakukan untuk membandingkan performa prediksi model LSTM terhadap sebagian partisi data utama yang diambil dengan data yang tidak tersedia di data utama atau bisa dikatakan terhadap data di masa depan.

3.2.7. Penyusunan Buku Tugas Akhir

Tahapan terakhir dari penelitian ini adalah penyusunan buku tugas akhir. Buku tugas akhir merepresentasikan dokumentasi proses penelitian dari awal hingga akhir sehingga terdapat analisa dan penarikan kesimpulan.

BAB IV

PERANCANGAN

Bab perancangan berisi penjelasan mengenai rancangan untuk setiap proses yang dilakukan untuk mendapatkan luaran penelitian tugas akhir. Perancangan yang akan dipaparkan antara lain rancangan pengambilan data, rancangan pra-pemrosesan data, rancangan pembentukan model, rancangan peramalan dan rancangan evaluasi model.

4.1. Rancangan Pengambilan Data

Tahap ini dilakukan dengan mengunduh *dataset* dari situs *Investing*. Data utama yang akan digunakan untuk pemodelan adalah data nilai tukar USD/IDR dan data saham Astra (ASII) dengan rentang periode yang sama.

Kemudian untuk menunjang keperluan skenario pengujian kualitas model terbaik berdasarkan MAPE di tahap evaluasi dibutuhkan dua *dataset* yang secara karakteristik data berbeda dengan saham Astra. Maka dilakukan pengambilan data saham masing-masing dari kategori *top gainers* dan *top losers*. Setelah memilih dua data dari kategori tersebut dilakukan pengamatan tren naik turun harga saham tersebut melalui *performance*. Pertimbangan lain dari pemilihan diantara kedua data juga akan dipengaruhi oleh besaran harga saham dimana akan dipilih rentang harga yang secara signifikan berbeda.

Untuk rentang waktu dari data yang digunakan baik untuk Fitur dependen (ketiga nilai saham) dan Fitur independen (nilai tukar USD/IDR) adalah data harian pada hari kerja dengan rentang lima tahun dari Oktober 2014 hingga September 2019. Namun ketika pertama kali data ditarik, Urutan data teratas adalah data terbaru dan data terbawah adalah data terlama yang nantinya akan dilakukan pra-pemrosesan data.

4.2. Rancangan Pra-pemrosesan Data

Rancangan ini dibuat sedemikian hingga sampai dihasilkan luaran berupa partisi data yang siap untuk dimodelkan dan divalidasi dengan model LSTM.

Di tahap ini mulai mengimplementasikan rencana kedalam sebuah *source code* Python. Sehingga sebelum melakukan tahapan di bawah kita perlu *load* semua Libraries dari Python yang dibutuhkan untuk keseluruhan proses rekayasa data.

4.2.1. Rancangan Standarisasi Data

Standarisasi data dilakukan agar data dapat diuktisarkan, divisualisasikan dan dapat dimodelkan yang mana hal tersebut dapat terjadi bila nilai data pada varibel numerik bertipe data numerik pula. Ketepatan tipe data cukup krusial untuk menentukan proses rekayasa data berikutnya.

Data yang telah ditarik pada tahap sebelumnya dipanggil dan disimpan kedalam empat variabel yang berbeda. Kemudian nilai data yang terdapat koma pada empat variabel tersebut distandarisasikan sehingga data bernilai integer untuk kemudian dapat dilakukan eksplorasi data dan tentunya dapat dimodelkan.

4.2.2. Rancangan Penggabungan Data

Penggabungan data dilakukan agar semua data memiliki rentang *time series* yang standar yakni menyesuaikan data dengan *time series* terlengkap yaitu nilai tukar USD/IDR (1304 baris). Penggabungan data menggunakan *left join* dimana *left* merujuk pada variabel yang menyimpan data kurs. Data saham sendiri tidak memiliki *time series* sebanyak data kurs sehingga apabila dilakukan *left join* akan mengakibatkan masing-masing fitur terdapat *missing value* sebanyak selisih jumlah kurs dengan masing-masing saham yang digunakan.

Untuk dapat menggabungkan masing-masing data perlu dilakukan penghimpunan semua *dataset* dalam satu variabel berupa Array dengan isi himpunan paling awal (*left*) adalah berupa variabel nilai tukar USD/IDR.

Seperti yang diuraikan pada tahap pengambilan data bahwa urutan data terbalik, maka setelah data berhasil digabungkan perlu dilakukan *reverse index* dan *reset index*. Kedua hal tersebut berguna untuk meletakkan data dengan index paling akhir yakni data paling awal menjadi observasi teratas sehingga data terurut dengan benar dimulai dari data lama ke data baru.

4.2.3. Rancangan Pengikhtisaran Data

Pengikhtisaran data dilakukan agar data dapat dipahami secara komprehensif dan akhirnya ditemukan *insight* untuk melakukna rekayasa data di tahap berikutnya. Selain menemukan insight, pengikhtisaran data juga berguna untuk menguji perbedaan karakter dua data saham lain, apakah keduanya layak untuk digunakan menguji model dengan akurasi terbaik. Rancangan tahap ini terbagi menjadi dua bagian yakni melakukan uji korelasi dengan heatmap *correlation plot* dan melihat tren atau karakter dari setiap data dengan *stacked line chart*.

Correlation plot berguna untuk melihat perbandingan korelasi antar fitur sehingga nantinya dapat dipastikan bahwa korelasi nilai tukar USD/IDR terhadap setiap saham berbeda-beda. *Correlation plot* juga digunakan untuk keputusan seleksi fitur. Sementara *stacked line chart* berguna untuk melihat rentang nilai dan tren dari masing-masing saham, selain itu juga melihat secara sekilas *missing value* pada setiap data saham.

4.2.4. Rancangan Eliminasi Fitur

Eliminasi fitur dilakukan agar fitur dalam data yang sudah terseleksi dan mendukung efisiensi pembentukan model. Fitur akan dieliminasi berdasarkan urgensi fitur tersebut dan tingginya kemiripan korelasi dengan fitur lainnya.

4.2.5. Rancangan Pemeriksaan *Missing Value*

Pemeriksaan *missing value* dilakukan agar data yang ada dapat dilakukan pelatihan dan evaluasi model yang akan digunakan. Kemungkinan terdapat *missing value* karena penggabungan data sebelumnya memiliki jumlah baris yang berbeda. Perlakuan terhadap *missing value* sejatinya sangat beragam.

Metode untuk memperlakukan *missing value* dalam penelitian ini adalah pengisian dengan metode *Last Observastion Carried Forward* (LOCF) yakni dengan menggantikan *missing value* dengan nilai terbaru sebelum terjadi *missing value* tersebut [18].

LOCF dipilih karena algoritma ini termasuk yang paling sederhana dalam memanfaatkan karakteristik *timeseries*. Selain itu karena sering terhadap hubungan yang kuat antara observasi saat ini di titik waktu t_n dengan observasi sebelumnya di waktu t_{n-1} metode ini bisa cukup sukses [19].

4.2.6. Rancangan Pembagian Data

Pembagian Data bertujuan agar terdapat partisi data untuk dilatih (*training set*) dan partisi data untuk validasi (*test set*). Pembagian data ini dilakukan baik untuk data univariat dan multivariat. Pembagian data ini akan menggunakan *library sklearn* dengan fungsi *train_test_split*.

Nantinya skenario membangun model dan *tuning parameter* akan dilakukan dengan partisi 70:30. Dimana *training set* akan mengambil 70% baris data (912 baris) dan *test set* akan mengambil 30% baris data (392 baris). Diluar partisi tersebut hanya akan digunakan apabila melakukan pengujian terhadap model dengan akurasi terbaik yang nantinya akan dihasilkan.

Selain itu 30% partisi *actual test set* akan digunakan untuk membandingkan hasil peramalan atau *predicted test set*. Sehingga perlu dilakukan *reset index* pada partisi *actual test set* agar index dimulai dari 1 karena nantinya *predicted test set* juga akan dimulai dari 1, sehingga nantinya keduanya dapat dibandingkan dengan menggunakan *stacked line chart*.

4.2.7. Rancangan Normalisasi Fitur

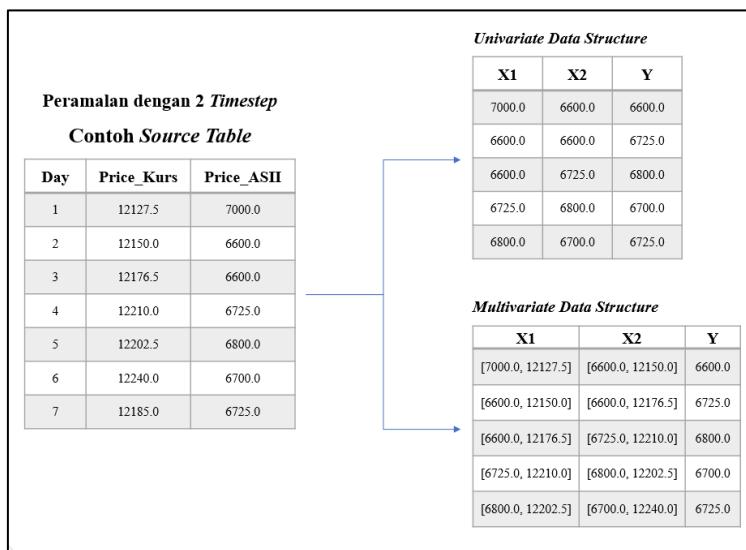
Masing-masing data univariat dan multivariat nantinya akan menggunakan *scaler* yang berbeda mengingat fitur yang digunakan juga akan berbeda. Normalisasi fitur dilakukan dengan rentang fitur atau *feature range* bernilai desimal 0 hingga 1 menggunakan *library MinMaxScaler* dari Python.

4.3. Rancangan Pembentukan Model

Rancangan pada tahap ini diawali dengan membangun struktur data berdasarkan banyaknya *timestep*, kemudian dilanjutkan dengan membangun arsitektur model.

4.3.1. Rancangan Struktur Data Masukan dan Luaran

Tahap ini dilakukan untuk membentuk ulang *dataframe* dalam bentuk *3D tensor shape* sebagai masukan untuk model dimana *output* pada hari ini ditentukan oleh *input* dengan data sebanyak *timestep* yang telah ditentukan. Banyaknya *timestep* akan berpengaruh terhadap banyaknya fitur independen untuk memprediksi data saham hari berikutnya. Ilustrasi dari struktur data berdasarkan *timestep* ditunjukkan pada Gambar 4.1.



Gambar 4.1. Ilustrasi *Timestep*

Pembentukan struktur data menjadi *3D tensor shape* dilakukan terhadap empat partisi data. Dua partisi pertama adalah *training set* data univariat dan *training set* data multivariat untuk pemodelan, kemudian dua partisi terakhir adalah *test set* data univariat dan *test set* data multivariat untuk peramalan.

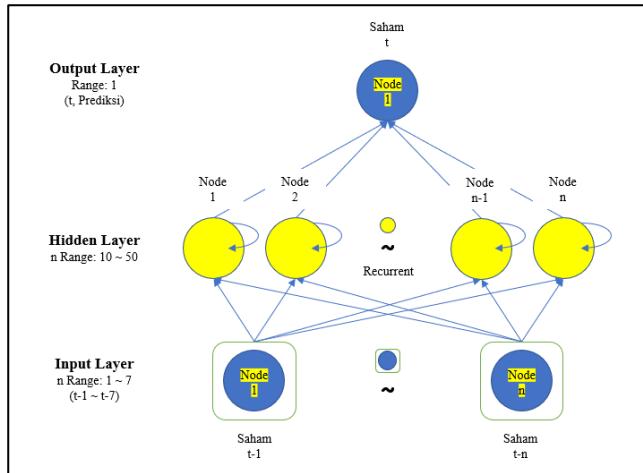
Model LSTM sejatinya mampu memproses data sekuensial dengan baik hingga 1000 *timestep* [20]. Namun *timestep* yang besar akan berpengaruh terhadap waktu pemodelan, sehingga diperlukan batasan untuk menentukan *timestep* yang digunakan. Banyaknya *timestep* yang akan digunakan bersifat *given* yang mana untuk univariat ataupun multivariat akan dimulai dari 1 hingga 7 *timestep*. Alasan *timestep* tersebut dipilih adalah karena terdapat literatur peramalan harga saham menggunakan berbagai varian RNN yang mencoba berbagai macam *timestep* yang hasilnya LSTM memiliki MAPE terbaik untuk *timestep* dibawah 5 dan GRU memiliki MAPE terbaik untuk *timestep* 5 hingga 10, Selain itu hasil percobaan menunjukkan bahwa terlalu banyak *timestep* hanya akan manambah waktu *training* dan prediksi model [21]. Sehingga pemberlakuan peramalan menggunakan 1 hingga 7 *timestep* adalah tolok ukur yang tepat karena mencoba seluruh 5 *timestep* untuk LSTM dan memberikan kelebihan 2 *timestep* untuk bereksperimen.

Satu buah eksperimen *timestep* akan memiliki 324 skenario pemodelan yang mana angka tersebut adalah hasil *full factorial* dari kombinasi *tuning parameter* yang digunakan seperti yang akan dijelaskan pada Subbab 4.5.2. Sehingga dengan desain *full factorial* tersebut memungkinkan terdapat 4536 model terbentuk.

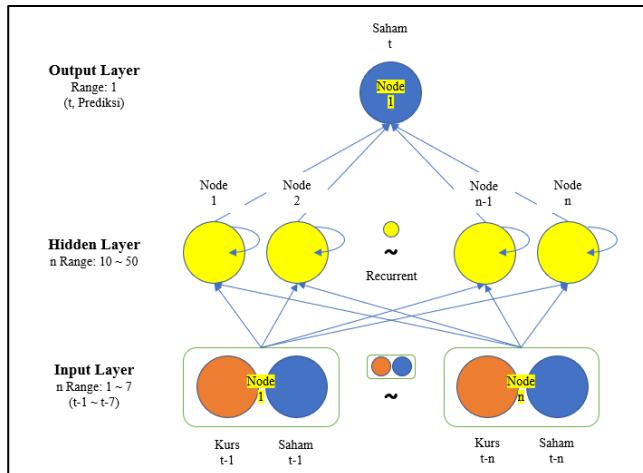
4.3.2. Rancangan Arsitektur LSTM

Secara umum arsitektur model LSTM dibentuk dari *sequential layer* yang terdiri atas *recurrent layer* dan *core layer*. Arsitektur model yang dirancang akan melalui proses *coupling* dan *training*. Arsitektur LSTM dirancang untuk pemodelan dan *tuning parameter* sehingga nilai *node* akan berbeda-beda.

Inisiasi dalam merancang Arsitektur LSTM adalah menyimpan *sequential layer* kedalam dua variabel yang berbeda yakni model univariat dan multivariat. Berikutnya adalah menambahkan *recurrent layer* yakni dengan parameter *units* yang merupakan jumlah *hidden node* di *hidden layer* dan parameter *input shape* yang merupakan dimensi *input layer* seperti yang diilustrasikan pada Gambar 4.2 dan 4.3.



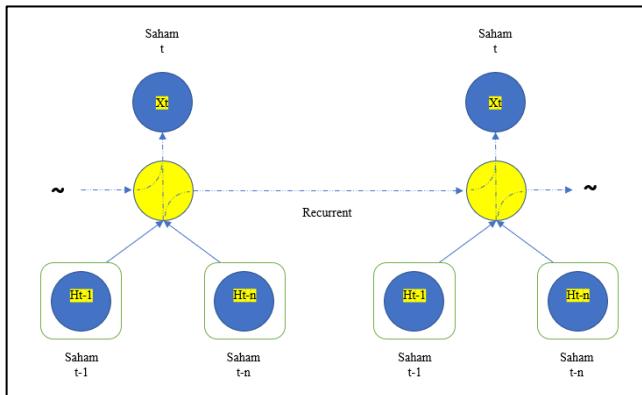
Gambar 4.2. Arsitektur Recurrent Model Univariat



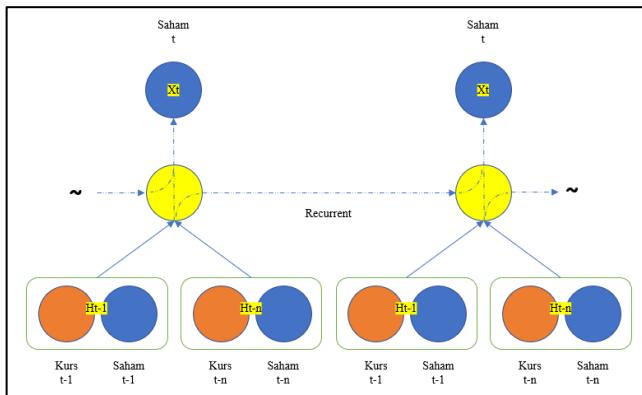
Gambar 4.3. Arsitektur Recurrent Model Multivariat

Seperti yang ditunjukkan Gambar 4.2 dan 4.3 *input node* akan berkisar 1 hingga 7 yang memiliki bentuk *tensor shape* dengan fleksibilitas jumlah timestep (1~7) dan elemen prediktor (1 bila univariat dan 2 bila multivariat) dari training set (70% data).

Sementara itu *Hidden Node* akan berkisar antara 10 hingga 50 sesuai pada perencanaan Subbab 4.5.2 untuk keperluan *tuning parameter*. Cara kerja *hidden node* berdasarkan arsitektur yang diilustrasikan sebelumnya terdapat pada Gambar 4.4 dan 4.5.



Gambar 4.4. Kerja *Hidden Node* Univariat



Gambar 4.5. Kerja *Hidden Node* Multivariat

Current hidden node pada *hidden layer* akan bekerja untuk memodelkan hubungan antara *input* (H_{t-1} hingga H_{t-n}) dan *output* dari *hidden node* sebelumnya agar menghasilkan *output* saat ini (X_t) dan ini akan terus berlangsung antar *node* secara berurutan sehingga model ini kerap disebut dengan *Sequential*.

Recurrent layer akan dilengkapi dengan *core layer* berupa *dropout* dan *dense*. *Dropout* berisi parameter *rate* yang telah ditentukan untuk mencegah *overfitting*, Sementara *dense* berisi parameter *units* yang menjadi *output node* dalam output layer yang bernilai 1 karena untuk memprediksi nilai saham saja seperti yang ditunjukkan pada Gambar 4.2 dan 4.3.

Setelah itu arsitektur yang telah dirancang perlu mengekskusi fungsi *compile* dengan parameter *optimizer* dan *loss* untuk membangun model yang telah dirancang. Setelah itu akan dijalankan fungsi *fitting model* dengan parameter *epoch* dan *batch size* untuk menjalankan pelatihan model. Pengertian dan nilai dari masing-masing parameter di arsitektur LSTM akan dijelaskan pada Subbab 4.5.2. Nilai parameter dapat diatur guna mendapatkan model terbaik.

4.4. Rancangan Peramalan Model

Peramalan model dilakukan dengan memprediksi partisi *test set* menggunakan fungsi *predict* dengan model yang telah dibentuk sehingga mendapatkan hasil peramalan. Hasil peramalan *test set* akan dibandingkan dengan hasil aktual test set menggunakan visualisasi *stacked line chart*. Visualisasi tersebut dilakukan untuk melihat kecenderungan apakah hasil peramalan menggunakan LSTM dapat dengan baik mengikuti fluktuasi data aktual di partisi yang sama.

4.5. Rancangan Evaluasi Model

Rancangan ini dilakukan dengan mengukur performa seluruh model peramalan saham Astra hingga mendapatkan model terbaik berdasarkan MAPE. Selanjutnya model terbaik akan diuji dengan karakter data dan metode yang berbeda.

4.5.1. Rancangan Evaluasi dengan MAPE

Evaluasi MAPE mengukur berapa besarnya persentase simpangan prediksi terhadap nilai aktual dalam bentuk nilai mutlak. Evaluasi akan dibuat dalam bentuk fungsi *python* dengan argumen berupa *dataframe* aktual *test set* (*y*) dan *dataframe* prediksi *test set* (*y'*) didalamnya.

$$MAPE = \frac{100\%}{n} \sum | \frac{y-y'}{y} |$$

Keterangan:
 y = Nilai aktual
 y' = Nilai prediksi
 n = Jumlah data

Setelah selesai membuat fungsi yang berisi perhitungan MAPE, maka fungsi akan dieksekusi dua kali dengan argumen untuk masing-masing kasus univariat dan multivariat. Kemudian hasil evaluasi dan peramalan akan didokumentasikan berdasarkan model yang digunakan.

4.5.2. Rancangan Tuning Parameter

Rencangan ini membuat pelatihan model menjadi iteratif dengan mencoba berbagai jenis kombinasi parameter sehingga diharapkan ditemukan model dengan hasil evaluasi terbaik untuk model univariat atau multivariat. Parameter yang ada ditunjukkan pada Tabel 4.1 yang mana terdapat masing-masing lima parameter *adjustable* dan *non-adjustable*. Parameter yang bersifat *adjustable* memiliki nilai lebih dari satu yang masing-masing akan dicoba untuk *tuning parameter*.

Tabel 4.1. Parameter yang Digunakan [22]

Parameter	Pengertian dan <i>Expected Value</i>
<i>units</i> (LSTM)	Dimensional ruang <i>input</i> model yang merujuk pada jumlah <i>node layer</i> . Nilai dari parameter ini adalah <i>positive integer</i> .
<i>input_shape</i>	<i>Input</i> dari struktur <i>training set</i> yang akan diproses oleh model. Nilai dari parameter ini adalah index 1 dan 2 dari <i>3D Tensor Shape</i> yang mewakili jumlah <i>timestep</i> dan jumlah fitur independen di setiap <i>timestep array</i> .
<i>rate</i> (Dropout)	Memberikan <i>dropout</i> ke input. <i>Dropout</i> adalah fraksi dari unit input yang akan mengalami penurunan. <i>Dropout</i> terdiri dari pengaturan acak <i>fraction rate</i> terhadap unit input menjadi 0 pada setiap pembaruan selama waktu pelatihan model, yang membantu mencegah <i>overfitting</i> . Nilai dari parameter ini adalah <i>float</i> antara 0 dan 1.

<i>units (Dense)</i>	Dimensional <i>output</i> model yang merujuk pada jumlah <i>output</i> node. Nilai parameter ini adalah <i>positive integer</i> .
<i>optimizer</i>	Parameter ini satu dari dua argumen yang dibutuhkan dalam membangun atau mengkompilasi model. Optimizer adalah algoritma yang berjalan untuk miminimalkan nilai <i>loss function</i> dengan memperbarui parameter menggunakan <i>learning rate</i> dan <i>built-in parameter</i> dalam optimizer tersebut [23]. Optimizer dapat bernilai <i>string</i> (menggunakan <i>default parameter</i>) atau bernilai objek yang dapat kita inisiasi lalu atur parameternya (dapat berupa learning rate, momentum, dll) sebelum mendeklarasikan kedalam fungsi <i>compile</i> .
<i>loss</i>	Fungsi objektif atau <i>loss instance</i> . Nilai <i>loss</i> yang akan diminimalkan oleh model kemudian akan menjadi jumlah dari semua loss individual per epoch. Nilai dari parameter ini adalah <i>String</i> untuk nama dari <i>objective function</i> .
<i>x</i>	<i>Input</i> data pada <i>training set</i> .
<i>y</i>	Target data pada <i>training set</i> .
<i>epoch</i>	Jumlah epoch untuk melatih model. Epoch adalah iterasi untuk seluruh record data x dan y yang disediakan. Nilai dari parameter ini adalah <i>positive integer</i> .
<i>batch_size</i>	Angka sampel setiap pembaharuan gradien pada training set di setiap iterasi epoch. Nilai standar adalah 32. Nilai dari parameter ini adalah <i>positive integer</i> atau none.

Lima dari sepuluh parameter direncanakan memiliki nilai lebih dari satu yaitu *hidden units LSTM* (3 nilai), *rate Dropout* (3 nilai), *optimizer* (3 nilai), *epoch* (4 nilai) dan *batch_size* (3 nilai) seperti yang ditunjukkan pada Tabel 4.2. Sehingga dengan desain eksperimen *full factorial* (mencoba semua kombinasi) maka model yang dihasilkan adalah sebanyak 324 model untuk masing-masing skenario *n-timestep* model univariat dan multivariat. Sehingga apabila semakin banyak eksperimen timestep yang dikarenakan *best error* terus menurun maka jumlah model akan semakin banyak karena satu eksperimen *timestep* akan mengalami 324 kali *tuning parameter*.

Tabel 4.2. Nilai Parameter yang Digunakan

Parameter	Nilai Parameter
<i>Units (LSTM)</i>	10, 30, 50
<i>input_shape</i>	<i>3D Tensor Shape</i>
<i>Rate (Dropout)</i>	0.1, 0.3, 0.5
<i>Units (Dense)</i>	1
<i>optimizer</i>	<ul style="list-style-type: none"> ‘Adam’: <i>Adaptive Moment Estimation</i>. Optimizer ini adalah pengembangan dari <i>Stochastic Gradient Descent</i> (SGD) yang didasarkan pada estimasi adaptif momentum orde pertama dan kedua. Adam diibaratkan seperti gabungan dari SGD dengan momentum dan RMSprop. Keunggulannya adalah waktu yang cepat untuk mencapai konvergensi <i>loss function</i> dibanding optimizer lain dan dikenal efisien secara komputasional. Adam memiliki <i>built-in parameter</i> berupa: <i>learning_rate</i> = 0.001, <i>beta_1</i> = 0.9, <i>beta_2</i> = 0.999, <i>epsilon</i> = 1e-07, <i>amsgrad</i> = False [23]. Persamaan: $\theta_{t+1} = \theta_t - \frac{\alpha \cdot \hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon} \quad (4-1)$ <p>Keterangan:</p> <ul style="list-style-type: none"> θ_{t+1} = Nilai bobot saat <i>timestep</i> t+1 θ_t = Nilai bobot saat <i>timestep</i> t+1 α = <i>Learning Rate</i> \hat{m}_t = Prediksi bias momen orde pertama t \hat{v}_t = Prediksi bias momen orde kedua t ϵ = Nilai Epsilon <p>Dengan \hat{m}_t dan \hat{v}_t didapat dari:</p> $\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad \hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (4-2)$ $m_t = (1 - \beta_1)g_t + \beta_1 m_{t-1} \quad (4-3)$ $v_t = (1 - \beta_2)g_t + \beta_2 v_{t-1} \quad (4-4)$

	<ul style="list-style-type: none"> • ‘RMSprop’: <i>Root Mean Squared Propagation</i>. Optimizer RMSprop memperbarui parameter bobot layaknya <i>backward propagation</i> tetapi perhitungan gradiennya sedikit berbeda yakni membaginya dengan akar kuadrat dari persamaan yang ditunjukkan rumus dibawah. RMSprop memiliki <i>built-in parameter</i> berupa: <i>learning_rate</i> = 0.001, <i>rho</i> = 0.9, <i>momentum</i> = 0.0, <i>epsilon</i> = 1e-07, <i>centered</i> = False [23]. Persamaan: $\theta_{t+1} = \theta_t - \frac{\alpha}{\sqrt{(1-\gamma)g_{t-1}^2 + \gamma.g_t + \epsilon}} \quad (4-5)$ <p>Keterangan:</p> <ul style="list-style-type: none"> θ_{t+1} = Nilai bobot saat <i>timestep</i> t+1 θ_t = Nilai bobot saat <i>timestep</i> t+1 α = <i>Learning Rate</i> γ = Nilai <i>Rho</i> g_t = Nilai Gradien terbaru ϵ = Nilai Epsilon <ul style="list-style-type: none"> • ‘SGD’: <i>Stochastic Gradient Descent</i>. Optimizer ini adalah varian dari <i>Gradient Descent</i> (GD) namun pembaharuan bobot parameter tunggal dari model dilakukan terus menerus berdasarkan banyaknya observasi data. Pembaharuan yang terus menerus tersebut memungkinkan penggunaan memori yang kecil karena perhitungan gradien pada SGD tidak dilakukan sekali untuk seluruh observasi data. SGD memiliki <i>built-in parameter</i> berupa: <i>learning_rate</i> = 0.01, <i>momentum</i> = 0.0, <i>nesterov</i> = False [23]. Persamaan: $\theta = \theta - \alpha . g \quad (4-6)$ <p>Keterangan:</p> <ul style="list-style-type: none"> θ = Nilai bobot (<i>Single Weight</i>) α = <i>Learning Rate</i> g = Nilai Gradien terbaru
<i>loss</i>	<i>mean_squared_error</i>

x	<i>Dataframe Input Training Set</i>
y	<i>Dataframe Input Test Set</i>
<i>epoch</i>	50, 100, 150, 200
<i>batch_size</i>	32, 64, 96

Hasil dari *tuning parameter* akan diletakkan ke *sheet excel* untuk mendapat model terbaik untuk diuji kembali.

4.5.3. Rancangan Skenario Pengujian Model Terbaik

Setelah merekap hasil evaluasi dari *tuning parameter* dari rancangan yang diuraikan di tahap sebelumnya, dilakukan empat skenario untuk pengujian kualitas model yang dilakukan dengan *pre-trained model* atau model terbaik kedua kasus.

4.5.3.1. Skenario Proporsi Pembagian Data

Skenario ini dilakukan dengan membandingkan hasil dari peramalan model LSTM terbaik berproporsi 70:30 dengan proporsi yang lain. Skenario proporsi yang diterapkan adalah 60:40 dan 80:20 pada *training set* dan *test set*. Kedua proporsi tersebut dipilih karena masing-masing mewakili jumlah *training set* yang lebih banyak dan lebih sedikit dari semula. Skenario ini sekaligus didesain untuk menunjukkan apakah besar proporsi pada data mengakibatkan dampak pada performa pemodelan dan peramalan harga saham dengan LSTM.

4.5.3.2. Skenario Penggunaan Dataset Lain

Skenario ini dilakukan dengan data saham diluar Astra yang dipilih berdasarkan karakter yang berbeda yakni berdasarkan rentang nilai dan tren naik turun saham. Skenario ini dilakukan dengan mengambil dua data saham lain yakni Kimia Farma Persero Tbk dan Semen Indonesia Persero Tbk dimana keduanya memiliki tren serta rentang nilai yang secara signifikan berbeda dengan PT Astra International Tbk.

4.5.3.3. Skenario Perbandingan Metode

Skenario ini dilakukan dengan metode *Neural Network* yang lain yang dapat menerima masukan dan parameter sejenis dengan LSTM, sehingga metode pembanding yang akan digunakan adalah *Gated Recurrent Unit* (GRU) yang juga merupakan pengembangan dari RNN tetapi memiliki arsitektur yang berbeda dari LSTM dan SimpleRNN. Nantinya akan terdapat acuan lain berupa hasil peramalan dari RNN dan ANN.

4.5.3.4. Skenario Data Masa Depan

Skenario ini dialakukan dengan mengganti sumber data untuk peramalan sebelumnya dengan data saham Astra dan Nilai Tukar USD/IDR di masa depan. Sehingga data yang diramalkan adalah data setelah 1 Oktober 2019 hingga 20 Mei 2020. Sementara data yang dimodelkan dengan LSTM adalah data utama yang digunakan sebelumnya yakni dari 1 Oktober 2014 hingga 30 September 2019.

Halaman ini sengaja dikosongkan

BAB V

IMPLEMENTASI

Bab implementasi berisi penerapan dari perancangan yang telah dilakukan sesuai dengan metode pengembangan yang dibuat. Bagian yang dijelaskan yaitu lingkungan implementasi dan seluruh pemrosesan data dalam bentuk *source code* dengan bahasa pemrograman Python.

5.1. Lingkungan Implementasi

Untuk mendukung pelaksanaan penelitian tugas akhir ini menggunakan satu buah laptop yakni Asus X450JB dengan spesifikasi yang ditunjukkan pada Tabel 5.1.

Tabel 5.1. Spesifikasi *Hardware*

Processor	Intel Core i7-4720HQ
GPU	Nvidia Geforce GT940M
Memory	8GB GDDR3
Arsitektur Sistem	64-bit Operating System, X64-based processor

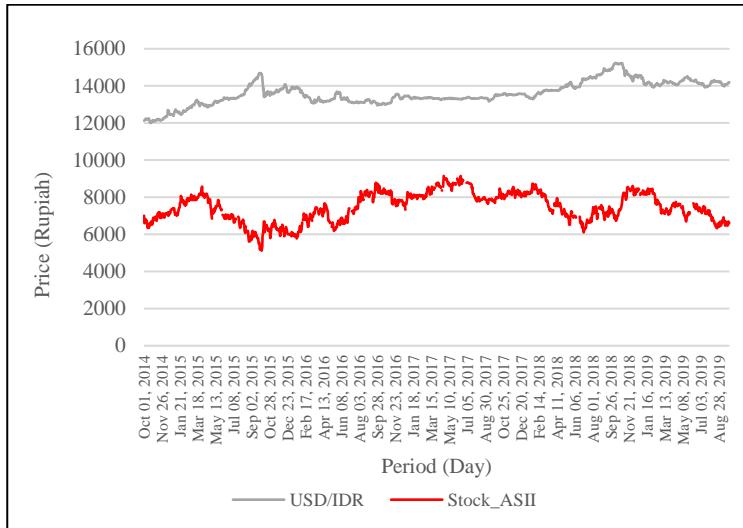
Sementara pemrosesan data dilakukan menggunakan bahasa pemrograman, perangkat lunak dan beberapa *library* yang harus diinstalasi seperti yang ditunjukkan pada Tabel 5.2.

Tabel 5.2. *Library* Yang Digunakan

Bahasa Pemrograman	Python
Computational Environment	Spyder
Virtual Environment	Anaconda
Library	Pandas, Numpy, Matplotlib, Seaborn, Sklearn, Keras, Tensorflow, Time dan Functools

5.2. Pengambilan Data

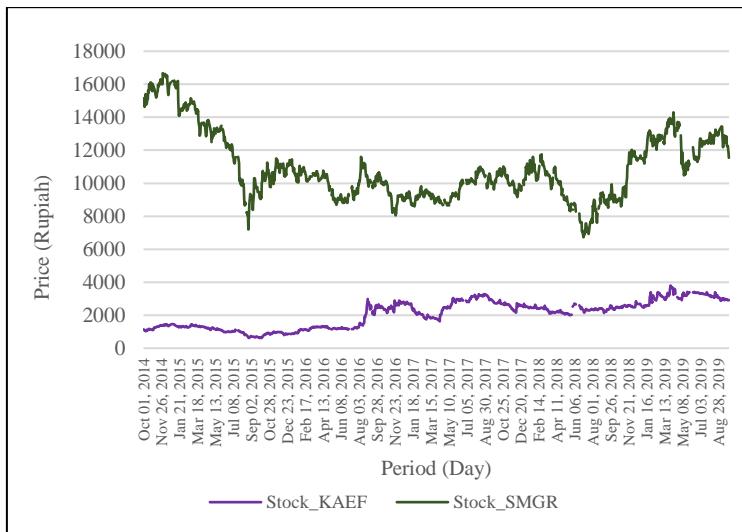
Data saham utama dalam studi kasus adalah saham Astra (ASII) yang dalam setahun terakhir cukup menurun, tetapi dalam lima tahun terakhir cukup fluktuatif. Data lain yang digunakan untuk meramalkan sebagai fitur independen adalah data nilai tukar USD/IDR yang dalam lima tahun terakhir tidak terlalu fluktuatif seperti yang ditunjukkan pada Gambar 5.1.



Gambar 5.1. Grafik Saham ASII dan Nilai Tukar

Kedua data ini nantinya akan digunakan untuk pemodelan univariat dan multivariat. Univariat berarti peramalan harga saham dilakukan berdasarkan historis harga saham, sementara multivariat berarti peramalan harga saham dilakukan berdasarkan historis harga nilai tukar USD/IDR atau dengan fitur independen. Seluruh data dihimpun dari sebuah situs Investasi dengan URL <https://www.investing.com/>. Data dapat diperoleh dengan mudah dengan mengetikkan data yang ingin dicari melalui *search bar* dari situs tersebut.

Dua data saham lain yang digunakan untuk menguji model terbaik peramalan harga saham Astra diambil berdasarkan dua kategori yang berbeda, masing-masing berdasarkan saham *top gainers* dan *top losers* saat pengambilan data dilakukan pada tanggal 6 Desember 2019. Sumber data dipilih dari dua kategori tersebut dengan harapan data memiliki karakteristik tren yang berbeda. Selain itu pemilihan data di masing-masing kategori dipilih berdasarkan rentang nilai yang cukup kontras jika dibandingkan dengan saham Astra.



Gambar 5.2. Grafik Saham KAEF dan SMGR

Dari kategori *top gainers* dipilih saham Semen Indonesia (SMGR) karena saat diamati tren saham tersebut naik dalam satu tahun terakhir serta interval harganya secara signifikan lebih tinggi dari saham Astra. Dari kategori *top losers* dipilih saham Kimia Farma (KAEF) karena saat diamati tren saham tersebut turun dalam satu tahun terakhir serta interval harganya secara signifikan lebih rendah dari saham Astra sebagaimana yang ditunjukkan pada Gambar 5.2.

Tabel 5.3. Ikhtisar Karakter Saham 6 Desember 2019

Saham	Tren Harian	Nilai Saham	Jenis Dataset	Kategori Saham
Astra International Kode: ASII	2.29%	6700	Pemodelan	-
Kimia Farma Kode: KAEF	-6.59%	1700	Pengujian	<i>Top Losers</i>
Semen Gresik Kode: SMGR	5.97%	12425	Pengujian	<i>Top Gainers</i>

Dari Tabel 5.3 dapat dilihat bahwa setiap saham memiliki karakter data yang berbeda pada saat data diambil baik dari segi tren ataupun rentang nilai sehingga *dataset* saham diluar Astra cukup layak untuk pengujian model terbaik. Ikhtisar untuk data yang akan diolah bisa jadi berbeda karena hari terakhir pada data yang diambil jatuh pada 30 September 2019.

5.3. Pra-Pemrosesan Data

Pada tahap ini dilakukan rekayasa data yang sedemikian hingga menghasilkan *training set* dan *test set* yang siap digunakan untuk peramalan univariat dan multivariat.

5.3.1. Standarisasi Data

Standarisasi dilakukan untuk memastikan apakah semua muatan data sudah standar seperti penulisan dan tipe data. Hal pertama yang perlu dilakukan adalah *import* semua *library* yang diperlukan selama proses penggerjaan seperti yang ditunjukkan Kode Program 5.1. Proses ini didukung oleh beberapa *library* misalnya rekayasa data tabular menggunakan *numpy* dan *pandas*, visualisasi data menggunakan *library matplotlib* dan *seaborn*, pemodelan menggunakan *library keras* dan *sklearn*.

```

1. import numpy as np
2. import matplotlib.pyplot as plt
3. import seaborn as sns
4. import pandas as pd
5. import time
6. from numpy import hstack
7. from functools import reduce
8. from sklearn.model_selection import train_test_split
9. from sklearn.preprocessing import MinMaxScaler
10. from keras.models import Sequential
11. from keras.layers import LSTM
12. from keras.layers import GRU
13. from keras.layers import Dense
14. from keras.layers import Dropout

```

Kode Program 5.1. Load Libraries

Setelah *import* beberapa *library* yang diperlukan, semua *dataset* yang diperlukan dapat dimuat baik variabel independen maupun variabel dependen dengan *library pandas*. Argumen yang disematkan kedalam method *read_csv* adalah *thousands* dengan value "," untuk memastikan bahwa price tidak bernilai *object* dan praktis akan dikonversi menjadi numerik sebagaimana yang ditunjukkan pada Kode Program 5.2.

```

1. dataset_Kurs = pd.read_csv('C:/Users/muslikhannur/Documents/8 - Tugas Akhir/Code and Dataset/Historical Data USD_IDR.csv', thousands = ",")
2. dataset_ASII = pd.read_csv('C:/Users/muslikhannur/Documents/8 - Tugas Akhir/Code and Dataset/HistoricalDataStockASII.csv', thousands = ",")
3. dataset_KAEF = pd.read_csv('C:/Users/muslikhannur/Documents/8 - Tugas Akhir/Code and Dataset/HistoricalDataStockKAEF.csv', thousands = ",")
4. dataset_SMGR = pd.read_csv('C:/Users/muslikhannur/Documents/8 - Tugas Akhir/Code and Dataset/HistoricalDataStockSMGR.csv', thousands = ",")

```

Kode Program 5.2. Load dan Standarisasi Data

Setelah *dataset* dimuat kedalam program dan distandardkan, cek kembali tipe datanya. Data numerik harus bertipe data sesuai. Pengecekan tipe data ditunjukkan di Kode Program 5.3.

1. dataset_Kurs.dtypes
2. dataset_ASII.dtypes
3. dataset_KAEF.dtypes
4. dataset_SMGR.dtypes

Kode Program 5.3. Pengecekan Tipe Data

Setelah data yang dimuat sudah benar dan standar maka proses rekayasa data berikutnya dapat dijalankan.

5.3.2. Penggabungan Data

Penggabungan data dilakukan untuk menggabungkan keempat sumber data dengan menggunakan fungsi *reduce* dari *library functools* dan fungsi *merge* dari *library pandas*. Analogi yang digunakan adalah seperti *left join* pada SQL dimana penggabungan data bertumpu pada fitur yang dijadikan *key* yakni ‘*Date*’ pada masing-masing tabel seperti yang ditunjukkan pada Kode Program 5.4. *Key* yang dijadikan rujukan adalah key dari data kurs karena memiliki data yang lebih lengkap untuk semua tanggal.

1. dataset_merge = [dataset_Kurs, dataset_ASII, dataset_KAEF, dataset_SMGR]
2. dataset_merge = reduce(lambda left,right: pd.merge(left,right,on='Date',how='left'), dataset_merge)
3. dataset_merge = dataset_merge.iloc[:-1]
4. dataset_merge = dataset_merge.reset_index()
5. dataset_merge = dataset_merge.drop(['index', 'Change %_x', 'Change %_y', 'Vol.', 'Vol._x', 'Vol._y'], axis = 1)
6. dataset_merge.columns = ['Date', 'Price_Kurs', 'Open_Kurs', 'High_Kurs', 'Low_Kurs', 'Price_ASII', 'Open_ASII', 'High_ASII', 'Low_ASII', 'Price_KAEF', 'Open_KAEF', 'High_KAEF', 'Low_KAEF', 'Price_SMGR', 'Open_SMGR', 'High_SMGR', 'Low_SMGR']

Kode Program 5.4. Penggabungan Data

Data yang telah digabungkan perlu diatur kembali urutannya atau *reverse index* dengan fungsi'.iloc[::-1]' karena data sumber meletakkan data tanggal terbaru pada baris dan indeks teratas. Kemudian indeks tersebut diatur agar urutan indeks kembali seperti semula tetapi dengan kondisi urutan data sudah benar dengan tanggal lama di posisi teratas atau *reset index*.

Selanjutnya dilakukan eliminasi fitur yang tidak memiliki makna yang berarti terhadap pemrosesan data yakni sebanyak 7 dari 24 fitur yang ada. Sisa sebanyak 17 fitur kemudian dinamai ulang untuk dilanjutkan ke tahap berikutnya.

5.3.3. Pengikhtisaran Data

Luaran dari proses ini adalah data dapat dipahami secara komprehensif berdasarkan pola dan kecenderungan yang ada dari visualisasi data uji korelasi dan pengamatan tren.

5.3.1.1. Uji Korelasi

Uji korelasi dilakukan untuk mengetahui kekuatan hubungan antar fitur satu dengan yang lain. Dalam melakukan proses visualisasi *Correlation Plot*, dibutuhkan fungsi *heatmap* dari *library seaborn* yang sudah diimpor sejak awal. Pembuatan *heatmap correlation plot* ditunjukkan pada Kode Program 5.5.

```
1. cor_mat = dataset_merge[:].corr()
2. mask = np.array(cor_mat)
3. mask[np.tril_indices_from(mask)] = False
4. fig=plt.gcf()
5. fig.set_size_inches(30,12)
6. sns.heatmap(data=cor_mat, mask=mask, square=True,
   annot=True, cbar=True)
```

Kode Program 5.5. Membuat *Correlation Plot*

Fitur dengan nilai yang berbanding lurus akan berkorelasi positif dan fitur dengan nilai yang berbanding terbalik akan berkorelasi negatif. Nilai korelasi berkisar antara -1 hingga 1 dimana semakin mendekati 0 akan semakin lemah korelasinya.

5.3.1.2. Pengamatan Tren

Pola atau tren dari keempat data memiliki karakter data yang berbeda. *stacked line chart* dibuat untuk memastikan bahwa data saham lain cukup berbeda karakternya untuk megudi kekuatan model terbaik dari peramalan saham Astra. Proses visualisasi ini didukung fungsi *plot* dari *library matplotlib*. Visualisasi dapat diperjelas dengan menambahkan aspek lain seperti *legend*, *axis* dan *label* seperti pada Kode Program 5.6.

```

1. plt.plot(dataset_merge['Price_Kurs'], color = 'red',
           label = 'USD/IDR')
2. plt.plot(dataset_merge['Price_ASII'], color = 'green',
           label = 'ASII')
3. plt.plot(dataset_merge['Price_KAEF'], color = 'blue',
           label = 'KAEF')
4. plt.plot(dataset_merge['Price_SMGR'], color = 'purple',
           label = 'SMGR')
5. plt.title('Grafik Kurs, ASII, KAEF, SMGR')
6. plt.xlabel('Time')
7. plt.ylabel('Rupiah')
8. plt.legend()
9. plt.show()
```

Kode Program 5.6. Membuat *Stacked Line Chart*

5.3.4. Eliminasi Fitur

Setelah melalui proses pengikhtisan maka diketahui fitur yang tidak diperlukan untuk pemodelan yakni data harga buka, tertinggi dan terendah untuk setiap data karena memiliki korelasi hampir sempurna terhadap *price* dari setiap data sehingga diwakilkan oleh *price* tersebut. Seleksi fitur dapat melalui fungsi *drop* ditunjukkan pada Kode Program 5.7.

```

1. dataset_merge = dataset_merge.drop(['Open_Kurs',
                                      'High_kurs', 'Low_kurs', 'Open_ASII', 'High_ASII',
                                      'Low_ASII', 'Open_KAEF', 'High_KAEF', 'Low_KAEF',
                                      'Open_SMGR', 'High_SMGR', 'Low_SMGR'], axis = 1)
```

Kode Program 5.7. *Feature Selection*

5.3.5. Pemeriksaan *Missing Value*

Pengisian *missing value* diisi berdasarkan nilai pada periode sebelumnya menggunakan nilai parameter ‘*ffill*’ pada parameter *method* di fungsi *fillna* seperti pada Kode Program 5.8.

```
1. dataset_merge.isnull().values.any()
2. dataset_merge.isnull().sum()
3. dataset_merge = dataset_merge.fillna(method='ffill')
```

Kode Program 5.8. Pengisian Missing Values

5.3.6. Pembagian Data

Pembagian data dibagi atas *training set* dan *test set*. Skenario standar yang dilakukan adalah dengan membagi *training set* dan *test set* dengan proporsi 70:30 seperti pada Kode Program 5.9.

```
1. n_testProp = 0.3
```

Kode Program 5.9. Inisiasi Proporsi Test Set

Nilai proporsi *test set* disimpan ke dalam variabel agar memudahkan ketika melakukan skenario dengan proposi lain.

5.3.6.1. Pembagian Data Kasus Univariat

Data univariat berupa data saham Astra diambil dari *dataframe* gabungan yang telah dibuat dengan fungsi *loc*. Data dibagi dengan nama ‘*data_trainUni*’ dan ‘*data_testUni*’ dengan fungsi *train_test_split* sebagaimana ditunjukkan pada Kode Program 5.10. Perlu dipastikan bahwa pembagian data *time series* tidak dilakukan secara acak dengan parameter *shuffle* bernilai *False*.

```
1. data_Univariate = dataset_merge.loc[:,['Price_ASII']]
2. data_trainUni, data_testUni = train_test_split(
    data_Univariate, test_size=n_testProp, shuffle=False)
3. data_testUni= data_testUni.reset_index().iloc[:,1:2]
4. data_testActual = data_testUni
```

Kode Program 5.10. Splitting Data Univariat

5.3.1.4. Pembagian Data Kasus Multivariat

Data multivariat berupa data kurs dan saham Astra diambil dari dataframe gabungan yang telah dibuat dengan fungsi *loc*. Kemudian dilakukan split dengan nama ‘*data_trainMulti*’ dan ‘*data_testMulti*’ dengan fungsi *train_test_split*. Sebagaimana ditunjukkan pada Kode Program 5.12 bahwa perlu dipastikan *dataframe* multivariat dipisah kembali menjadi dua bagian karena akan dilakukan normalisasi dengan dua *scaler* yang berbeda untuk setiap fitur seperti pada Kode Program 5.11.

```

1. data_Multivariate = dataset_merge.loc[:,['Price_Kurs',
   'Price_ASII']]
2. data_trainMulti, data_testMulti = train_test_split
   (data_Multivariate, test_size=n_testProp, shuffle=False)
3. data_testMulti = data_testMulti.reset_index().iloc[:,1:3]
4. data_trainMultiKurs, data_trainMultiSaham =
   data_trainMulti.iloc[:,0:1], data_trainMulti.iloc[:,1:2]
```

Kode Program 5.11. *Splitting* Data Multivariat

5.3.7. Normalisasi Fitur

Fase terakhir dalam pra-pemrosesn data adalah dilakukannya normalisasi atau *feature scaling*. Normalisasi dilakukan dengan menggunakan *library sklearn* dengan fungsi *MinMaxScaler* dengan interval 0 sampai dengan 1. Sebelumnya perlu dilakukan *split* pada data terlebih dahulu seperti yang akan dijelaskan di Subbab 5.3.6. Hal tersebut dikarenakan normalisasi dilakukan terpisah untuk *training set* dan *test set*.

```

1. # Scaling Train Univariate
2. sc = MinMaxScaler(feature_range = (0, 1))
3. data_trainUni = sc.fit_transform(data_trainUni)
4. # Scaling Train Multivariate using Different Scaler
5. scI = MinMaxScaler(feature_range = (0, 1))
6. scD = MinMaxScaler(feature_range = (0, 1))
7. data_trainMultiKurs = scI.fit_transform(data_trainMultiKurs)
8. data_trainMultiSaham = scD.fit_transform(data_trainMultiSaham)
```

Kode Program 5.12. *Feature Scaling*

Perlu diingat bahwa *scaler* pada data multivariat menggunakan *scaler* yang berbeda seperti pada Kode Program 5.12. Hal ini dilakukan untuk konsistensi ketika data didenormalisasi.

5.4. Pembentukan Model

Pembentukan model biasa disebut dengan istilah *training model*. Tahap ini diawali dengan pembentukan struktur data masukan dan luaran, kemudian dilanjutkan dengan fase pembentukan dan pelatihan model.

5.4.1. Struktur Data Masukan dan Luaran

Luaran dari pembentukan struktur data ini adalah struktur *3D Tensor Shape* dengan jumlah *timestep* yang telah ditetapkan. *Timestep* adalah berapa banyak data masa lalu untuk meramalkan data saat ini. *Timestep* akan disimpan dalam variabel ‘n_timestep’ dengan nilai numerik ‘n’. Program akan meramalkan data saat ini sebagai *output* dengan ‘n’ data sebelumnya sebagai *input*. Nilai ‘n_timestep’ dimulai dari 1 dan terus naik hingga 7 agar sesuai dengan yang sudah dijelaskan pada bagian perancangan struktur data.

5.4.1.1. Struktur Data Univariat

Langkah pertama adalah membentuk struktur data *training set* univariat sebagaimana ditunjukkan pada Kode Program 5.13 yang mana terbagi atas ‘x_trainUni’ untuk merepresentasikan data saham sebanyak *timestep* yang ditentukan dan ‘y_trainUni’ untuk merepresentasikan harga saham pada periode berikutnya.

```

1. x_trainUni = []
2. y_trainUni = []
3. for i in range(n_timestep, len(data_trainUni)):
4.     x_trainUni.append(data_trainUni[i-n_timestep:i, 0])
5.     y_trainUni.append(data_trainUni [i, 0])
6. x_trainUni, y_trainUni = np.array(x_trainUni),
np.array(y_trainUni)
7. x_trainUni = np.reshape(x_trainUni, (x_trainUni.shape[0],
x_trainUni.shape[1], 1))

```

Kode Program 5.13. Struktur *Training Set* Univariat

Langkah kedua adalah membentuk struktur data *test set* univariat sebagaimana ditunjukkan pada Kode Program 5.14 yang mana terdiri atas ‘x_testUni’ untuk merepresentasikan data saham sebanyak *timestep* yang ditentukan. Variabel ‘x_testUni’ akan berperan sebagai fitur independen yang akan diramalkan nilai targetnya pada *test set*. Struktur data dibuat dengan menggunakan mekanisme *Looping* pada Python sepanjang ‘inputs_uni’ atau proporsi *test set* ditambah sejumlah ‘n’ *timestep* yang ditentukan. Penambahan panjang pada *loop* adalah untuk kesesuaian struktur data *test set* yang mana bila meramalkan saham hari pertama pada *test set* tentu memerlukan ‘n’ data saham kebelakang yang terdapat di *training set*. Sehingga penambahan panjang dari *timestep* ini merujuk pada ‘n’ hari terakhir pada partisi *training set*.

```

1. inputs_uni = data_Univariate[len(data_Univariate) -
   len(data_testUni) - n_timestep: ].values
2. inputs_uni = sc.transform(inputs_uni)
3. x_testUni = []
4. for i in range(n_timestep, len(inputs_uni)):
5.     x_testUni.append(inputs_uni[i-n_timestep:i, 0])
6. x_testUni = np.array(x_testUni)
7. x_testUni = np.reshape(x_testUni, (x_testUni.shape[0],
   x_testUni.shape[1], 1))

```

Kode Program 5.14. Struktur *Test Set* Univariat

5.4.1.2. Struktur Data Multivariat

Langkah pertama adalah membentuk struktur data *training set* multivariat sebagaimana ditunjukkan pada Kode Program 5.15 dengan ‘x_trainMulti’ untuk merepresentasikan data kurs dan saham sebanyak *timestep* yang ditentukan dan ‘y_trainUni’ untuk merepresentasikan hasil harga saham pada periode berikutnya. Struktur data dibuat dengan menggunakan mekanisme *looping* pada Python sepanjang proporsi *training*. Perbedaan struktur data kali ini jika dibandingkan univariat adalah bahwa *input* dilakukan dengan fungsi *hstack* untuk

memastikan bahwa kurs dan saham pada hari yang sama terhimpun didalam satu *array* atau sel yang sama.

```

1. data_trainMultiHstack = hstack((data_trainMultiKurs,
   data_trainMultiSaham))
2. x_trainMulti = []
3. y_trainMulti = []
4. for i in range(n_timestep, len(data_trainMultiHstack)):
5.     x_trainMulti.append(data_trainMultiHstack[(i-
   n_timestep):i])
6.     y_trainMulti.append(data_trainMultiSaham[i,0])
7. x_trainMulti, y_trainMulti = np.array(x_trainMulti),
   np.array(y_trainMulti)
8. for i in range(len(x_trainMulti)):
9.     print(x_trainMulti[i], y_trainMulti[i])

```

Kode Program 5.15. Struktur *Training Set* Multivariat

Langkah kedua adalah membentuk struktur data *test set* multivariat sebagaimana ditunjukkan pada Kode Program 5.16 dengan ‘x_testMulti’ untuk merepresentasikan data kurs dan saham sebanyak *timestep* yang ditentukan. Variabel ‘x_testMulti’ akan berperan sebagai fitur independen yang akan diramalkan nilai targetnya pada *test set*. Struktur data dibuat dengan menggunakan mekanisme *looping* pada Python sepanjang ‘inputs_multi’ atau proporsi *test set* ditambah dengan *timestep* yang ditentukan. Penambahan ‘n’ timestep pada panjang *loop* adalah untuk kesesuaian struktur data *test set* sama seperti halnya pada pembentukan struktur data *test set* untuk kasus univariat. Sebelumnya dua kolom dipecah untuk nantinya digabungkan dengan fungsi *hstack* agar satu *array* mengandung kurs dan saham pada hari yang sama.

```

1. inputs_multi = data_Multivariate[len(data_Multivariate) -
   len(data_testMulti) - n_timestep: ].values
2. inputs_multi = pd.DataFrame(inputs_multi)
3. inputs_multi.columns = ['Price_Kurs', 'Price_Saham']
4. data_testMultiKurs, data_testMultiSaham =
   inputs_multi.iloc[:,0:1], inputs_multi.iloc[:,1:2]
5. data_testMultiKurs = scI.transform(data_testMultiKurs)
6. data_testMultiSaham = scD.transform(data_testMultiSaham)

```

```

7. data_testMultiHstack = hstack((data_testMultiKurs,
   data_testMultiSaham))
8. x_testMulti = []
9. for i in range(n_timestep, len(inputs_multi)):
10.    x_testMulti.append(data_testMultiHstack[i-
      n_timestep:i, :])
11. x_testMulti = np.array(x_testMulti)
12. x_testMulti = x_testMulti.reshape((x_testMulti.shape[0],
   x_testMulti.shape[1], 2))

```

Kode Program 5.16. Struktur Test Set Multivariat

5.4.2. Pembentukan Arsitektur LSTM

Di tahap ini terdiri atas inisiasi nilai parameter kedalam variabel dan pembentukan arsitektur itu sendiri. Kode Program 5.17 menunjukkan inisiasi nilai standar yang disimpan dalam variabel untuk diisikan kedalam parameter arsitektur model. Inisiasi variabel ini berguna untuk efektifitas kode karena dalam satu variabel dapat digunakan untuk dua model yakni univariat dan multivariat. Nilai ini nantinya dapat berubah tergantung pada nilai *tuning parameter* yang ditetapkan..

```

1. n_LSTMunits = 10
2. n_DropoutRate = 0.1
3. n_DenseUnits = 1
4. n_optimizer = 'adam'
5. n_loss = 'mean_squared_error'
6. n_epoch = 50
7. n_batchsize = 32

```

Kode Program 5.17. Inisiasi Variabel untuk Nilai Parameter

Arsitektur model univariat disimpan dalam ‘modelUni’ terdiri atas *Recurrent Layer* berupa ‘LSTM’ dan *Core Layer* berupa *Dropout* untuk regularisasi dan *Dense* sebagai *output*. Sebagaimana ditunjukkan pada Kode Program 5.18, model akan mengeksekusi fungsi *compile* kemudian mengeksekusi fungsi *training* dengan menghitung waktu eksekusinya.

```

1. modelUni = Sequential()

```

```

2. modelUni.add(LSTM(units = n_LSTMunits, input_shape =
(x_trainUni.shape[1], x_trainUni.shape[2])))
3. modelUni.add(Dropout(rate = n_DropoutRate))
4. modelUni.add(Dense(units = n_DenseUnits))
5. modelUni.compile(optimizer = n_optimizer, loss = n_loss)
6. startTrain = time.perf_counter()
7. historyUni = modelUni.fit(x = x_trainUni, y = y_trainUni,
epochs = n_epoch, batch_size = n_batchsize)
8. elapsedTrainUni = time.perf_counter() - startTrain
9. TTUni = '%.4f' % elapsedTrainUni
10. LastLossUni = '%.4f' % historyUni.history['loss'][-1]

```

Kode Program 5.18. Arsitektur Model Univariat

Arsitektur model multivariat yang tersimpan dalam ‘modelMulti’ sebagaimana ditunjukkan pada Kode Program 5.19 memiliki baris kode yang hampir sama secara keseluruhan namun akan menghasilkan model yang berbeda.

```

1. modelMulti = Sequential()
2. modelMulti.add(LSTM(units = n_LSTMunits, input_shape =
(x_trainMulti.shape[1] , x_trainMulti.shape[2])))
3. modelMulti.add(Dropout(rate = n_DropoutRate))
4. modelMulti.add(Dense(units = n_DenseUnits))
5. modelMulti.compile(optimizer = n_optimizer, loss = n_loss)
6. startTrain = time.perf_counter()
7. historyMulti = modelMulti.fit(x = x_trainMulti, y =
y_trainMulti, epochs = n_epoch, batch_size = n_batchsize)
8. elapsedTrainMulti = time.perf_counter() - startTrain
9. TTMulti = '%.4f' % elapsedTrainMulti
10. LastLossMulti = '%.4f' % historyMulti.history['loss'][-1]

```

Kode Program 5.19. Arsitektur Model Multivariat

Riwayat pelatihan model disimpan kedalam ‘historyUni’ dan ‘historyMulti’ dimana variabel tersebut berguna untuk melihat tingkat penurunan *loss* di setiap *epoch* untuk masing-masing model. Grafik *training loss* ini berguna untuk menentukan epoch yang tepat untuk model dengan melihat kovergensi dari *training loss* antar periode. Waktu pelatihan model juga perlu disimpan sebagaimana yang ditunjukkan Kode Program 5.20.

```

1. figLoss = plt.gcf()
2. plt.plot(historyUni.history['loss'])
3. plt.plot(historyMulti.history['loss'])
4. plt.title(str(n_LSTMunits) + ' LSTM Units, ' +
   str(n_DenseUnits) + ' Dense Units, ' + str(n_DropoutRate)
   + ' Dropout Rate,\n' + str(n_optimizer) + ' Optimizer, '
   + str(n_epoch) + ' Epoch, ' + str(n_batchsize) +
   ' Batch Size.')
5. plt.ylabel('Loss')
6. plt.xlabel('Epoch')
7. plt.figtext(0.60, 0.70, 'TT Uni: ' + str(TTUni) +
   '\nTT Multi: ' + str(TTMulti) + '\nLastLoss Uni: ' +
   str>LastLossUni) + '\nLastLoss Multi: ' +
   str>LastLossMulti))
8. plt.legend(['Train Loss Univariate',
   'Train Loss Multivariate'], loc='upper left')
9. plt.show()
10. figLoss.savefig('C:/Users/muslikhannur/Documents/8 - Tugas
   Akhir/Code and Dataset/Hasil/' +str(n_testProp)+ ' Test
   Size, ' +str(n_timestep)+ ' Timestep, ' +str(n_LSTMunits)+
   ' LSTM Units, ' +str(n_DropoutRate)+ ' Dropout Rate,
   +str(n_optimizer)+ ' Optimizer, ' +str(n_epoch)+ ' Epoch,
   ' +str(n_batchsize)+ ' Batch Size - Training Loss.png')

```

Kode Program 5.20. *Stacked Line Chart* pada *Training Loss*

5.5. Peramalan Model

Proses ini dilakukan dua kali dengan meramalkan data univariat dan multivariat seperti halnya proses sebelumnya. Hasil peramalan univariat sebagaimana yang ditunjukkan pada Kode Program 5.21 akan disimpan kedalam ‘y_testUni’ yang mana prosesnya model univariat akan menjalankan fungsi *predict* terhadap prediktor ‘x_testUni’ yang telah dibuat.

```

1. startTestUni = time.perf_counter()
2. y_testUni = modelUni.predict(x_testUni)
3. elapsedTest = time.perf_counter() - startTestUni
4. print('Predicting Time Univariate: %.3f seconds.'
   % elapsedTest)
5. data_testPredUni = sc.inverse_transform(y_testUni)

```

Kode Program 5.21. Peramalan Univariat pada *Test Set*

Seperti halnya peramalan univariat, hasil peramalan multivariat univariat sebagaimana yang ditunjukkan pada Kode Program 5.22 akan disimpan kedalam ‘y_testMulti’ yang mana prosesnya model multivariat akan menjalankan fungsi *predict* terhadap prediktor ‘x_testMulti’ yang telah dibuat.

```

1. startTestMulti = time.perf_counter()
2. y_testMulti = modelMulti.predict(x_testMulti)
3. elapsedTest = time.perf_counter() - startTestMulti
4. print('Predicting Time Multivariate: %.3f seconds.' % elapsedTest)
5. data_testPredMulti = scD.inverse_transform(y_testMulti)
```

Kode Program 5.22. Peramalan Multivariat pada *Test Set*

Hasil kedua model peramalan kemudian di visualisasikan kedalam *stacked line chart* dengan menggunakan fungsi *plot* dari *library matplotlib* dengan mengisi beberapa argument. Visualisasi ini dilakukan untuk melihat apakah hasilnya dapat mengikuti tren data aktual pada *test set*. Hasil peramalan dalam format tabel dan visualisasi disimpan ke dalam *local files* sebagaimana ditunjukkan pada Kode Program 5.23 yang mana dokumentasi ini penting untuk evaluasi *tuning parameter*.

```

1. A_PredictionResult =
   np.hstack([data_testPredUni,data_testPredMulti])
2. A_PredictionResult = np.around(A_PredictionResult,
   decimals=2, out=None)
3. A_PredictionResult = A_PredictionResult.astype(str)
4.
5. plt.plot(data_testActual, color = 'red', label =
   'Real Stock Price', linewidth=0.5)
6. plt.plot(data_testPredUni, color = 'blue', label =
   'Univariate - Predicted Stock Price', linewidth=0.5)
7. plt.plot(data_testPredMulti, color = 'orange', label =
   'Multivariate - Predicted Stock Price', linewidth=0.5)
8. plt.title(str(n_LSTMunits)+ ' LSTM Units, '+str(n_DenseUnits)
   + ' Dense Units, ' +str(n_DropoutRate)+ ' Dropout Rate,\n'
   +str(n_optimizer)+ ' Optimizer, ' +str(n_epoch)+ ' Epoch,
   ' +str(n_batchsize)+ ' Batch Size.')
9. plt.xlabel('Time')
```

```

10. plt.ylabel('Stock Price')
11. plt.figtext(0.63, 0.77, 'MAPE Uni: ' +str(MAPEUni)+ 
   '\nMAPE Multi: ' +str(MAPEMulti))
12. plt.legend()
13. plt.show()
14. figPredict.savefig('C:/Users/muslikhannur/Documents/8 - 
   Tugas Akhir/Code and Dataset/Hasil/' +str(n_testProp)+ ' 
   Test Size, ' +str(n_timestep)+ ' Timestep, ' 
   +str(n_LSTMunits)+ ' LSTM Units, ' +str(n_DropoutRate)+ ' 
   Dropout Rate, ' +str(n_optimizer)+ ' Optimizer, ' 
   +str(n_epoch)+ ' Epoch, ' +str(n_batchsize)+ ' Batch Size 
   - Testing Result.png', dpi = 100)

```

Kode Program 5.23. Stacked Line Chart Hasil Prediksi

5.6. Evaluasi Model

Luaran dari proses ini adalah kumpulan hasil evaluasi berbagai model peramalan menggunakan metrik MAPE.

5.6.1. Evaluasi dengan MAPE

Evaluasi dengan MAPE diawali dengan membuat *method* ‘mean_absolute_percentage_error’ dengan *argument* ‘y_true, y_pred’ yang merupakan data aktual dan data prediksi. Diakhir Kode Program 5.24 dilakukan *print method* tersebut dengan argumen yang berbeda untuk model univariat dan multivariat.

```

1. def mean_absolute_percentage_error(y_true, y_pred):
2.     y_true, y_pred = np.array(y_true), np.array(y_pred)
3.     return np.mean(np.abs((y_true - y_pred) / y_true)) * 100
4. MAPEUni = '%.4f' % mean_absolute_percentage_error(
   data_testUni, data_testPredUni)
5. MAPEMulti = '%.4f' % mean_absolute_percentage_error(
   data_testActual, data_testPredMulti)

```

Kode Program 5.24. Method Metriks Evaluasi MAPE

5.6.2. Tuning Parameter

Luaran dari proses ini adalah munculnya hasil evaluasi yang lebih baik dengan model yang berbeda. Satu saja perubahan parameter sudah dapat membuat model yang berbeda.

Serangkaian *comment* pada Kode Program 5.25 menunjukkan bahwa nilai pada baris tersebut dapat diubah atau bersifat *adjustable* untuk proses *tuning parameter*.

```
1. n_LSTMunits = 10 # Adjustable: 10; 30; 50
2. n_DropoutRate = 0.1 # Adjustable: 0.1; 0.3; 0.5
3. n_DenseUnits = 1
4. n_optimizer = 'adam' # Adjustable: adam, rmsprop, sgd
5. n_loss = 'mean_squared_error'
6. n_epoch = 50 # Adjustable: 50, 100, 150, 200
7. n_batchsize = 32 # Adjustable: 32, 64, 96
```

Kode Program 5.25. Mengubah Nilai Parameter Variabel

5.6.3. Skenario Pengujian Model Terbaik

Setelah mendapatkan model terbaik untuk peramalan harga saham Astra untuk kasus univariat dan multivariat melalui tuning parameter, berikutnya adalah melakukan skenario untuk menguji model terbaik univariat dan multivariat. Skenario pengujian model terbaik terbagi atas tiga buah skenario yaitu skenario perubahan proporsi data, perubahan sumber data dan perubahan penggunaan metode.

5.6.3.1. Skenario Proporsi Pembagian Data

Skenario ini cukup dilakukan dengan mengganti nilai dari variabel ‘n_testProp’ yang merepresentasikan proporsi *test set* sebagaimana ditunjukkan pada Kode Program 5.26 menjadi 0.2 dan 0.4. Setelah nilai diganti dilakukan *running* ulang terhadap semua *source code* di bawahnya.

```
1. n_testProp = 0.2 #Last SKENARIO: 0.3; 0.2; 0.4
```

Kode Program 5.26. Skenario Proporsi *Train:Test*

5.6.3.2. Skenario Penggunaan Dataset Lain

Untuk data univariat skenario ini cukup dilakukan dengan mengganti *column name* menjadi ‘Price_KAEF’ atau ‘Price_SMGR’ pada variabel ‘data_Univariate’. Sementara

untuk data multivariat skenario ini cukup dilakukan dengan mengganti *column name* menjadi ‘Price_KAEF’ atau ‘Price_SMGR’ disamping *column* kurs pada variabel ‘data_Univariate’. Letak perubahan nilai untuk skenario ini ditunjukkan Kode Program 5.27. Setelah nilai diganti dilakukan *running* ulang terhadap semua *source code* di bawahnya.

```
1. data_Univariate = dataset_merge.loc[:,['Price_KAEF']]
   #Last SKENARIO: Price_ASII, Price_KAEF; Price_SMGR
2. data_Multivariate = dataset_merge.loc[:,['Price_Kurs',
   'Price_KAEF']]
```

Kode Program 5.27. Skenario Penggunaan Saham Lain

5.6.3.3. Skenario Perbandingan Metode

Skenario menggunakan metode lain berarti membutuhkan import *Recurrent Layer* dari *library Keras* dimana dalam hal ini menggunakan layer GRU (*Gated Recurrent Unit*) sebagaimana yang ditunjukkan pada Kode Program 5.28.

```
1. from keras.layers import LSTM
2. from keras.layers import GRU
```

Kode Program 5.28. Library Penggunaan Metode Lain

Selanjutnya skenario dapat dijalankan cukup dengan mengganti satu baris *recurrent layer* pada arsitektur model dari LSTM menjadi GRU sebagaimana ditunjukkan pada Kode Program 5.29 yang kemudian perlu dijalankan kembali *source code* di bawahnya untuk mendapat hasil yang berbeda.

```
1. modelUni.add(GRU(units = n_LSTMunits, input_shape =
(x_trainUni.shape[1], x_trainUni.shape[2])))
   #Last SKENARIO: LSTM, GRU
2. modelMulti.add(GRU(units = n_LSTMunits, input_shape =
(x_trainMulti.shape[1] , x_trainMulti.shape[2]))
   #Last SKENARIO: LSTM, GRU
```

Kode Program 5.29. Skenario Metode Lain

BAB VI

HASIL DAN PEMBAHASAN

Bab hasil dan pembahasan berisi pemaparan hasil dari implementasi yang telah dilakukan sesuai dengan metode pengembangan yang dibuat dalam Peramalan Harga Saham menggunakan *Long Short-Term Memory* (LSTM).

6.1. Hasil Pengambilan Data

Pengambilan Data dilakukan dengan mengunduh data pada situs Investing. Hasil pengambilan data adalah data nilai tukar USD/IDR dan tiga buah data harga saham.

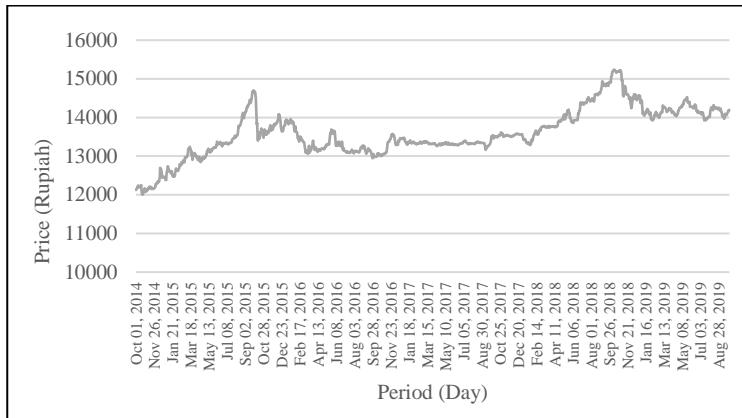
6.1.1. Data Nilai Tukar USD/IDR

Data yang pertama kali diunduh adalah data nilai tukar (kurs) USD/IDR dengan rentang kuartal empat (Q4) 2014 hingga kuartal tiga (Q3) 2019. Data pada historis kurs ini nantinya akan digunakan sebagai fitur dependen pada peramalan multivariat. Data kurs ditunjukkan pada Tabel 6.1.

Tabel 6.1. Tampilan Tabel Nilai Tukar USD/IDR

Date	Price	Open	High	Low	Change
Sep 30, 2019	14195	14155.0	14195.0	14155.0	0.21%
Sep 27, 2019	14165	14185.0	14200.0	14165.0	-0.09%
Sep 26, 2019	14177,5	14147.5	14177.5	14145.5	0.19%
...
Oct 03, 2014	12176,5	12121.5	12176.5	12121.5	0.22%
Oct 02, 2014	12150	12145.0	12175.0	12120.0	0.19%
Oct 01, 2014	12127,5	12167.5	12202.5	12127.5	-0.47%

Selama 5 tahun data kurs menunjukkan nilai yang fluktuatif seperti pada Gambar 6.1. Terdapat 1304 baris data kurs dengan rata-rata nilai kurs 13599 yang mana memiliki nilai maksimal di angka 15235 dan nilai minimal di angka 12000.

**Gambar 6.1. Grafik Nilai Tukar USD/IDR**

6.1.2. Data Harga Saham

Setelah data kurs diunduh, Data berikutnya yang diambil adalah data saham dengan rentang kuartal empat (Q4) 2014 hingga kuartal tiga (Q3) 2019. Data pada historis saham ini nantinya akan digunakan sebagai fitur dependen dalam peramalan.

Data yang berhasil diambil adalah 3 buah data saham dengan rincian 1 data saham untuk mencari model terbaik (pemodelan) dan 2 data saham untuk pengujian model terbaik. Data saham untuk pemodelan adalah data saham dari PT Astra International Tbk (ASII) yang ditunjukkan pada Tabel 6.2.

Tabel 6.2. Tampilan Tabel Harga Saham ASII

Date	Price	Open	High	Low	Vol.	Change
Sep 30, 2019	6600	6650	6675	6575	21.09M	-0.75%
Sep 27, 2019	6650	6700	6700	6600	9.83M	-0.75%
Sep 26, 2019	6700	6575	6700	6525	37.98M	3.08%
...
Oct 03, 2014	6600	6700	6700	6450	52.77M	0.00%
Oct 02, 2014	6600	6975	6975	6600	77.53M	-5.71%
Oct 01, 2014	7000	7000	7075	7000	16.22M	-0.71%

Data saham untuk pengujian model terbaik yang pertama adalah data saham dari sebuah perusahaan farmasi yaitu PT Kimia Farma Tbk (KAEF) yang ditunjukkan pada Tabel 6.3.

Tabel 6.3. Tampilan Tabel Harga Saham KAEF

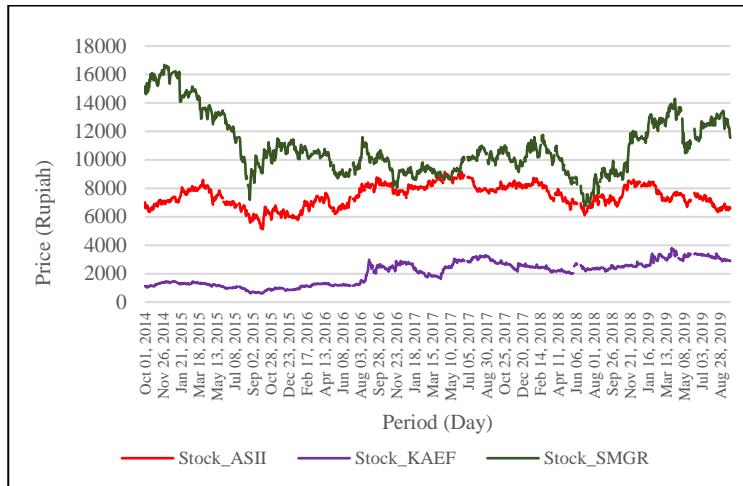
Date	Price	Open	High	Low	Vol.	Change
Sep 30, 2019	2900	2900	2920	2880	27.10K	-0.68%
Sep 27, 2019	2920	2930	2930	2900	431.40K	-0.34%
Sep 26, 2019	2930	2890	2950	2890	21.00K	0.69%
...
Oct 03, 2014	1070	1105	1110	1035	3.10M	-3.17%
Oct 02, 2014	1105	1135	1140	1105	726.60K	-3.49%
Oct 01, 2014	1145	1140	1150	1140	316.90K	-0.43%

Data saham untuk pengujian model terbaik yang kedua adalah data saham dari sebuah perusahaan semen yaitu PT Semen Indonesia Tbk (SMGR) yang ditunjukkan pada Tabel 6.4.

Tabel 6.4. Tampilan Tabel Harga Saham SMGR

Date	Price	Open	High	Low	Vol.	Change
Sep 30, 2019	11550	11850	11850	11425	7.82M	-2.53%
Sep 27, 2019	11850	12025	12150	11750	5.30M	-3.27%
Sep 26, 2019	12250	12200	12500	12025	5.68M	0.20%
...
Oct 03, 2014	14625	14850	14900	14525	7.53M	-0.51%
Oct 02, 2014	14700	14950	15000	14700	11.74M	-2.97%
Oct 01, 2014	15150	15625	15700	15150	3.97M	-1.78%

Setelah mendapatkan ketiga data saham, Dilakukan sebuah visualisasi dengan *line chart* untuk melihat perbedaan karakter pada ketiga saham seperti yang ditunjukkan pada Gambar 6.2.



Gambar 6.2. Grafik Seluruh Fitur Saham

Dari grafik dapat dilihat secara jelas perbedaan karakter berupa rentang nilai dan tren dari masing-masing saham. Rentang nilai terkecil hingga terbesar adalah KAEF, ASII dan SMGR yang digambarkan melalui nilai rata-rata, nilai minimum dan maksimum. Perihal tren saham dalam 5 tahun juga signifikan berbeda yang mana KAEF naik 60,52%, ASII turun 6,06% dan SMGR turun 31,17% seperti yang ditunjukkan pada Tabel 6.5.

Tabel 6.5. Ikhtisar Karakter Saham 30 September 2019

Pembanding	ASII	KAEF	SMGR
Jumlah Baris	1213	1212	1213
Harga 30/09/2019	6600	2900	11550
Nilai Minimal	5125	615	6725
Nilai Maksimal	9150	3800	16675
Nilai Rata-Rata	7462,35	2064,42	10941,92
Tren 5 Tahunan	-6,06%	60,52%	-31,17%
Korelasi dengan Kurs	-20%	39%	-44%

6.2. Hasil Pra-Pemrosesan Data

Pada bagian ini akan dijabarkan seluruh hasil dari proses pra-pemrosesan data dari standarisasi data hingga mendapat luaran berupa data yang sudah terpartisi (*training set, test set*) dan ternormalisasi untuk dimodelkan.

6.2.1. Hasil Standarisasi Data

Pada Subbab 5.3.1. terkait Implementasi Standarisasi Data sebelumnya pemberian argument *thousands* pada saat *load dataset* membuat tipe data pada fitur penting menjadi sesuai yakni int64 yang mana sebelumnya adalah *object*.

Out[1]:	
Date	object
Price	int64
Open	int64
High	int64
Low	int64
Vol.	object
Change %	object
dtype:	object

Gambar 6.3. Hasil Standarisasi Fitur Harga

Apabila seluruh fitur harga yakni *price, open, high* dan *low* pada harga saham dan kurs sudah sesuai seperti Gambar 6.3 maka proses pra-pemrosesan data dapat dilanjutkan.

6.2.2. Hasil Penggabungan Data

Penggabungan data menggunakan mekanisme *left join* dengan *key* berupa ‘Date’ dari kurs dimuat dalam ‘dataset_Merge’. Hasilnya adalah *dataframe* dengan satu buah fitur *series* waktu yaitu ‘Date’ dengan gabungan 4 buah *dataframe* (Kurs, ASII, KAEF, SMGR) dengan harganya masing-masing dengan dimensi total 1304 baris dan 25 kolom seperti yang ditunjukkan pada *variable explorer* di Tabel 6.6.

Tabel 6.6. Hasil Penggabungan Semua Variabel Dataframe

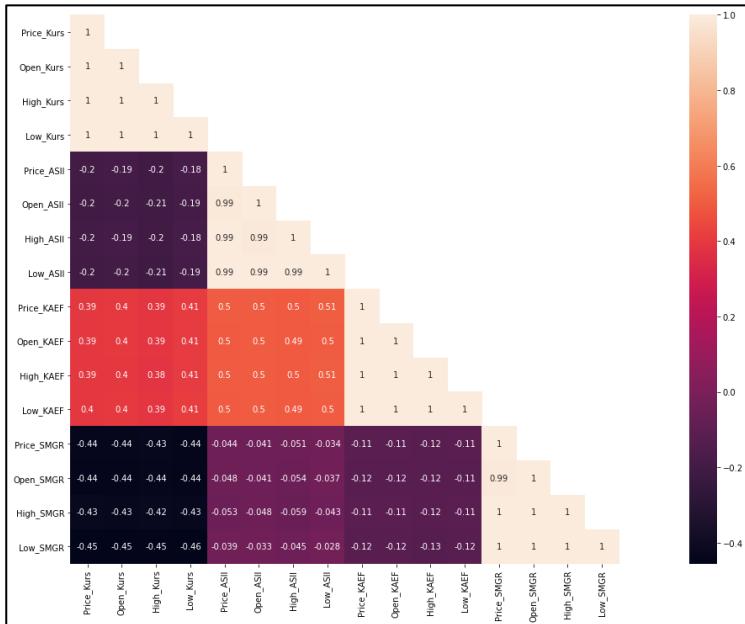
dataset_merge	DataFrame	(1304, 25)	Column names: index, Date, Price_x, Open_x, High_x, Low_x, Change %_x, ...
---------------	-----------	------------	--

6.2.3. Hasil Pengikhtasaran Data

Hasil dari pengikhtasaran data adalah *insight* untuk sebelum tahap pra-pemrosesan data berikutnya yang direpresentasikan dengan visualisasi uji korelasi dan pengamatan tren.

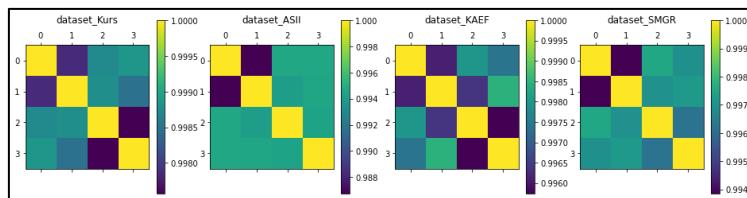
6.2.3.1. Hasil Uji Korelasi

Data ‘dataset_Merge’ yang dihasilkan di proses sebelumnya dilakukan uji korelasi pada fitur numerik seperti Gambar 6.4.

**Gambar 6.4. Correlation Plot Variabel Dataframe Gabungan**

Dari grafik *correlation plot* di atas dapat dilihat korelasi satu fitur dengan yang lain yang direpresentasikan dengan angka dan kecerahan warna. Setelah diamati lebih lanjut fitur harga pada setiap *dataframe* (*Price*, *Open*, *High* dan *Low*), fitur tersebut memiliki korelasi yang hampir sama terhadap kelompok fitur yang lain. Hal tersebut dibuktikan dengan himpunan warna yang saling berkelompok membentuk persegi.

Kemudian untuk memperjelas, setiap kelompok fitur dipecah menjadi 4 *correlation plot*. Kembali terbukti bahwa nilai korelasi fitur di setiap kelompok memiliki nilai yang berdekatan. Meskipun warnanya kini berbeda seperti yang ditunjukkan pada Gambar 6.5, Rentang nilai untuk seluruh warna bernilai antara 99% hingga 100% atau secara sempurna berbanding lurus untuk fitur *Price*, *Open*, *High* dan *Low*.



Gambar 6.5. *Correlation Plot Variable Setiap Dataframe*

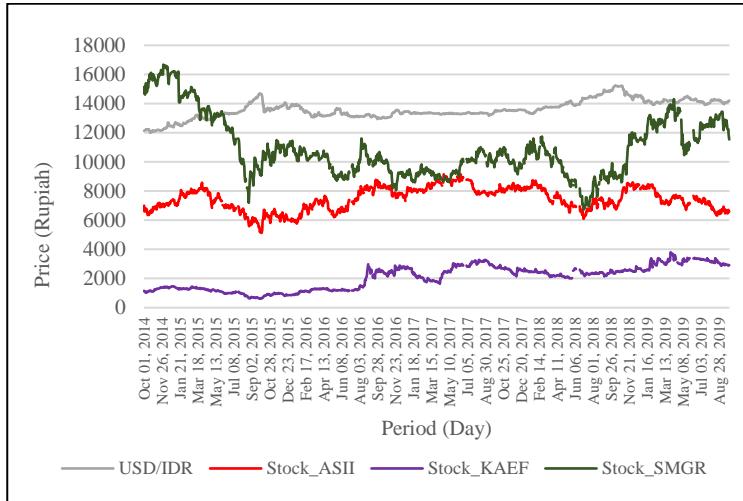
Dengan tingkat korelasi fitur yang hampir sempurna untuk setiap kelompok, nantinya akan dilakukan proses seleksi fitur karena kelompok fitur tersebut dapat diwakilkan satu fitur saja. *Correlation plot* dengan fitur yang sudah diwakilkan dan lebih jelas keterbacaannya ditunjukkan pada Gambar 6.6.

	Price_Kurs	Price_ASII	Price_KAEF	Price_SMGR
Price_Kurs	1	-0,194	0,396	-0,427
Price_ASII	-0,194	1	0,506	-0,045
Price_KAEF	0,396	0,506	1	-0,114
Price_SMGR	-0,427	-0,045	-0,114	1

Gambar 6.6. *Correlation Plot* untuk Fitur *Closed Price*

6.2.3.2. Hasil Pengamatan Tren

Pengamatan tren dilakukan dengan *stacked line chart* pada setiap fitur. Seperti yang ditunjukkan pada Gambar 6.7.



Gambar 6.7. Stacked Line Chart untuk Fitur Closed Price

Dari grafik terlihat bahwa terdapat titik-titik kosong memotong beberapa *series* yang divisualisasikan menandakan terdapat *missing value*. Untuk hasil pengamatan tren di setiap fitur secara jelas dapat dilihat pada Tabel 6.7.

Tabel 6.7. Pengamatan Tren 30 September 2019

Tren	Kurs	ASII	KAEF	SMGR
Last Price	14195	6600	2900	11550
Harian	0,21%	-0,76%	-0,69%	-2,60%
Mingguan	0,77%	-0,38%	-1,38%	-8,23%
Bulanan	0,07%	-1,14%	-5,52%	-14,72%
1 Tahun	-5,04%	-10,98%	15,17%	16,88%
3 Tahun	8,06%	-25,00%	14,83%	12,55%
5 Tahun	14,56%	-6,06%	60,52%	-31,17%

Dari tabel hasil pengamatan tren terlihat bahwa harga Kurs memiliki tren harga yang terus meningkat. Pada harga saham terdapat penurunan secara konstan pada saham ASII yang merupakan fitur untuk pemodelan. Pada saham pembanding, KAEF cenderung naik dan hanya terdapat sedikit penurunan yang tidak signifikan. Sementara untuk SMGR cenderung turun dan hanya terdapat sedikit kenaikan yang tidak signifikan.

6.2.4. Hasil Eliminasi Fitur

Eliminasi fitur dilakukan hingga hanya terdapat 5 buah fitur yang digunakan yakni ‘Date’, ‘Price_Kurs’, ‘Price_ASII’, ‘Price_KAEF’ dan ‘Price_SMGR’ seperti pada Tabel 6.8.

Tabel 6.8. Pratinjau Dataframe setelah Feature Selection

Index	Date	Price_Kurs	Price_ASII	Price_KAEF	Price_SMGR
0	Oct 01, 2014	12127,5	7000	1145	15150
1	Oct 02, 2014	12150	6600	1105	14700
2	Oct 03, 2014	12176,5	6600	1070	14625
...
1301	Sep 26, 2019	14177,5	6700	2930	12250
1302	Sep 27, 2019	14165	6650	2920	11850
1303	Sep 30, 2019	14195	6600	2900	11550

Eliminasi pertama dilakukan pada fitur 'Change %' dan 'Vol' karena fitur tersebut tidak diperlukan serta dari awal bernilai objek sehingga fitur menjadidi sebanyak 17 buah. Eliminasi berikutnya dilakukan setelah mendapatkan *insight* dari *correlation plot* yakni fitur yang dapat diwakilkan antara lain *Open*, *High* dan *Low* untuk setiap Kurs dan Saham. Fitur tersebut diwakili oleh fitur *Price* yang merupakan harga tutup saham. Sehingga total terdapat 20 fitur yang dieliminasi dari total 25 fitur tersedia di awal.

6.2.5. Hasil Pemeriksaan *Missing Value*

Pengecekan *missing value* menghasilkan jumlah baris kosong setiap fitur. Hasilnya pada seluruh data saham terdapat *missing value*. Hal ini dikarenakan baris pada kurs dolar lebih banyak dibandingkan baris pada data saham. Data harga saham sendiri memang tidak aktif mengumumkan harga terkini pada tanggal-tanggal tertentu yang mengakibatkan *missing value*.

```
In [6]: dataset_merge.isnull().values.any()
      ...: dataset_merge.isnull().sum()
Out[6]:
Date          0
Price_Kurs    0
Price_ASII   91
Price_KAEF   92
Price_SMGR   91
dtype: int64
```

Gambar 6.8. Pengecekan *Missing Value* sebelum *Treatment*

Nilai yang kosong akan disimbolkan dengan ‘nan’ seperti yang ditunjukkan pada Tabel 6.9. Dapat dilihat bahwa harga saham cenderung kosong ketika hari-hari besar seperti hari raya natal 2014 dan tahun baru 2015.

Tabel 6.9. Pengecekan *Missing Value* dalam *Dataframe*

Index	Date	Price_Kurs	Price_ASII	Price_KAEF	Price_SMGR
...
61	Dec 25, 2014	12467.5	nan	nan	nan
62	Dec 26, 2014	12467.5	nan	nan	nan
63	Dec 29, 2014	12447.0	7350.0	1455.0	16175.0
64	Dec 30, 2014	12446.5	7425.0	1465.0	16200.0
65	Dec 31, 2014	12385.0	nan	nan	nan
66	Jan 01, 2015	12385.0	nan	nan	nan

Setelah diketahui bahwa terdapat lebih dari 90 *missing value* di masing-masing data saham, maka dilakukan pengisian data saham menggunakan *method* `fillna` pada Python. Hal ini memungkinkan pengisian *missing value* dengan menggunakan nilai pada hari sebelumnya. Setelah pengecekan kembali yang ditunjukkan Gambar 6.9, *missing value* tidak terdapat lagi.

```
In [9]: dataset_merge =
dataset_merge.fillna(method='ffill')
...: dataset_merge.isnull().values.any()
...: dataset_merge.isnull().sum()
Out[9]:
Date      0
Price_Kurs 0
Price_ASII 0
Price_KAEF 0
Price_SMGR 0
dtype: int64
```

Gambar 6.9. Pengecekan *Missing Value* setelah *Treatment*

Setelah pengisian *missing value* menggunakan nilai saham hari sebelumnya, Nilai ‘nan’ yang ditunjukkan pada Tabel 6.8 sudah tidak terdapat lagi pada ‘dataset_Merge’ seperti yang ditunjukkan pada Tabel 6.10.

Tabel 6.10. Pengisian *Missing Value* dalam *Dataframe*

Index	Date	Price_Kurs	Price_ASII	Price_KAEF	Price_SMGR
...
61	Dec 25, 2014	12467.5	7325.0	1435.0	16100.0
62	Dec 26, 2014	12467.5	7325.0	1435.0	16100.0
63	Dec 29, 2014	12447.0	7350.0	1455.0	16175.0
64	Dec 30, 2014	12446.5	7425.0	1465.0	16200.0
65	Dec 31, 2014	12385.0	7425.0	1465.0	16200.0
66	Jan 01, 2015	12385.0	7425.0	1465.0	16200.0

6.2.6. Hasil Pembagian Data

Pembagian data dilakukan dengan partisi 70% training set untuk pemodelan dan 30% test set untuk validasi.

6.2.6.1. Hasil Pembagian Data Kasus Univariat

Pada kasus univariat data dibagi dalam variabel ‘data_trainUni’ dengan 912 baris dan ‘data_testUni’ dengan 392 baris, keduanya memiliki satu buah fitur yakni ‘Price_ASII’ seperti yang ditunjukkan pada Tabel 6.11.

Tabel 6.11. Hasil Pembagian Data Univariat

data_trainUni	DataFrame (912, 1)	Column names: Price_ASII
data_testUni	DataFrame (392, 1)	Column names: Price_ASII

6.2.6.2. Hasil Pembagian Data Kasus Multivariat

Pada kasus multivariat data dibagi dalam variabel ‘data_trainMulti’ dengan 912 baris dan ‘data_testMulti’ dengan 392 baris, keduanya memiliki dua buah fitur yakni ‘Price_kurs’ dan ‘Price_ASII’ seperti yang ditunjukkan pada Tabel 6.12.

Tabel 6.12. Hasil Pembagian Data Multivariat

data_trainMulti	DataFrame (912, 2)	Column names: Price_Kurs, Price_ASII
data_testMulti	DataFrame (392, 2)	Column names: Price_Kurs, Price_ASII

6.2.7. Hasil Normalisasi Fitur

Normalisasi fitur untuk harga saham dan harga kurs menggunakan *object scaler* yang berbeda dengan rentang nilai 0 hingga 1 seperti yang ditunjukkan pada Gambar 6.10.

Tabel 6.13. Hasil Feature Scaling

[0.04726599]	[0.46583851]
[0.05560704]	[0.36645963]
[0.06543095]	[0.36645963]
[0.07784986]	[0.39751553]
[0.07506951]	[0.41614907]

6.3. Hasil Peramalan Data Univariat

Subbab ini berisi hasil struktur data sebagai masukan model, kemudian dilanjutkan hasil *tuning parameter* yang sudah mencakup pemodelan, peramalan dan evaluasi univariat.

6.3.1. Hasil Pembentukan Struktur Data Univariat

Struktur data untuk *training set* tergantung pada *timestep* yang digunakan. Pada univariat *multi-timestep* struktur *training set* dapat dilihat pada Gambar 6.11. Prediktor berupa 2 *array* yang disatukan dalam 1 *array* merepresentasikan harga saham hingga dua hari sebelumnya dengan regresor di sebelah kanan.

Tabel 6.14. Struktur Training Set Univariat Multi-timestep

[[0.46583851]
[0.36645963]] 0.36645962732919246
[[0.36645963]
[0.36645963]] 0.39751552795031064
[[0.36645963]
[0.39751553]] 0.4161490683229814
[[0.39751553]
[0.41614907]] 0.3913043478260869
[[0.41614907]
[0.39130435]] 0.39751552795031064

Struktur data untuk *test set* sama seperti *training set* namun tidak memiliki regresor seperti pada Gambar 6.12 karena regresor itu sendiri yang akan diprediksi pada partisi ini.

Tabel 6.15. Struktur Test Set Univariat Multi-timestep

[[0.49068323]
[0.54037267]]
[[0.54037267]
[0.54037267]]
[[0.54037267]
[0.60248447]]
[[0.60248447]
[0.63354037]]
[[0.63354037]
[0.60869565]]

6.3.2. Hasil Tuning Parameter Univariat

Tuning parameter univariat berisi percobaan kombinasi terhadap *given parameter* untuk pemodelan yakni *units*, *rate*, *optimizer*, *epoch* dan *batch_size* mulai dari *timestep* 1 hingga *threshold* berhentinya eksperimen *timestep*.

a. Timestep 1

Pada eksperimen meramalkan harga saham ASII menggunakan harga saham ASII 1 hari sebelumnya didapatkan 324 model dari kombinasi 5 buah parameter. Dari hasil eksperimen yang ditunjukkan pada Tabel 6.16 didapatkan rata-rata pada masing-masing pengukuran yakni MAPE sebesar 2,7182%; *time* sebesar 10,5116s; dan nilai *training loss* sebesar 0,0121.

Tabel 6.16. Hasil Tuning Parameter 1 Timestep Univariat

Best No.	units, rate, optimizer, epoch, batch_size	MAPE (%)	Training Time (s)	Training Loss
1	50, 0.1, RMSprop, 50, 96	1,347	4,4867	0,002
2	30, 0.1, RMSprop, 200, 64	1,3471	13,1666	0,0016
3	50, 0.5, RMSprop, 200, 64	1,3473	16,262	0,0022
4	50, 0.3, RMSprop, 150, 32	1,3474	18,0577	0,0016
5	50, 0.5, RMSprop, 200, 32	1,3475	24,6391	0,002
n
320	30, 0.5, SGD, 50, 96	6,3965	4,5693	0,04
321	10, 0.5, SGD, 100, 96	6,4054	5,8198	0,0414
322	50, 0.1, SGD, 50, 96	6,4839	5,1769	0,04
323	10, 0.5, SGD, 50, 96	6,4945	3,6694	0,0436
324	50, 0.5, SGD, 50, 96	6,5047	4,1431	0,0413
Average		2,7182	10,5116	0,0121

Hasilnya didapatkan model terbaik dengan kombinasi parameter berupa 50 *hidden units*; 0,1 *dropout rate*; RMSprop *optimizer*; 50 *epoch*; dan 96 *batch size*. Model tersebut menghasilkan MAPE 1,347% dengan *training time* 4,4867 detik dan *loss* sebesar 0,002. Percobaan dilanjutkan ke *timestep* berikutnya sesuai dengan desain eksperimen.

b. *Timestep 2*

Pada eksperimen meramalkan harga saham ASII menggunakan harga saham ASII hingga 2 hari sebelumnya didapatkan 324 model dari kombinasi 5 buah parameter. Dari hasil eksperimen yang ditunjukkan pada Tabel 6.17 didapatkan rata-rata pada masing-masing pengukuran yakni MAPE sebesar 2,2406%; *time* sebesar 12,9457s; dan *training loss* sebesar 0,0077.

Tabel 6.17. Hasil Tuning Parameter 2 Timestep Univariat

Best No.	units, rate, optimizer, epoch, batch_size	MAPE (%)	Training Time (s)	Training Loss
1	30, 0.3, RMSprop, 200, 32	1,3676	24,9129	0,0019
2	50, 0.3, RMSprop, 200, 32	1,3697	39,5357	0,0017
3	50, 0.1, RMSprop, 150, 32	1,3715	23,7887	0,0016
4	50, 0.5, RMSprop, 200, 32	1,3817	34,5499	0,0022
5	30, 0.1, Adam, 200, 32	1,3905	28,1123	0,0017
n
320	50, 0.3, SGD, 100, 96	5,3055	11,1602	0,0268
321	30, 0.1, SGD, 50, 96	5,4204	4,5305	0,0282
322	50, 0.5, SGD, 50, 96	5,6168	4,9256	0,0328
323	50, 0.3, SGD, 50, 96	5,7679	5,8566	0,0322
324	10, 0.1, SGD, 50, 64	5,8402	4,3647	0,0317
Average		2,2406	12,9457	0,0077

Hasilnya didapatkan model terbaik dengan kombinasi parameter berupa 30 *hidden units*; 0,3 *dropout rate*; RMSprop *optimizer*; 200 *epoch*; dan 32 *batch size*. Model tersebut menghasilkan MAPE 1,3676% dengan *training time* 24,9129 detik dan *loss* sebesar 0,0019.

Percobaan peramalan dengan 2 *timestep* ini mendapatkan model terbaik dengan MAPE yang mengalami kenaikan dari sebelumnya sehingga otomatis tidak lebih baik dari model terbaik univariat yang telah didapatkan sebelumnya.

c. *Timestep 3*

Pada eksperimen meramalkan harga saham ASII menggunakan harga saham ASII hingga 3 hari sebelumnya didapatkan 324 model dari kombinasi 5 buah parameter. Dari hasil eksperimen yang ditunjukkan pada Tabel 6.18 didapatkan rata-rata pada masing-masing pengukuran yakni MAPE sebesar 2,0981%; *time* sebesar 15,316s; dan *training loss* sebesar 0,0066.

Tabel 6.18. Hasil Tuning Parameter 3 Timestep Univariat

Best No.	units, rate, optimizer, epoch, batch_size	MAPE (%)	Training Time (s)	Training Loss
1	50, 0.3, RMSprop, 200, 32	1,3628	42,5828	0,0016
2	50, 0.1, RMSprop, 200, 32	1,3685	40,7689	0,0015
3	30, 0.1, RMSprop, 200, 32	1,3764	30,6779	0,0015
4	50, 0.1, Adam, 200, 32	1,3821	43,0318	0,0016
5	30, 0.1, RMSprop, 150, 32	1,3912	21,9521	0,0016
n
320	30, 0.3, SGD, 50, 96	4,7163	5,0336	0,0238
321	10, 0.1, SGD, 50, 64	4,7631	4,9589	0,0254
322	30, 0.1, SGD, 50, 96	4,7992	5,0191	0,0213
323	10, 0.1, SGD, 50, 96	5,0828	4,201	0,0259
324	10, 0.5, SGD, 50, 64	5,7435	5,1236	0,035
Average		2,0981	15,316	0,0066

Hasilnya didapatkan model terbaik dengan kombinasi parameter berupa 50 *hidden units*; 0,3 *droupout rate*; RMSprop *optimizer*; 200 *epoch*; dan 32 *batch size*. Model tersebut menghasilkan MAPE 1,3628% dengan *training time* 42,5828 detik dan *loss* sebesar 0,0016.

Percobaan peramalan dengan 3 *timestep* ini mendapatkan model terbaik dengan MAPE yang mengalami penurunan dari sebelumnya, sehingga untuk sementara akan menjadi model terbaik untuk kasus univariat.

d. *Timestep 4*

Pada eksperimen meramalkan harga saham ASII menggunakan harga saham ASII hingga 4 hari sebelumnya didapatkan 324 model dari kombinasi 5 buah parameter Dari hasil eksperimen yang ditunjukkan pada Tabel 6.19 didapatkan rata-rata pada masing-masing pengukuran yakni MAPE sebesar 2,0256%; *time* sebesar 17,7674s; dan *training loss* sebesar 0,0059.

Tabel 6.19. Hasil Tuning Parameter 4 Timestep Univariat

Best No.	units, rate, optimizer, epoch, batch_size	MAPE (%)	Training Time (s)	Training Loss
1	50, 0.1, RMSprop, 150, 32	1,3523	39,0214	0,0016
2	50, 0.1, RMSprop, 200, 32	1,3648	60,1478	0,0015
3	30, 0.1, RMSprop, 200, 32	1,3666	38,7221	0,0014
4	50, 0.3, RMSprop, 200, 32	1,3835	58,2097	0,0017
5	50, 0.3, RMSprop, 150, 32	1,3836	37,0168	0,0018
n
320	10, 0.5, SGD, 50, 96	4,499	4,5748	0,0267
321	30, 0.1, SGD, 50, 96	4,5149	6,3433	0,0195
322	10, 0.3, SGD, 50, 96	4,8166	4,635	0,0289
323	50, 0.5, SGD, 50, 96	4,8207	6,501	0,0256
324	30, 0.5, SGD, 50, 96	5,0654	5,5571	0,0305
Average		2,0256	17,7674	0,0059

Hasilnya didapatkan model terbaik dengan kombinasi parameter berupa 50 *hidden units*; 0,1 *dropout rate*; RMSprop *optimizer*; 150 *epoch*; dan 32 *batch size*. Model tersebut menghasilkan MAPE 1,3523% dengan *training time* 39,0214 detik dan *loss* sebesar 0,0016.

Percobaan peramalan dengan 4 *timestep* ini mendapatkan model terbaik dengan MAPE yang mengalami penurunan dari sebelumnya, sehingga untuk sementara akan menjadi model terbaik untuk kasus univariat.

e. *Timestep 5*

Pada eksperimen meramalkan harga saham ASII menggunakan harga saham ASII hingga 5 hari sebelumnya didapatkan 324 model dari kombinasi 5 buah parameter. Dari hasil eksperimen yang ditunjukkan pada Tabel 6.20 didapatkan rata-rata pada masing-masing pengukuran yakni MAPE sebesar 2,0089%; *time* sebesar 20,2435s; dan *training loss* sebesar 0,0057.

Tabel 6.20. Hasil Tuning Parameter 5 Timestep Univariat

Best No.	units, rate, optimizer, epoch, batch_size	MAPE (%)	Training Time (s)	Training Loss
1	50, 0.1, RMSprop, 150, 32	1,3465	38,956	0,0016
2	50, 0.1, RMSprop, 200, 64	1,3801	30,7791	0,0018
3	50, 0.3, RMSprop, 150, 32	1,3807	42,4743	0,0018
4	50, 0.3, RMSprop, 200, 32	1,3851	57,4982	0,0017
5	50, 0.1, RMSprop, 200, 32	1,3933	53,8141	0,0015
n
320	30, 0.1, SGD, 50, 64	4,1262	6,4264	0,0158
321	30, 0.5, SGD, 50, 96	4,7264	5,6302	0,028
322	10, 0.1, SGD, 50, 96	4,9344	4,69	0,0257
323	10, 0.5, SGD, 50, 64	4,9475	8,2439	0,0272
324	10, 0.3, SGD, 50, 96	5,1706	6,6119	0,029
Average		2,0089	20,2435	0,0057

Hasilnya didapatkan model terbaik dengan kombinasi parameter berupa 50 *hidden units*; 0,1 *droupout rate*; RMSprop *optimizer*; 150 *epoch*; dan 32 *batch size*. Model tersebut menghasilkan MAPE 1,3465% dengan *training time* 38,956 detik dan *loss* sebesar 0,0016.

Percobaan peramalan dengan 5 *timestep* ini mendapatkan model terbaik dengan MAPE yang mengalami penurunan dari sebelumnya, sehingga untuk sementara akan menjadi model terbaik untuk kasus univariat.

f. *Timestep 6*

Pada eksperimen meramalkan harga saham ASII menggunakan harga saham ASII hingga 6 hari sebelumnya didapatkan 324 model dari kombinasi 5 buah parameter. Dari hasil eksperimen yang ditunjukkan pada Tabel 6.21 didapatkan rata-rata pada masing-masing pengukuran yakni MAPE sebesar 2,0314%; *time* sebesar 22,9148s; dan *training loss* sebesar 0,0057.

Tabel 6.21. Hasil Tuning Parameter 6 Timestep Univariat

Best No.	units, rate, optimizer, epoch, batch_size	MAPE (%)	Training Time (s)	Training Loss
1	50, 0.3, RMSprop, 200, 32	1,3636	69,533	0,0017
2	30, 0.3, RMSprop, 200, 32	1,3784	39,8187	0,0018
3	50, 0.5, RMSprop, 150, 32	1,4024	50,1527	0,0024
4	30, 0.1, Adam, 200, 32	1,4083	44,8122	0,0017
5	50, 0.1, Adam, 200, 32	1,4128	57,1118	0,0017
n
320	30, 0.5, SGD, 50, 96	4,1798	6,6151	0,0239
321	30, 0.3, SGD, 50, 96	4,1812	8,0343	0,0196
322	10, 0.1, SGD, 50, 96	4,3505	9,4437	0,019
323	10, 0.1, SGD, 100, 96	4,5001	12,9122	0,0215
324	10, 0.3, SGD, 50, 96	5,4892	4,9408	0,0327
Average		2,0314	22,9148	0,0057

Hasilnya didapatkan model terbaik dengan kombinasi parameter berupa 50 *hidden units*; 0,3 *dropout rate*; RMSprop *optimizer*; 200 *epoch*; dan 32 *batch size*. Model tersebut menghasilkan MAPE 1,3636% dengan *training time* 69,533 detik dan *loss* sebesar 0,0017.

Percobaan peramalan dengan 6 *timestep* ini mendapatkan model terbaik dengan MAPE yang mengalami kenaikan dari sebelumnya sehingga otomatis tidak lebih baik dari model terbaik univariat yang telah didapatkan sebelumnya.

g. *Timestep 7*

Pada eksperimen meramalkan harga saham ASII menggunakan harga saham ASII hingga 7 hari sebelumnya didapatkan 324 model dari kombinasi 5 buah parameter. Dari hasil eksperimen yang ditunjukkan pada Tabel 6.22 didapatkan rata-rata pada masing-masing pengukuran yakni MAPE sebesar 2,0097%; *time* sebesar 23,9925s; dan *training loss* sebesar 0,0055.

Tabel 6.22. Hasil Tuning Parameter 7 Timestep Univariat

Best No.	units, rate, optimizer, epoch, batch_size	MAPE (%)	Training Time (s)	Training Loss
1	30, 0.1, RMSprop, 150, 32	1,3704	38,0881	0,0016
2	50, 0.3, RMSprop, 150, 32	1,3925	56,4562	0,0017
3	30, 0.3, RMSprop, 150, 32	1,4129	31,6944	0,002
4	50, 0.5, RMSprop, 200, 32	1,4223	63,3389	0,0022
5	30, 0.5, RMSprop, 200, 32	1,428	50,4964	0,0028
n
320	50, 0.1, SGD, 50, 96	3,6181	10,7542	0,0118
321	10, 0.3, SGD, 50, 96	3,777	5,5446	0,0209
322	50, 0.5, SGD, 50, 96	3,8707	9,4696	0,0198
323	10, 0.5, SGD, 50, 96	4,1266	8,5854	0,0236
324	10, 0.3, SGD, 50, 64	5,2087	6,8277	0,0304
Average		2,0097	23,9925	0,0055

Hasilnya didapatkan model terbaik dengan kombinasi parameter berupa 30 *hidden units*; 0,1 *droupout rate*; RMSprop *optimizer*; 150 *epoch*; dan 32 *batch size*. Model tersebut menghasilkan MAPE 1,3704% dengan *training time* 38,0881 detik dan *loss* sebesar 0,0016.

Percobaan peramalan dengan 7 *timestep* ini mendapatkan model terbaik dengan MAPE yang mengalami kenaikan dari sebelumnya sehingga otomatis tidak lebih baik dari model terbaik univariat yang telah didapatkan sebelumnya. *Tuning Parameter* berhenti pada timestep ini sesuai desain eksperimen.

6.4. Hasil Peramalan Data Multivariat

Subbab ini berisi hasil struktur data sebagai masukan model, kemudian dilanjutkan hasil *tuning parameter* yang sudah mencakup pemodelan, peramalan dan evaluasi multivariat.

6.4.1. Hasil Pembentukan Struktur Data Multivariat

Struktur data untuk *training set* tergantung pada *timestep* yang digunakan. Pada multivariat *multi-timestep* struktur *training set* dapat dilihat pada Gambar 6.25. Prediktor berupa 2 *array* yang disatukan dalam 1 *array* merepresentasikan harga nilai tukar USD/IDR dan harga saham ASII hingga dua hari sebelumnya dengan sebuah regresor di sebelah kanan.

Tabel 6.23. Struktur Training Set Multivariat Multi-timestep

[[0.04726599 0.46583851]
[0.05560704 0.36645963]] 0.36645962732919246
[[0.05560704 0.36645963]
[0.06543095 0.36645963]] 0.39751552795031064
[[0.06543095 0.36645963]
[0.07784986 0.39751553]] 0.4161490683229814
[[0.07784986 0.39751553]
[0.07506951 0.41614907]] 0.3913043478260869
[[0.07506951 0.41614907]
[0.08897127 0.39130435]] 0.39751552795031064

Struktur data untuk *test set* sama seperti *training set* namun tidak memiliki regresor seperti pada Gambar 6.26 karena regresor itu sendiri yang akan diprediksi pada partisi ini.

Tabel 6.24. Struktur Test Set Multivariat Multi-timestep

[[0.65356812 0.49068323]
[0.65430955 0.54037267]]
[[0.65430955 0.54037267]
[0.65430955 0.54037267]]
[[0.65430955 0.54037267]
[0.6502317 0.60248447]]
[[0.6502317 0.60248447]
[0.65412419 0.63354037]]
[[0.65412419 0.63354037]
[0.65486562 0.60869565]]

6.4.2. Hasil Tuning Parameter Multivariat

Tuning parameter multivariat berisi percobaan kombinasi terhadap *given parameter* untuk pemodelan yakni *units*, *rate*, *optimizer*, *epoch* dan *batch_size* mulai dari *timestep* 1 hingga *threshold* berhentinya eksperimen *timestep*.

a. Timestep 1

Pada eksperimen meramalkan harga saham ASII menggunakan harga saham ASII dan kurs Dolar 1 hari sebelumnya didapatkan 324 model dari kombinasi 5 buah parameter. Dari hasil eksperimen yang ditunjukkan pada Tabel 6.25 didapatkan rata-rata pada masing-masing pengukuran yakni MAPE sebesar 2,9973%; *time* sebesar 11,1259s; dan *training loss* 0,0118.

Tabel 6.25. Hasil Tuning Parameter 1 Timestep Multivariat

Best No.	units, rate, optimizer, epoch, batch_size	MAPE (%)	Training Time (s)	Training Loss
1	30, 0.3, RMSprop, 200, 32	1,3612	21,9788	0,0019
2	50, 0.5, RMSprop, 200, 64	1,3621	15,9708	0,002
3	30, 0.5, RMSprop, 200, 32	1,3732	20,5746	0,0026
4	30, 0.5, RMSprop, 150, 32	1,3732	15,1725	0,0029
5	10, 0.3, RMSprop, 150, 32	1,3745	15,4156	0,0032
n
320	50, 0.5, SGD, 50, 64	6,6703	4,7941	0,0401
321	30, 0.1, SGD, 50, 64	6,7068	4,1972	0,0327
322	30, 0.1, SGD, 50, 96	6,9363	4,0697	0,0384
323	10, 0.3, SGD, 100, 64	7,1687	8,2518	0,0413
324	10, 0.5, SGD, 50, 64	7,1976	4,4482	0,0389
Average		2,9973	11,1259	0,0118

Hasilnya didapatkan model terbaik dengan kombinasi parameter berupa 30 *hidden units*; 0,3 *droupout rate*; RMSprop *optimizer*; 200 *epoch*; dan 32 *batch size*. Model tersebut menghasilkan MAPE 1,3612% dengan *training time* 21,9788 detik dan *loss* sebesar 0,0019. Percobaan dilanjutkan ke *timestep* berikutnya sesuai dengan desain eksperimen.

b. *Timestep 2*

Pada eksperimen meramalkan harga saham ASII menggunakan harga saham ASII dan kurs Dolar hingga 2 hari sebelumnya didapatkan 324 model dari kombinasi 5 buah parameter. Dari hasil eksperimen yang ditunjukkan pada Tabel 6.26 didapatkan rata-rata pada masing-masing pengukuran yakni MAPE sebesar 2,7043%; *time* sebesar 13,181s; dan *training loss* 0,0081.

Tabel 6.26. Hasil Tuning Parameter 2 Timestep Multivariat

Best No.	units, rate, optimizer, epoch, batch_size	MAPE (%)	Training Time (s)	Training Loss
1	30, 0.3, RMSprop, 200, 32	1,3512	33,5328	0,0019
2	50, 0.3, RMSprop, 200, 32	1,3784	39,1322	0,0018
3	50, 0.3, RMSprop, 200, 64	1,3937	29,1482	0,0018
4	50, 0.3, Adam, 200, 32	1,4023	47,4384	0,0018
5	30, 0.1, Adam, 200, 32	1,4321	26,9389	0,0016
n
320	30, 0.5, SGD, 50, 96	5,9567	4,4456	0,0328
321	10, 0.1, SGD, 50, 96	6,1409	3,891	0,0421
322	50, 0.1, SGD, 50, 96	6,1595	4,9146	0,0294
323	10, 0.5, SGD, 100, 96	6,594	5,78	0,041
324	30, 0.3, SGD, 50, 96	6,9366	4,5693	0,0301
Average		2,7043	13,181	0,0081

Hasilnya didapatkan model terbaik dengan kombinasi parameter berupa 30 *hidden units*; 0,3 *dropout rate*; RMSprop *optimizer*; 200 *epoch*; dan 32 *batch size*. Model tersebut menghasilkan MAPE 1,3512% dengan *training time* 33,5328 detik dan *loss* sebesar 0,0019.

Percobaan peramalan dengan 2 *timestep* ini mendapatkan model terbaik dengan MAPE yang mengalami penurunan dari sebelumnya, sehingga untuk sementara akan menjadi model terbaik untuk kasus multivariat.

c. *Timestep 3*

Pada eksperimen meramalkan harga saham ASII menggunakan harga saham ASII dan kurs Dolar hingga 3 hari sebelumnya didapatkan 324 model dari kombinasi 5 buah parameter. Dari hasil eksperimen yang ditunjukkan pada Tabel 6.27 didapatkan rata-rata pada masing-masing pengukuran yakni MAPE sebesar 2,5548%; *time* sebesar 15,6561s; dan *training loss* 0,0066.

Tabel 6.27. Hasil Tuning Parameter 3 Timestep Multivariat

Best No.	units, rate, optimizer, epoch, batch_size	MAPE (%)	Training Time (s)	Training Loss
1	30, 0,3, RMSprop, 200, 32	1,3795	29,7525	0,0018
2	50, 0,1, RMSprop, 150, 32	1,3918	30,0109	0,0016
3	50, 0,1, Adam, 200, 32	1,3941	42,7994	0,0016
4	10, 0,1, RMSprop, 200, 32	1,4	27,5683	0,0018
5	50, 0,3, RMSprop, 150, 32	1,4244	32,503	0,0018
n
320	10, 0,3, SGD, 100, 64	5,4447	9,0876	0,0121
321	50, 0,3, SGD, 50, 96	5,5695	5,7462	0,0226
322	10, 0,3, SGD, 50, 96	5,7016	4,527	0,0326
323	10, 0,3, SGD, 50, 64	5,834	5,4228	0,0326
324	30, 0,3, SGD, 50, 96	5,9171	5,1188	0,0269
Average		2,5448	15,6561	0,0066

Hasilnya didapatkan model terbaik dengan kombinasi parameter berupa 30 *hidden units*; 0,3 *droupout rate*; RMSprop *optimizer*; 200 *epoch*; dan 32 *batch size*. Model tersebut menghasilkan MAPE 1,3795% dengan *training time* 29,7525 detik dan *loss* sebesar 0,0018.

Percobaan peramalan dengan 3 *timestep* ini mendapatkan model terbaik dengan MAPE yang mengalami kenaikan dari sebelumnya sehingga otomatis tidak lebih baik dari model terbaik multivariat yang telah didapatkan sebelumnya.

d. *Timestep 4*

Pada eksperimen meramalkan harga saham ASII menggunakan harga saham ASII dan kurs Dolar hingga 4 hari sebelumnya didapatkan 324 model dari kombinasi 5 buah parameter. Dari hasil eksperimen yang ditunjukkan pada Tabel 6.28 didapatkan rata-rata pada masing-masing pengukuran yakni MAPE sebesar 2,5407%; *time* sebesar 18,0854s; dan *training loss* 0,0063.

Tabel 6.28. Hasil Tuning Parameter 4 Timestep Multivariat

Best No.	units, rate, optimizer, epoch, batch_size	MAPE (%)	Training Time (s)	Training Loss
1	10, 0.1, RMSprop, 200, 32	1,3825	35,804	0,0018
2	50, 0.3, RMSprop, 150, 32	1,4364	36,1078	0,0018
3	50, 0.1, Adam, 200, 32	1,4412	58,3122	0,0016
4	50, 0.5, RMSprop, 150, 32	1,445	37,5435	0,0024
5	30, 0.3, RMSprop, 200, 64	1,4514	21,5887	0,0021
n
320	10, 0.3, SGD, 50, 64	5,0725	5,4639	0,0214
321	10, 0.3, SGD, 200, 96	5,1616	14,4249	0,0119
322	10, 0.1, SGD, 50, 96	5,3625	4,7179	0,0245
323	10, 0.3, SGD, 50, 96	5,364	4,7735	0,0339
324	30, 0.1, SGD, 50, 96	5,3935	5,5289	0,0247
Average		2,5407	18,0854	0,0063

Hasilnya didapatkan model terbaik dengan kombinasi parameter berupa 10 *hidden units*; 0,1 *dropout rate*; RMSprop *optimizer*; 200 *epoch*; dan 32 *batch size*. Model tersebut menghasilkan MAPE 1,3825% dengan *training time* 25,804 detik dan *loss* sebesar 0,0018.

Percobaan peramalan dengan 4 *timestep* ini mendapatkan model terbaik dengan MAPE yang mengalami kenaikan dari sebelumnya sehingga otomatis tidak lebih baik dari model terbaik multivariat yang telah didapatkan sebelumnya.

h. *Timestep 5*

Pada eksperimen meramalkan harga saham ASII menggunakan harga saham ASII dan kurs Dolar hingga 5 hari sebelumnya didapatkan 324 model dari kombinasi 5 buah parameter. Dari hasil eksperimen yang ditunjukkan pada Tabel 6.29 didapatkan rata-rata pada masing-masing pengukuran yakni MAPE sebesar 2,1006%; *time* sebesar 25,8495s; dan *training loss* 0,0059.

Tabel 6.29. Hasil Tuning Parameter 5 Timestep Multivariat

Best No.	units, rate, optimizer, epoch, batch_size	MAPE (%)	Training Time (s)	Training Loss
1	10, 0.1, Adam, 50, 32	2,0844	4,4436	0,0051
2	10, 0.1, Adam, 50, 64	2,0845	3,0027	0,0072
3	10, 0.1, Adam, 50, 96	2,0846	2,6708	0,0085
4	10, 0.1, Adam, 100, 32	2,0847	8,0938	0,0038
5	10, 0.1, Adam, 100, 64	2,0848	5,2244	0,0046
n
320	50, 0.5, SGD, 150, 64	2,1163	35,6507	0,0065
321	50, 0.5, SGD, 150, 96	2,1164	55,6079	0,0087
322	50, 0.5, SGD, 200, 32	2,1165	59,7458	0,0041
323	50, 0.5, SGD, 200, 64	2,1166	43,3322	0,0054
324	50, 0.5, SGD, 200, 96	2,1167	67,6903	0,0068
Average		2,1006	25,8495	0,0059

Hasilnya didapatkan model terbaik dengan kombinasi parameter berupa 10 *hidden units*; 0,1 *dropout rate*; Adam *optimizer*; 50 *epoch*; dan 32 *batch size*. Model tersebut menghasilkan MAPE 2,0844% dengan *training time* 4,4436 detik dan *loss* sebesar 0,0051.

Percobaan peramalan dengan 5 *timestep* ini mendapatkan model terbaik dengan MAPE yang mengalami kenaikan dari sebelumnya sehingga otomatis tidak lebih baik dari dari model terbaik multivariat yang telah didapatkan sebelumnya.

i. *Timestep 6*

Pada eksperimen meramalkan harga saham ASII menggunakan harga saham ASII dan kurs Dolar hingga 6 hari sebelumnya didapatkan 324 model dari kombinasi 5 buah parameter. Dari hasil eksperimen yang ditunjukkan pada Tabel 6.30 didapatkan rata-rata pada masing-masing pengukuran yakni MAPE sebesar 2,4989%; *time* sebesar 29,3813s; dan *training loss* 0,0057.

Tabel 6.30. Hasil Tuning Parameter 6 Timestep Multivariat

Best No.	units, rate, optimizer, epoch, batch_size	MAPE (%)	Training Time (s)	Training Loss
1	50, 0.1, Adam, 200, 32	1,4168	54,7082	0,0016
2	50, 0.1, RMSprop, 200, 32	1,4201	65,2302	0,0016
3	50, 0.1, RMSprop, 150, 32	1,4216	50,0202	0,0018
4	50, 0.3, RMSprop, 200, 32	1,4521	134,669	0,0017
5	50, 0.1, RMSprop, 200, 96	1,4559	88,892	0,0022
n
320	10, 0.5, Adam, 50, 64	5,206	11,5027	0,0291
321	10, 0.5, SGD, 50, 64	5,2554	15,3944	0,0232
322	10, 0.3, SGD, 100, 64	5,3067	13,343	0,0116
323	10, 0.5, SGD, 50, 96	5,3767	14,6982	0,0217
324	10, 0.5, Adam, 50, 96	6,5571	11,1619	0,0289
Average		2,4989	29,3813	0,0057

Hasilnya didapatkan model terbaik dengan kombinasi parameter berupa 50 *hidden units*; 0,1 *dropout rate*; Adam *optimizer*; 200 *epoch*; dan 32 *batch size*. Model tersebut menghasilkan MAPE 1,4168% dengan *training time* 54,7082 detik dan *loss* sebesar 0,0016.

Percobaan peramalan dengan 6 *timestep* ini mendapatkan model terbaik dengan MAPE yang mengalami penurunan dari sebelumnya, namun tidak mendapatkan MAPE yang lebih baik dari model terbaik multivariat yang telah didapatkan sebelumnya.

j. *Timestep 7*

Pada eksperimen meramalkan harga saham ASII menggunakan harga saham ASII dan kurs Dolar hingga 7 hari sebelumnya didapatkan 324 model dari kombinasi 5 buah parameter. Dari hasil eksperimen yang ditunjukkan pada Tabel 6.31 didapatkan rata-rata pada masing-masing pengukuran yakni MAPE sebesar 2,4981%; *time* sebesar 17,5886s; dan *training loss* 0,0057.

Tabel 6.31. Hasil Tuning Parameter 7 Timestep Multivariat

Best No.	units, rate, optimizer, epoch, batch_size	MAPE (%)	Training Time (s)	Training Loss
1	50, 0.3, RMSprop, 150, 32	1,4148	32,1606	0,0019
2	30, 0.1, RMSprop, 200, 64	1,4154	21,0013	0,0018
3	50, 0.3, Adam, 200, 32	1,4265	45,6169	0,0019
4	30, 0.1, Adam, 200, 32	1,4358	36,8376	0,0018
5	30, 0.3, RMSprop, 200, 32	1,4392	39,4626	0,002
n
320	10, 0.3, Adam, 50, 64	5,5504	6,287	0,0157
321	10, 0.1, SGD, 50, 64	5,7628	6,6358	0,028
322	10, 0.3, SGD, 100, 96	5,8671	8,2251	0,0132
323	10, 0.1, SGD, 100, 96	5,9802	8,4375	0,0095
324	10, 0.3, Adam, 50, 96	6,4009	4,9943	0,018
Average		2,4981	17,5886	0,0057

Hasilnya didapatkan model terbaik dengan kombinasi parameter berupa 50 *hidden units*; 0,3 *droupout rate*; RMSprop *optimizer*; 150 *epoch*; dan 32 *batch size*. Model tersebut menghasilkan MAPE 1,4148% dengan *training time* 32,1606 detik dan *loss* sebesar 0,0019. Percobaan peramalan dengan 7 *timestep* ini menghasilkan MAPE yang tidak lebih baik dari MAPE terbaik yang sebelumnya telah didapat.

6.5. Perbandingan Model Univariat dan Multivariat

Subbab ini berisi kumpulan model LSTM terbaik pada *tuning parameter* di setiap timestep yang kemudian dipilih model terbaik untuk masing-masing kasus univariat dan multivariat.

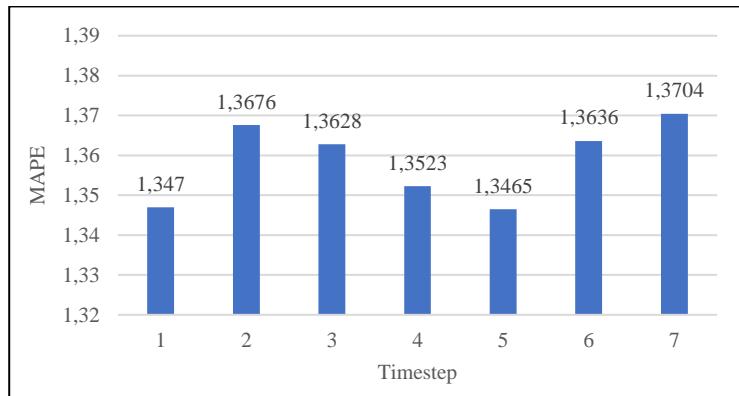
6.5.1. Hasil Pemilihan Model Terbaik Univariat

Pada peramalan univariat terdapat 2268 kali *tuning parameter* dalam 7 eksperimen *timestep* dengan MAPE terbaik sebesar 1,3465% seperti yang diilustrasikan pada Tabel 6.32.

Tabel 6.32. Model Terbaik Setiap *Timestep* Kasus Univariat

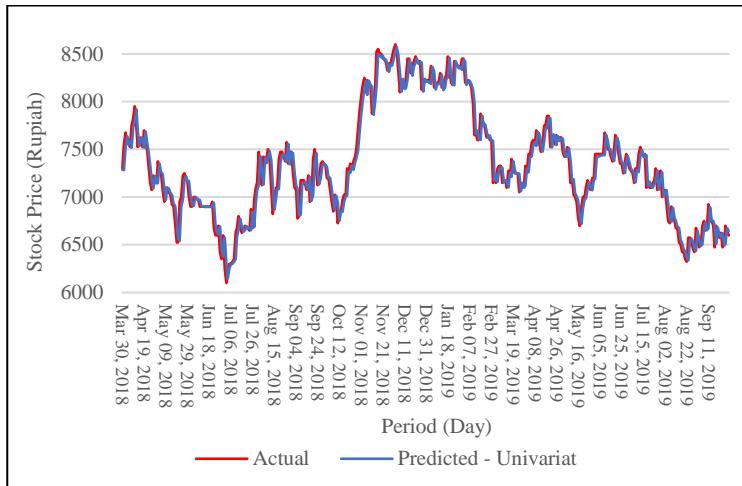
Step	units, rate, optimizer, epoch, batch_size	MAPE (%)	Training Time (s)	Training Loss
1	50, 0.1, RMSprop, 50, 96.	1,347	4,4867	0,002
2	30, 0.3, RMSprop, 200, 32.	1,3676	24,9129	0,0019
3	50, 0.3, RMSprop, 200, 32	1,3628	42,5828	0,0016
4	50, 0.1, RMSprop, 150, 32.	1,3523	39,0214	0,0016
5	50, 0.1, RMSprop, 150, 32.	1,3465	38,956	0,0016
6	50, 0.3, RMSprop, 200, 32.	1,3636	69,533	0,0017
7	30, 0.1, RMSprop, 150, 32.	1,3704	38,0881	0,0016

Model dengan MAPE terbaik terdapat pada *timestep* ke-5 seperti yang ditunjukkan Gambar 6.10 yang mana ditempuh dengan waktu 24,9129 detik dan *training loss* sebesar 0,0016.



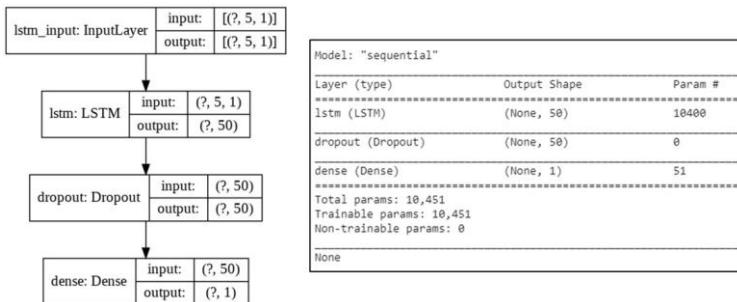
Gambar 6.10. Model Terbaik Setiap *Timestep* Univariat

Model terbaik dengan kombinasi parameter 50 *hidden units*; 0,1 *droupout rate*; RMSprop *optimizer*; 150 *epoch*; dan 32 *batch size* terlihat sangat presisi dalam mengikuti nilai aktual *test set* seperti yang ditunjukkan pada Gambar 6.11.



Gambar 6.11. Performa Model Terbaik Univariat

Lebih jelas terkait bagaimana arsitektur dari model terbaik univariat dari satu *layer* ke *layer* yang lain dapat dilihat pada Gambar 6.12. Masukan untuk model adalah jumlah baris *training set* dengan 5 fitur representasi *timestep* yang setiap cellnya berisikan 1 buah elemen data saham. Kemudian masukan tersebut akan diproses kedalam *recurrent layer* dan *dropout layer* dengan *hidden node* sebanyak 50 buah yang terhubung dengan luaran dengan jumlah baris yang sama dengan 1 fitur saham yang akan membuat sebuah *pattern*. Pola tersebut nantinya dapat digunakan untuk memprediksi *test set*.



Gambar 6.12. Arsitektur Model Terbaik Univariat

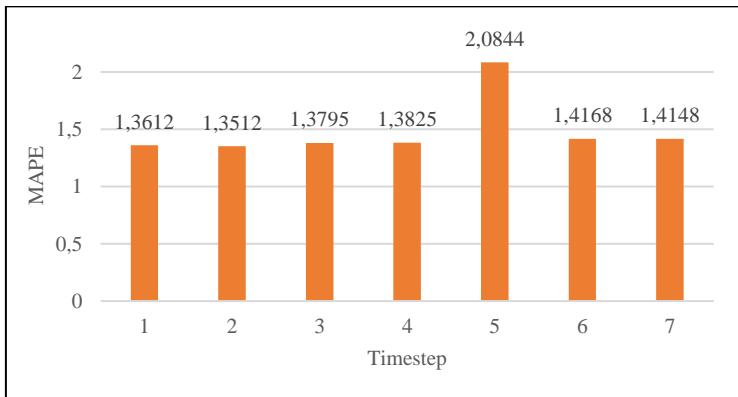
6.5.2. Hasil Pemilihan Model Terbaik Multivariat

Pada peramalan multivariat terdapat 2268 kali *tuning parameter* dalam 7 eksperimen *timestep* dengan MAPE terbaik sebesar 1,3512% seperti yang diilustrasikan pada Tabel 6.33.

Tabel 6.33. Model Terbaik Setiap *Timestep* Kasus Multivariat

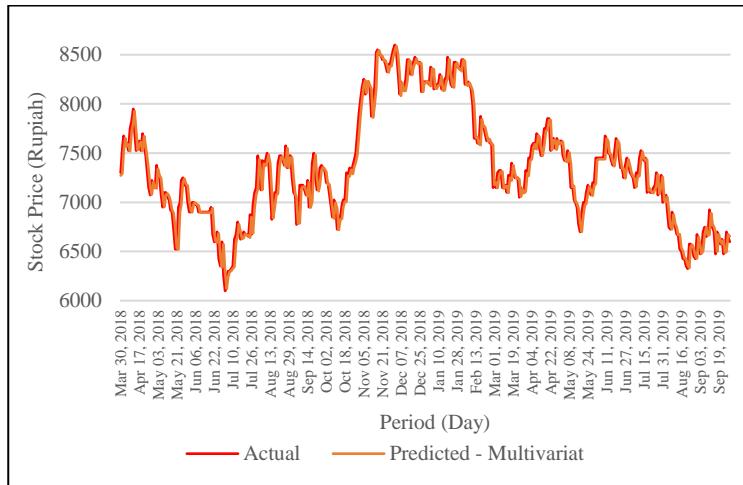
Step	units, rate, optimizer, epoch, batch_size	MAPE (%)	Training Time (s)	Training Loss
1	30, 0.3, RMSprop, 200, 32.	1,3612	21,9788	0,0019
2	30, 0.3, RMSprop, 200, 32.	1,3512	33,5328	0,0019
3	30, 0.3, RMSprop, 200, 32	1,3795	29,7525	0,0018
4	10, 0.1, RMSprop, 150, 32.	1,3825	35,804	0,0018
5	10, 0.1, Adam, 50, 32.	2,0844	4,4436	0,0051
6	50, 0.1, Adam, 200, 32.	1,4168	54,7082	0,0016
7	50, 0.3, RMSprop, 150, 32.	1,4148	32,1606	0,0019

Model dengan MAPE terbaik terdapat pada *timestep* ke-2 seperti yang ditunjukkan Gambar 6.13 yang mana ditempuh dengan waktu 33,5328 detik dan *training loss* sebesar 0,0019.



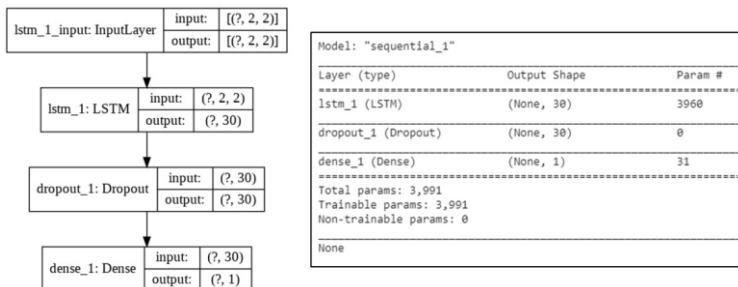
Gambar 6.13. Model Terbaik Setiap *Timestep* Multivariat

Model terbaik dengan kombinasi parameter 30 *hidden units*; 0,3 *dropout rate*; RMSprop *optimizer*; 200 *epoch*; dan 32 *batch size* terlihat sangat presisi dalam mengikuti nilai aktual *test set* seperti yang ditunjukkan pada Gambar 6.14.



Gambar 6.14. Performa Model Terbaik Multivariat

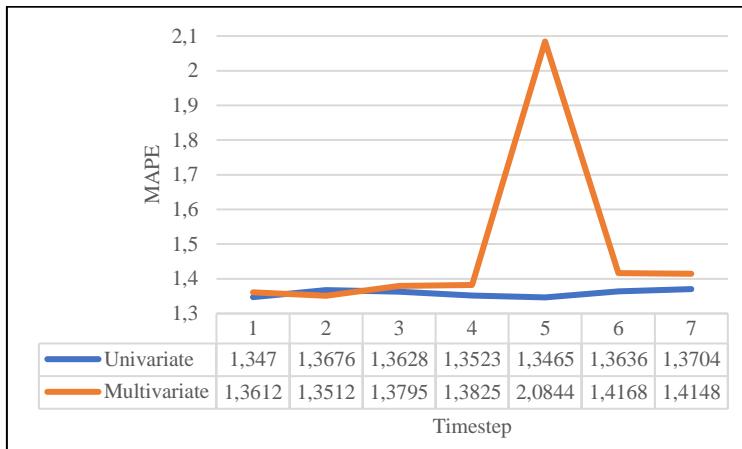
Lebih jelas terkait bagaimana arsitektur dari model terbaik multivariat dari satu *layer* ke *layer* yang lain dapat dilihat pada Gambar 6.15. Masukan untuk model adalah jumlah baris *training set* dengan 2 fitur representasi *timestep* yang setiap *cell* berisi 2 buah elemen data kurs dan saham. Kemudian masukan tersebut akan diproses kedalam *recurrent layer* dan *dropout layer* dengan *hidden node* sebanyak 30 buah yang terhubung dengan luaran dengan jumlah baris yang sama dengan 1 fitur saham yang akan membuat sebuah *pattern*. Pola tersebut nantinya dapat digunakan untuk memprediksi *test set*.



Gambar 6.15. Arsitektur Model Terbaik Multivariat

6.5.3. Visualisasi Eksperimen dan Perbandingan

Setelah mendapatkan masing-masing *best model* setiap *timestep* dan memilih yang paling baik untuk kategori univariat dan multivariat, dilakukan Visualisasi *Tuning parameter* untuk setiap *best model* yang mewakili seperti pada Gambar 6.16. Visualisasi digambarkan dengan stacked line chart dengan warna *series* yang berbeda untuk membandingkan.



Gambar 6.16. Ikhtisar Model Terbaik Setiap *Timestep*

Kasus univariat memiliki model yang lebih baik namun membutuhkan waktu lebih lama untuk mencapai titik terbaik, Sebaliknya model multivariat memiliki model yang tidak lebih baik yang mana juga lebih cepat dalam mencapai titik terbaik. Kedua model pada Tabel 6.34 sekaligus menutup eksperimen *tuning parameter* dan dilanjutkan pengujian model terbaik.

Tabel 6.34. Model Terbaik Univariat dan Multivariat

Model Prediktor	Jumlah Timestep	Kombinasi Parameter (units, rate, optimizer, epoch, batch_size)
Univariat	5	50, 0.1, RMSprop, 150, 32
Multivariat	2	30, 0.3, RMSprop, 200, 32

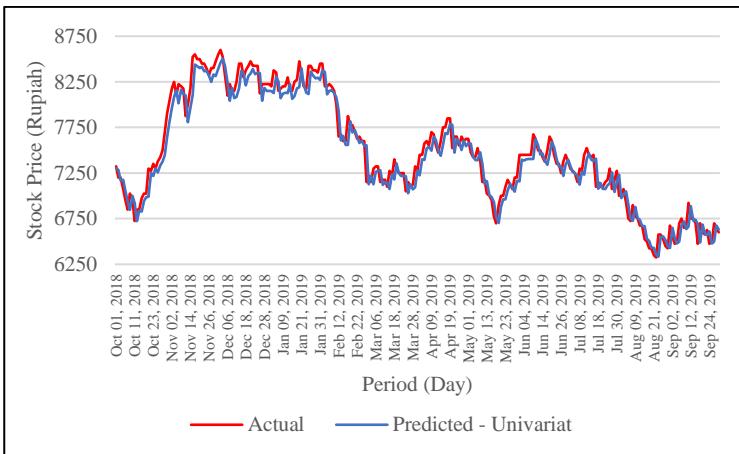
6.6. Hasil Skenario Proporsi Pembagian Data

Skenario pertama dalam menguji model terbaik adalah mengganti proporsi data yang digunakan untuk pemodelan. Dengan adanya 2 skenario (80:20 dan 60:40) dan 2 model terbaik (univariat dan multivariat) maka dalam subbab ini terbentuk 4 buah model seperti yang tertera pada Tabel 6.35.

Tabel 6.35. Evaluasi Skenario Proporsi Pembagian Data

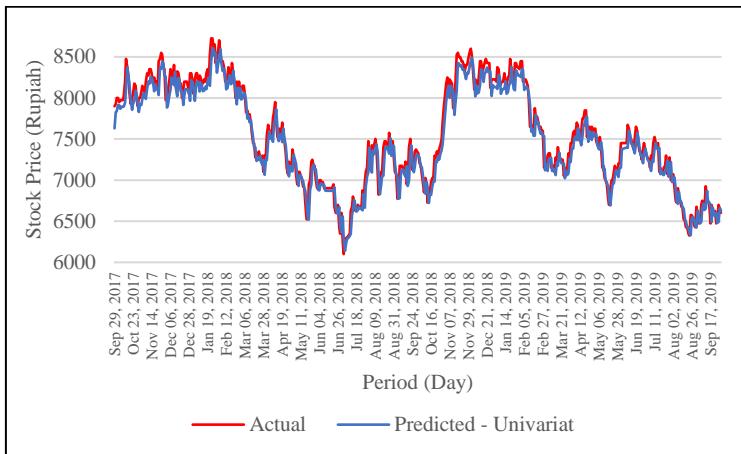
Best Model	Proporsi	MAPE (%)	Training Time (s)	Training Loss
Univariat	80:20	1,3421	47,4162	0,0016
	60:40	1,4617	30,4328	0,0017
Multivariat	80:20	1,3209	22,3326	0,0018
	60:40	2,0863	19,7921	0,002

Pada pengujian model terbaik univariat, Skenario proporsi data sebesar 80:20 menghasilkan MAPE sebesar 1,3421% dengan visualisasi hasil peramalan yang tertera pada Gambar 6.17.



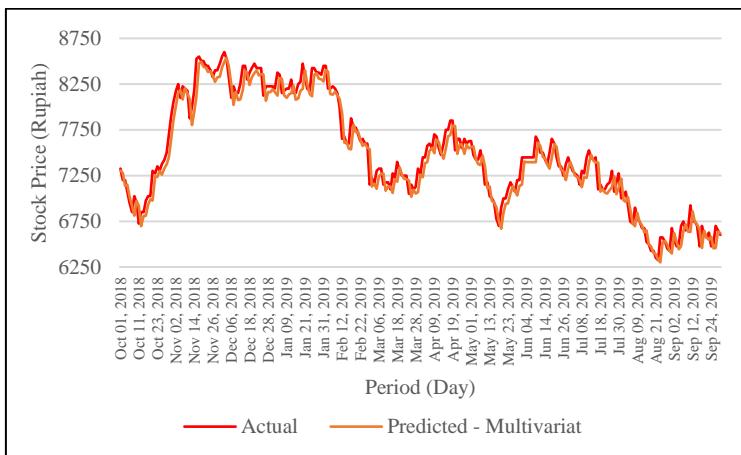
Gambar 6.17. Performa Skenario ‘Test Set 0.2’ Univariat

Sementara untuk skenario proporsi data sebesar 60:40 menghasilkan MAPE sebesar 1,4617% dengan visualisasi hasil peramalan yang tertera pada Gambar 6.18.



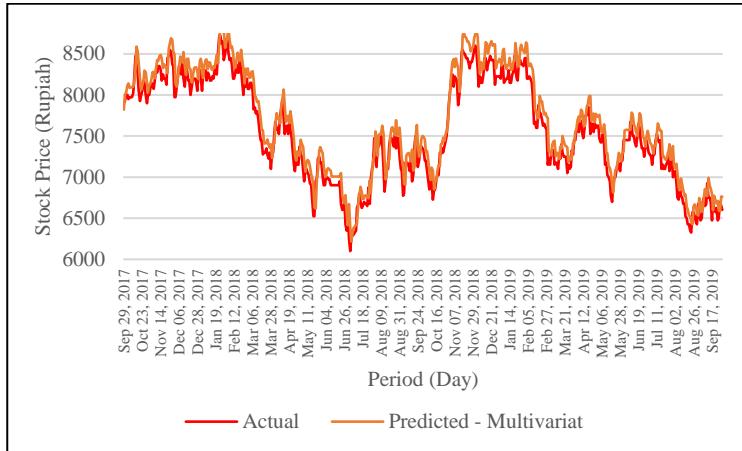
Gambar 6.18. Performa Skenario ‘Test Set 0.4’ Univariat

Pada pengujian model terbaik multivariat, Skenario proporsi data sebesar 80:20 menghasilkan MAPE sebesar 1,3209% dengan visualisasi peramalan yang tertera pada Gambar 6.19



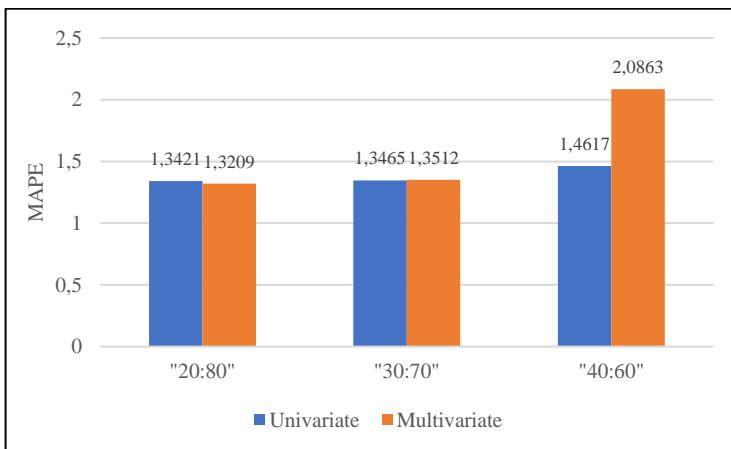
Gambar 6.19. Performa Skenario ‘Test Set 0.2’ Multivariat

Sementara untuk skenario proporsi data sebesar 60:40 menghasilkan MAPE sebesar 2,0863% dengan visualisasi hasil peramalan yang tertera pada Gambar 6.20.



Gambar 6.20. Performa Skenario ‘Test Set 0.4’ Multivariat

Untuk menyimpulkan implementasi skenario dilakukan pengikhtisan terhadap skenario proporsi pembagian data dengan menggunakan *bar chart* seperti pada Gambar 6.19.



Gambar 6.21. Ikhtisar Skenario Proporsi Pembagian Data

Pada model terbaik univariat, dilakukan skenario proporsi *testing:training* sebesar 20:80 dan 40:60. Hasilnya pada skenario proporsi 20:80 memiliki nilai MAPE yang lebih baik, Sementara pada skenario proporsi 40:60 memiliki nilai MAPE yang tidak lebih baik daripada model terbaik univariat.

Skenario proporsi *testing:training* dilakukan pula pada model terbaik multivariat. Hasilnya pada skenario proporsi 20:80 memiliki nilai MAPE yang lebih baik, Sementara pada skenario proporsi 40:60 memiliki nilai MAPE yang tidak lebih baik daripada model terbaik multivariat.

Dari skenario ini model LSTM terbaik masih sangat baik dalam menangani kondisi perbedaan penggunaan data dengan MAPE terburuk masih di angka 2,0863% (Kenaikan 54,40%) pada proporsi 40:60 kasus multivariat dan MAPE terbaik di angka 1,3209% (Penurunan 2,24%) pada data 20:80 kasus multivariat.

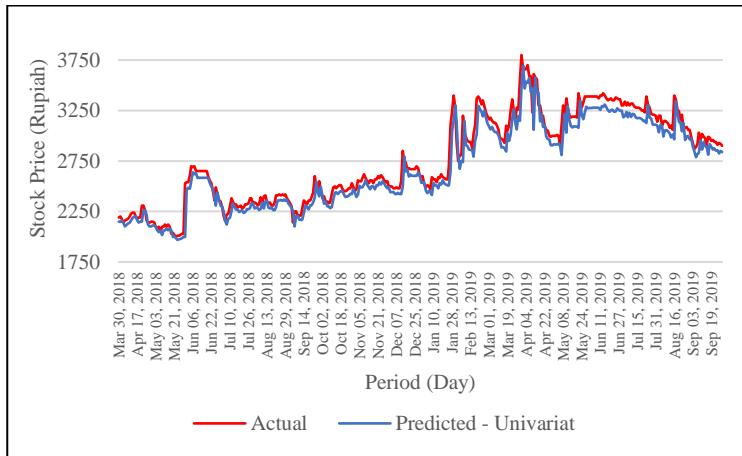
6.7. Hasil Skenario Penggunaan *Dataset Lain*

Skenario kedua dalam menguji model terbaik adalah mengganti *dataset* saham yang digunakan untuk pemodelan. Dengan adanya 2 skenario (KAEF dan SMGR) dan 2 model terbaik (univariat dan multivariat) maka dalam subbab ini terbentuk 4 buah model seperti yang tertera pada Tabel 6.36.

Tabel 6.36. Evaluasi Skenario Penggunaan *Dataset Lain*

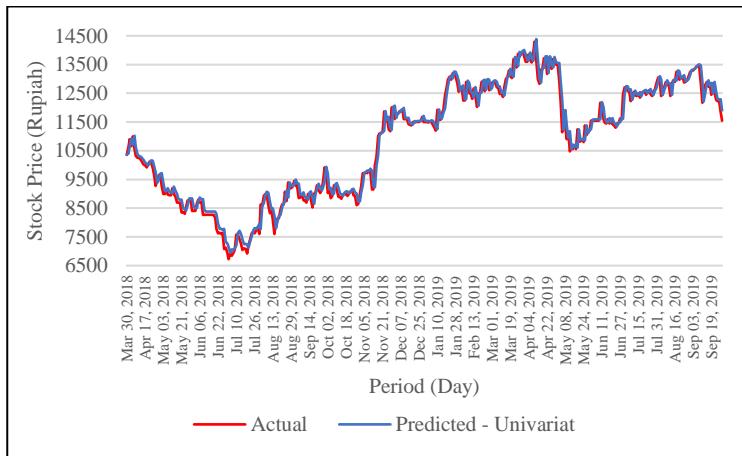
Best Model	Saham	MAPE (%)	Training Time (s)	Training Loss
Univariat	KAEF	2,904	38,3964	0,0009
	SMGR	1,9871	40,0255	0,0007
Multivariat	KAEF	1,8355	19,7056	0,0019
	SMGR	2,1867	23,1727	0,0012

Pada pengujian model terbaik univariat, Skenario penggunaan data saham KAEF menghasilkan MAPE sebesar 2,9040% dengan visualisasi peramalan yang tertera pada Gambar 6.22.



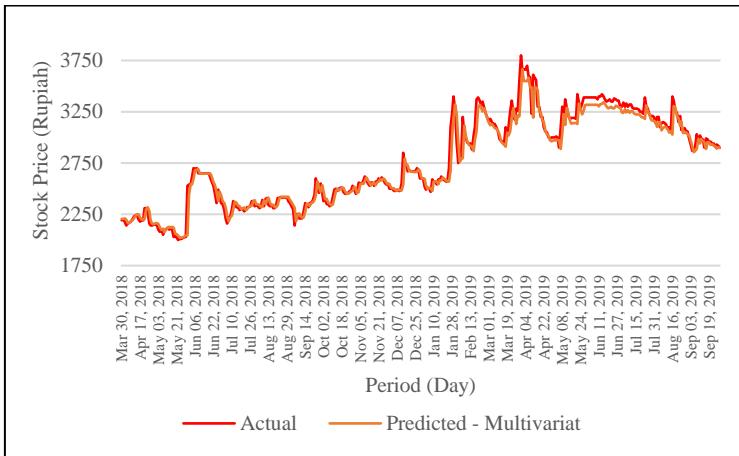
Gambar 6.22. Performa Skenario ‘Data KAEF’ Univariat

Sementara untuk skenario penggunaan data saham SMGR menghasilkan MAPE sebesar 1,9871% dengan visualisasi hasil peramalan yang tertera pada Gambar 6.23.



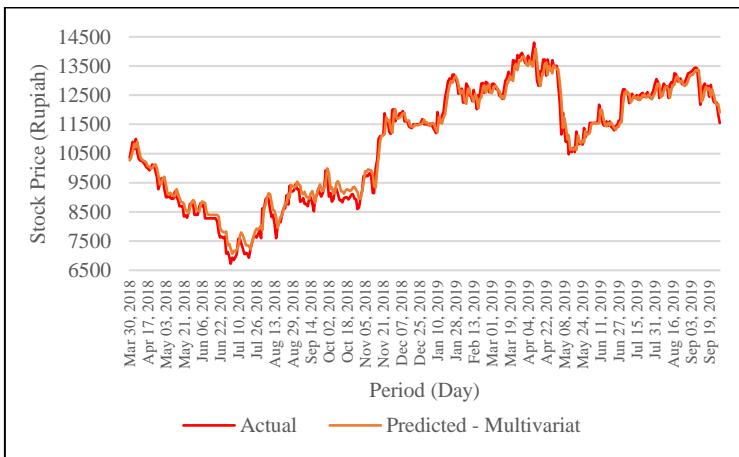
Gambar 6.23. Performa Skenario ‘Data SMGR’ Univariat

Pada pengujian model terbaik multivariat, Skenario penggunaan data saham KAEF dengan MAPE sebesar 1,8355% dengan visualisasi hasil peramalan yang tertera pada Gambar 6.24.



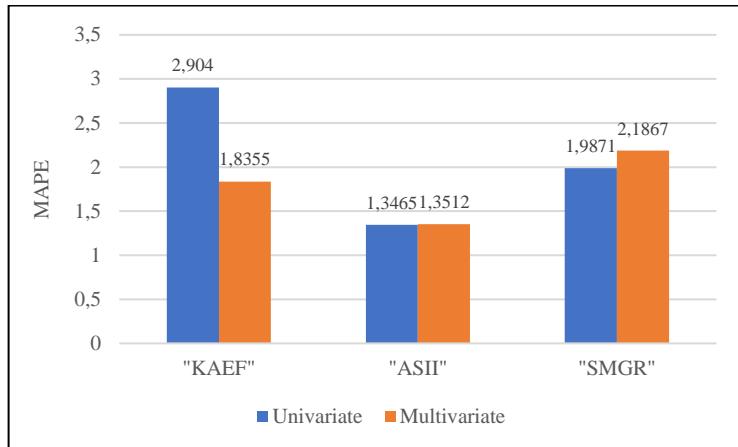
Gambar 6.24. Performa Skenario ‘Data KAEF’ Multivariat

Sementara untuk skenario penggunaan data saham SMGR menghasilkan MAPE sebesar 2,1867% dengan visualisasi hasil peramalan yang tertera pada Gambar 6.25.



Gambar 6.25. Performa Skenario ‘Data SMGR’ Multivariat

Untuk menyimpulkan implementasi skenario dilakukan pengikhtisan terhadap skenario penggunaan data dengan menggunakan *bar chart* seperti pada Gambar 6.24.



Gambar 6.26. Ikhtisar Skenario Penggunaan Data

Pada model terbaik univariat, dilakukan skenario penggunaan *dataset* lain yakni KAEF dan SMGR. Hasilnya pada skenario data KAEF memiliki nilai MAPE yang tidak lebih baik, Sementara pada skenario data SMGR juga memiliki nilai MAPE yang tidak lebih baik daripada model terbaik univariat.

Skenario penggunaan *dataset* lain dilakukan pula pada model terbaik multivariat. Hasilnya pada skenario data KAEF memiliki nilai MAPE yang tidak lebih baik, Sementara pada skenario data SMGR juga memiliki nilai MAPE yang tidak lebih baik daripada model terbaik multivariat.

Nilai MAPE yang tidak lebih baik pada skenario ini dapat dikarenakan adanya perbedaan karakter data mulai dari tren, rentang nilai dan korelasi terhadap prediktor.

Dari skenario ini model LSTM terbaik masih sangat baik dalam menangani kondisi perbedaan penggunaan data dengan MAPE terburuk masih di angka 2,904% (Kenaikan 115,67%) pada data KAEF kasus univariat dan MAPE terbaik di angka 1,8355% (Kenaikan 35,84%) pada data KAEF kasus multivariat.

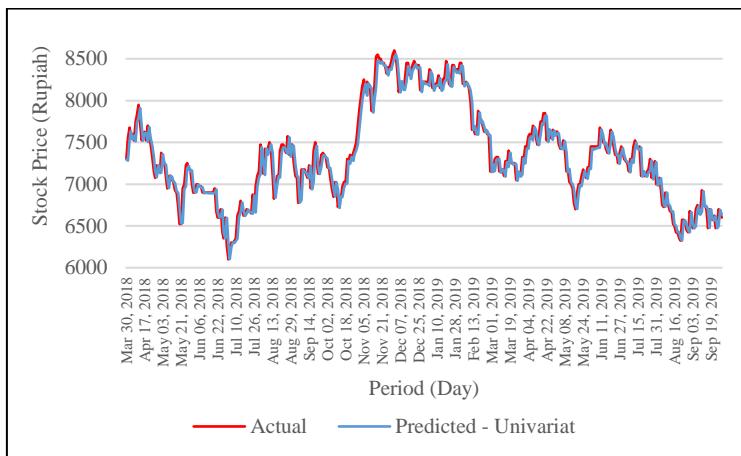
6.8. Hasil Skenario Perbandingan Metode

Skenario ketiga dalam menguji model terbaik adalah mengganti metode tanpa mengubah arsitektur untuk pemodelan. Dengan adanya 1 skenario (GRU) yang diimplementasikan dan 2 skenario (RNN dan ANN) sebagai acuan maka terdapat 6 buah model seperti yang tertera pada Tabel 6.37.

Tabel 6.37. Evaluasi Skenario Perbandingan Metode

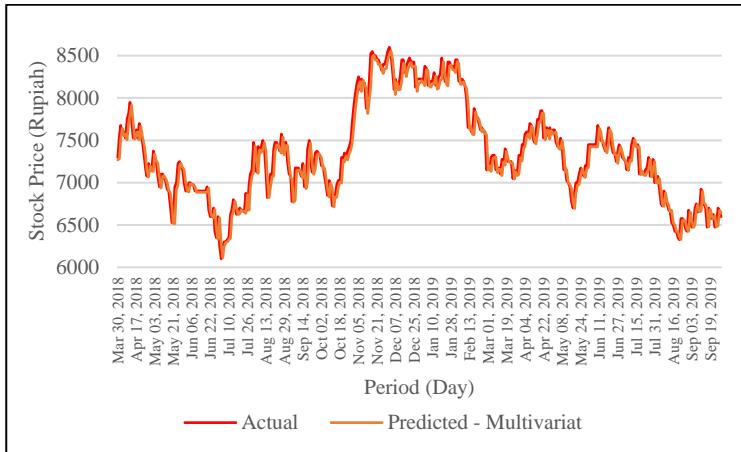
Best Model	Metode	MAPE (%)	Training Time (s)	Training Loss
Univariat	GRU	1,3517	37,8398	0,0015
	RNN	1,5460	37,8600	0,0064
	ANN	1,8350	2,1370	0,0036
Multivariat	GRU	1,3749	19,4091	0,0019
	RNN	1,5590	23,6600	0,0069
	ANN	2,9610	3,1930	0,0034

Pada pengujian model terbaik univariat, Skenario penggunaan metode GRU menghasilkan MAPE sebesar 1,3517% dengan visualisasi hasil peramalan yang tertera pada Gambar 6.27.



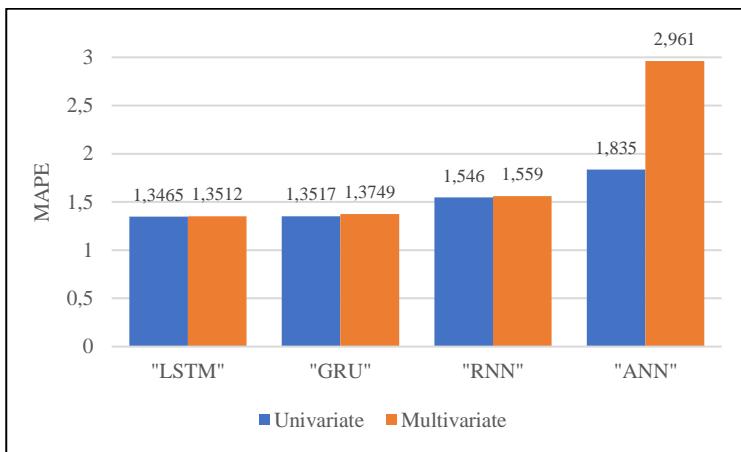
Gambar 6.27. Performa Skenario ‘Metode GRU’ Univariat

Sementara pada kasus multivariat, Skenario penggunaan metode GRU menghasilkan MAPE sebesar 1,3749% dengan visualisasi hasil peramalan yang tertera pada Gambar 6.28.



Gambar 6.28. Performa Skenario ‘Metode ‘GRU’ Multivariat

Untuk menyimpulkan implementasi skenario dilakukan pengikhtisan terhadap skenario penggunaan data dengan menggunakan *bar chart* seperti pada Gambar 6.27.



Gambar 6.29. Ikhtisar Skenario Perbandingan Metode

Pada model terbaik univariat dan multivariat, dilakukan skenario penggunaan metode lain yakni *Gated Recurrent Unit* (GRU). Hasilnya pada skenario GRU memiliki nilai MAPE yang tidak lebih baik. Begitu juga pada metode acuan yakni Recurrent Neural Network (RNN) dan Artificial Neural Network (ANN) yang memiliki nilai MAPE tidak lebih baik.

Dari skenario ini arsitektur model masih sangat baik dalam menangani kondisi perbedaan penggunaan metode dengan MAPE terburuk masih di angka 2,961% (Kenaikan 119%) pada metode ANN kasus multivariat dan MAPE terbaik di angka 1,3517% (Kenaikan 0,39%) pada metode GRU kasus univariat.

6.9. Hasil Skenario Data Masa Depan

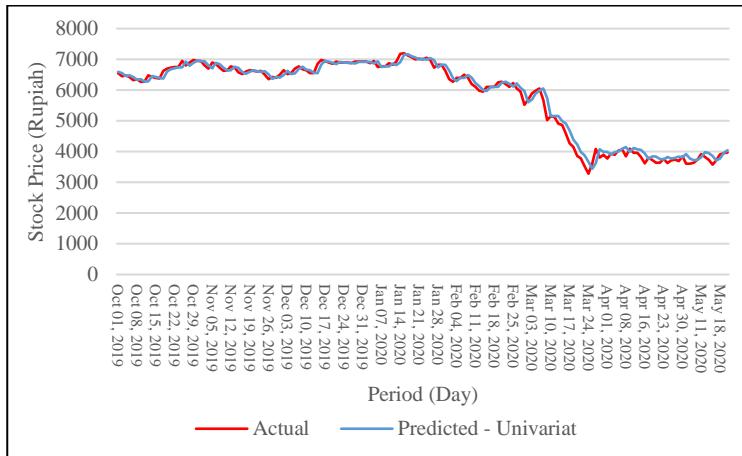
Skenario keempat dalam menguji model terbaik adalah mengganti rentang waktu *dataset* saham yang diprediksi oleh model. Dengan adanya 1 skenario (Data masa depan dengan periode Oktober 2019 hingga Mei 2020) dan 2 model terbaik (univariat dan multivariat) maka dalam subbab ini terbentuk 2 buah model seperti yang tertera pada Tabel 6.38.

Tabel 6.38. Evaluasi Skenario Penggunaan Data Masa Depan

Best Model	Periode Peramalan	MAPE (%)	Training Time (s)	Training Loss
Univariat	10/2019 – 05/2020	2,2979	22,4488	0,0014
Multivariat	10/2019 – 05/2020	3,0185	19,5377	0,0017

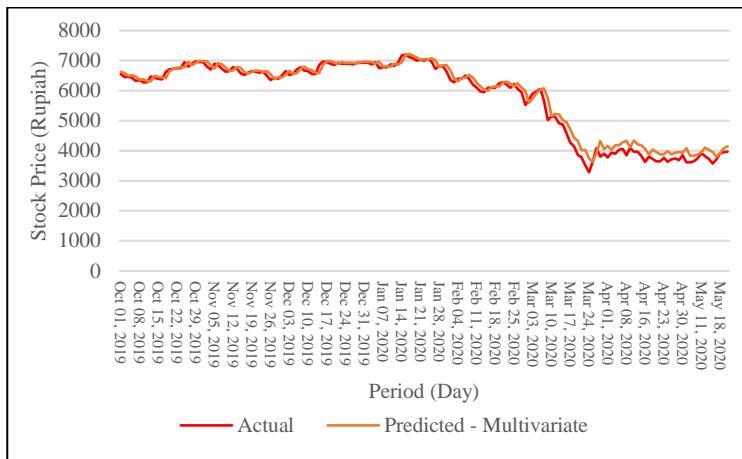
Data untuk memodelkan menggunakan data utama sebanyak 1304 baris dari Oktober 2014 hingga September 2019, Sementara untuk peramalan adalah data selanjutnya sebanyak 163 baris dari Oktober 2019 hingga Mei 2020.

Pada pengujian model terbaik univariat, Skenario peramalan data saham masa depan menghasilkan MAPE sebesar 2,2979% dengan visualisasi peramalan yang tertera pada Gambar 6.30.



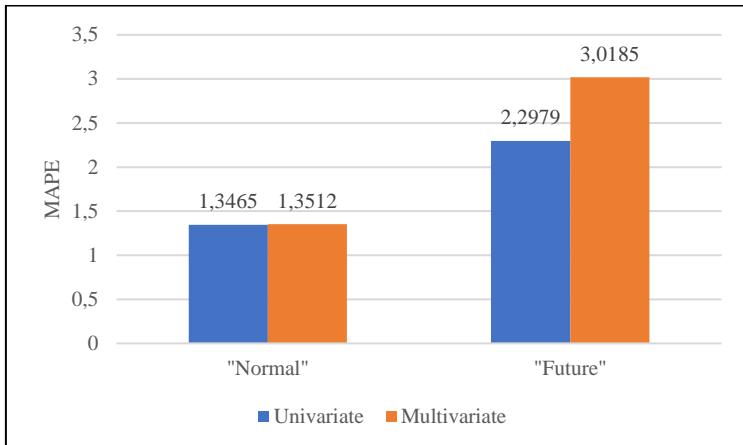
Gambar 6.30. Performa Skenario Data Kedepan Univariat

Pada pengujian model terbaik multivariat, Skenario peramalan data saham masa depan menghasilkan MAPE sebesar 3,0185% dengan visualisasi peramalan yang tertera pada Gambar 6.31.



Gambar 6.31. Performa Skenario Data Kedepan Multivariat

Untuk menyimpulkan implementasi skenario dilakukan pengikhtisaran terhadap skenario data masa depan dengan menggunakan *bar chart* seperti pada Gambar 6.32.



Gambar 6.32. Ikhtisar Skenario Data Masa Depan

Pada model terbaik univariat dan multivariat, dilakukan skenario peramalan data masa depan yakni dengan periode Oktober 2019 hingga Mei 2020. Hasilnya pada skenario ini memiliki nilai MAPE yang tidak lebih baik dari model awal.

Meskipun tidak lebih baik namun dari skenario ini model terbaik masih sangat baik dalam menangani peramalan data masa depan dengan MAPE terburuk di angka 3,0185% (Kenaikan 123,39%) pada multivariat dan MAPE terbaik di angka 2,2979% (Kenaikan 70,66%) pada kasus univariat.

6.10. Kesimpulan Hasil dan Pembahasan

Hasil dan pembahasan dari eksperimen peramalan harga saham berdasarkan faktor makroekonomi menggunakan arsitektur LSTM memiliki beberapa poin penting sebagai berikut:

1. Pada kasus univariat atau peramalan tanpa menggunakan nilai kurs USD/IDR didapatkan model terbaik pada percobaan *timestep* ke-5 dengan kombinasi parameter 50 *hidden units*, 0.1 *dropout rate*, RMSprop *optimizer*, 150 *epoch* dan 32 *batch size* dengan total percobaan sebanyak 2268 kali *tuning parameter* atau sebanyak 7 *timestep*.

2. Pada kasus multivariat atau peramalan menggunakan nilai kurs USD/IDR didapatkan model terbaik pada percobaan *timestep* ke-2 dengan kombinasi parameter 30 *hidden units*, 0.3 *dropout rate*, RMSprop *optimizer*, 200 *epoch* dan 32 *batch size* dengan total percobaan sebanyak 2268 kali *tuning parameter* atau sebanyak 7 *timestep*.
3. Adanya penambahan fitur makroekonomi berupa nilai tukar atau kurs USD/IDR dalam eksperimen peramalan saham dalam tidak menghasilkan performa yang lebih baik.
4. Terdapat kecenderungan parameter tertentu dapat menghasilkan model dengan MAPE yang sangat baik. Parameter yang dimaksud adalah *optimizer* RMSprop (*learning rate* = 0.001 dan *rho* = 0.9) yang sering muncul pada model terbaik di setiap *timestep* baik univariat dan multivariat mengungguli *optimizer* Adam dan SGD.
5. Terdapat kecenderungan parameter tertentu dapat menghasilkan model dengan *training time* yang lama. *Training time* akan cenderung lebih lama ketika parameter *hidden units* semakin tinggi, *epoch* semakin tinggi dan *batch size* semakin rendah. Selain itu struktur data juga berpengaruh seperti banyaknya fitur independen (univariat, multivariat) dan banyaknya *timestep* yang digunakan.
6. Pada skenario proporsi pembagian data dalam pengujian model terbaik, Proporsi *training set* yang lebih tinggi yaitu sebesar 80% dapat menghasilkan model dengan performa yang lebih baik untuk model univariat maupun multivariat. Nilai MAPE terburuk yang dihasilkan pada skenario ini adalah sebesar 2,0863% saat model terbaik multivariat diuji dengan proporsi *training:testing* sebesar 60:40.
7. Pada skenario penggunaan data lain dalam pengujian model terbaik, seluruh skenario data saham lain baik KAEF dan SMGR tidak menghasilkan model dengan performa yang lebih baik. Nilai MAPE terburuk yang dihasilkan pada skenario ini adalah sebesar 2,904% saat model terbaik univariat diuji dengan data saham KAEF.

8. Pada skenario perbandingan metode dalam pengujian model terbaik, Penggunaan metode lain tidak menghasilkan model dengan performa yang lebih baik. Nilai MAPE terburuk yang dihasilkan pada skenario ini adalah sebesar 2,961% saat arsitektur model terbaik multivariat diganti dengan metode ANN.
9. Pada skenario data masa depan dalam pengujian model terbaik, peramalan data masa depan tidak menghasilkan model dengan performa yang lebih baik. Nilai MAPE terburuk yang dihasilkan pada skenario ini adalah sebesar 3,0185% saat model terbaik multivariat diuji dengan data masa depan Astra.
10. Secara keseluruhan, model LSTM terbaik yang dihasilkan dari *tuning parameter* masih sangat baik ketika diuji dengan 12 kondisi yang terbagi dari 4 jenis skenario. Hal tersebut dibuktikan dengan nilai MAPE terburuk di setiap skenario yang masih ada dalam *threshold* sangat baik.

Halaman ini sengaja dikosongkan

BAB VII

KESIMPULAN DAN SARAN

Bab kesimpulan dan saran berisi daftar kesimpulan dari proses penelitian untuk menjawab rumusan masalah dan berisi daftar saran untuk pengembangan yang lebih baik kedepannya.

7.1. Kesimpulan

Kesimpulan yang didapatkan dari proses pengerjaan tugas akhir yang telah dilakukan antara lain :

1. Peramalan harga saham dilakukan dengan dan tanpa faktor makroekonomi. Faktor makroekonomi direpresentasikan dengan variabel kurs dolar atau nilai tukar USD/IDR. Eksperimen peramalan bersifat *full factorial* pada *tuning parameter* di setiap *timestep* dengan total 4536 model.
2. Performa LSTM untuk peramalan harga saham sangat baik. Model terbaik peramalan harga saham tanpa faktor makroekonomi menghasilkan MAPE 1,3465% yang didapat pada *timestep* ke-5, Sementara model terbaik peramalan harga saham dengan faktor makroekonomi menghasilkan MAPE 1,3512% didapat pada *timestep* ke-2.
3. Performa model LSTM terbaik yang dihasilkan masih sangat baik ketika diuji dengan empat skenario yaitu mengubah proporsi pembagian data, menggunakan dataset saham lain, menerapkan metode lain dan meramalkan data masa depan dengan MAPE tertinggi masing-masing 2,0863%, 2,904%, 2,961% dan 3,0185%.
4. Peramalan harga saham Astra menggunakan faktor makroekonomi berupa variabel kurs dolar pada periode data yang digunakan di penelitian tidak menghasilkan performa yang lebih baik dibandingkan dengan peramalan harga saham Astra tanpa menggunakan variabel kurs dolar.

7.2. Saran

Dari penggerjaan tugas akhir ini, adapun beberapa saran untuk pengembangan penelitian ke depan antara lain:

1. Dapat menggunakan asitektur lain dalam *Recurrent Layers*. Contoh modul *Recurrrent Layers* adalah *Recurrent Neural Network* (SimpleRNN), *Gated Recurrent Unit* (GRU), *Convolutional Long Short-Term Memory* (ConvLSTM2D) dan *Long Short-Term Memory Cell* (LSTMCell).
2. Mempertimbangkan Inflasi, Ekspor, Produk Domestik Bruto (PDB) atau faktor makroekonomi yang lain sebagai variabel bebas (prediktor) dalam meramalkan harga saham.
3. Untuk membuat model mempelajari lebih banyak data disarankan menggunakan periode waktu yang lebih lama

DAFTAR PUSTAKA

- [1] D. Wartati and N. A. Masruroh, "Aplikasi Jaringan Saraf Tiruan Dan Particle Swarm Optimization Untuk Peramalan Indeks Harga Saham Bursa Efek Indonesia," *J. Teknosains*, vol. 6, no. 1, p. 22, 2017, doi: 10.22146/teknosains.27616.
- [2] S. Suryanto, "Strategi Investasi di Bursa Saham," *The Winners*, vol. 3, no. 1, p. 79, 2002, doi: 10.21512/tw.v3i1.3834.
- [3] L. P. Putri, "Pengaruh Inflasi dan Nilai Tukar Rupiah atas Dollar AS terhadap Kinerja Saham Perusahaan Property dan Real Estate di Indonesia," vol. 151, pp. 10–17, 2015, doi: 10.1145/3132847.3132886.
- [4] H. A. Putranto, "Kelayakan Finansial Ekonomi Mahasiswa dalam Investasi Saham di Galeri Investasi Syariah UIN Sunan Ampel Surabaya," *Oeconomicus J. Econ.*, vol. 1, no. 1, pp. 1–20, 2016.
- [5] "Tentang Astra," *Website Company Profile*. <https://www.astra.co.id/About-Astra> (accessed Oct. 29, 2019).
- [6] S. Roondiwala, M., Patel, H. and Varma, "Predicting Stock Prices Using LSTM.," *Int. J. Sci. Res.*, 1754-1756, no. September, pp. 2–5, 2015, doi: 10.21275/ART20172755.
- [7] M. Karafi and J. H. Cernock, "Recurrent Neural Network Based Language Model," *11th Annu. Conf. Int. Speech Commun. Assoc.*, pp. 1045–1048, 2010, doi: 10.1021/jp056727x.
- [8] A. A. Rizal and S. Soraya, "Multi Time Steps Prediction dengan Recurrent Neural Network Long Short Term Memory," *MATRIK J. Manajemen, Tek. Inform. dan Rekayasa Komput.*, vol. 18, no. 1, pp. 115–124, 2018, doi: 10.30812/matrik.v18i1.344.
- [9] M. A. D. Suyudi, E. C. Djamaral, and A. Maspupah, "Prediksi Harga Saham menggunakan Metode Recurrent Neural Network," *Wikipedia*, vol. 052, no. 735, pp. 3–6,

- 2015.
- [10] F. E. Unissula, "Analisis Dampak Variabel Makro Ekonomi Terhadap Indeks Saham Syariah Indonesia," *Conf. Business, Accounting, Manag.*, pp. 398–412, 2013.
 - [11] H. Liu, X. wei Mi, and Y. fei Li, "Wind speed forecasting method based on deep learning strategy using empirical wavelet transform, long short term memory neural network and Elman neural network," *Energy Convers. Manag.*, vol. 156, no. November 2017, pp. 498–514, 2018, doi: 10.1016/j.enconman.2017.11.053.
 - [12] A. Subekti, "Pengelolaan Kas Daerah untuk Mendukung Peningkatan Pendapatan Asli Daerah Kabupaten Pekalongan," Universitas Indonesia, 2010.
 - [13] M. Suherli and S. S. Harahap, "Studi Empiris Terhadap Faktor Penentu Kebijakan Jumlah Dividen," *Media Ris. Akuntansi, Audit. dan Inf.*, vol. 4, no. 3, pp. 223–245, 2004.
 - [14] P. T. Sanggor, "Faktor-faktor yang Mempengaruhi Perubahan Kurs Mata Uang Rupiah terhadap Euro," *J. EMBA*, vol. 1, no. 4, pp. 1416–1430, 2013.
 - [15] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Comput.*, pp. 1735–1780, 1997, doi: 10.1162/neco.1997.9.8.1735.
 - [16] C. Olah, "Understanding LSTM Networks," 2015. <https://colah.github.io/posts/2015-08-Understanding-LSTMs/> (accessed Nov. 03, 2019).
 - [17] D. A. I. Maruddani and T. Trimono, "Prediksi Harga Saham PT Astra Agro Lestari Tbk dengan Jump Diffusion Model," *J. Ris. Akunt. Mercu Buana*, vol. 3, no. 1, p. 57, 2017, doi: 10.26486/jramb.v3i1.407.
 - [18] H. Hassani, M. Kalantari, and Z. Ghodsi, "Evaluating the Performance of Multiple Imputation Methods for Handling Missing Values in Time Series Data: A Study Focused on East Africa, Soil-Carbonate-Stable Isotope Data," *Stats*, vol. 2, no. 4, pp. 457–467, 2019, doi: 10.3390/stats2040032.

- [19] S. Moritz, A. Sardá, T. Bartz-Beielstein, M. Zaefferer, and J. Stork, “Comparison of different Methods for Univariate Time Series Imputation in R,” 2015, [Online]. Available: <http://arxiv.org/abs/1510.03924>.
- [20] S. Li, W. Li, C. Cook, C. Zhu, and Y. Gao, “Independently Recurrent Neural Network (IndRNN): Building A Longer and Deeper RNN,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, no. 1, pp. 5457–5466, 2018, doi: 10.1109/CVPR.2018.00572.
- [21] A. S. Saud and S. Shakya, “Analysis of look back period for stock price prediction with RNN variants: A case study on banking sector of NEPSE,” *Procedia Comput. Sci.*, vol. 167, no. 2019, pp. 788–798, 2020, doi: 10.1016/j.procs.2020.03.419.
- [22] “Recurrent Layers,” *Keras Documentation*. <https://keras.io/layers/recurrent/> (accessed Mar. 20, 2020).
- [23] “Usage of Optimizers,” *Keras Documentation*. <https://keras.io/optimizers/> (accessed Mar. 20, 2020).

Halaman ini sengaja dikosongkan

BIODATA PENULIS



Penulis bernama lengkap Muslikh Annur Meiviananda dan biasa dipanggil Muslikh. Penulis merupakan anak ketiga dari empat bersaudara yang mana lahir di Semarang, 25 Mei 1999. Penulis telah menempuh beberapa pendidikan formal sebelumnya antara lain SD Muhamadiyah 4 Pucang Surabaya, SMP Negeri 1 Surabaya dan SMA Negeri 10 Surabaya.

Pada tahun 2016 pasca kelulusan SMA, Penulis melanjutkan pendidikan di Program Studi Sistem Informasi, Fakultas Teknologi Elektro dan Informatika Cerdas — Institut Teknologi Sepuluh Nopember Surabaya melalui jalur PKM dan terdaftar sebagai mahasiswa dengan NRP 05211640000092.

Pada bidang non-akademik, penulis aktif mengikuti kegiatan kepanitian dan organisasi seperti Tim Formatur, IS Expo dan HMSI ITS selama dua tahun. Pada tahun kedua menjabat, Penulis bertugas pada posisi strategis antara lain Koordinator Tim Formatur, Staf Ahli Divisi IT Development IS Expo dan Kepala Departemen Kesejahteraan Mahasiswa HMSI ITS.

Pada bidang akademik, penulis aktif menjadi asisten dosen pada mata kuliah Pengantar Sistem Operasi dan Kecerdasan Bisnis. Selain itu pada tahun 2019 penulis mengikuti beberapa kompetisi data tingkat Nasional dan berhasil meraih prestasi Juara 2 Penggalian Data GemasTIK XII dari Kemenristekdikti, Juara 3 Data Science Competition IT Today dari Himalkom IPB dan Finalis Data Science Competition MCF dari Himatika ITB. Penulis juga memiliki total 6 bulan pengalaman magang sebagai *Data Analyst* di Telkom Indonesia dan Garena Indonesia.

Pada tahun keempat, karena penulis memiliki ketertarikan di bidang rekayasa data, maka penulis mengambil minat di Lab Rekayasa Data dan Intelelegensi Bisnis (RDIB). Penulis dapat dihubungi melalui email di muslikhannurm@gmail.com.

Halaman ini sengaja dikosongkan

LAMPIRAN A

Data Historis Nilai Tukar USD/IDR dan Harga Saham

No.	Date	Price_Kurs	Price_ASII	Price_KAEF	Price_SMGR
1	Oct 01, 2014	12127,5	7000	1145	15150
2	Oct 02, 2014	12150	6600	1105	14700
3	Oct 03, 2014	12176,5	6600	1070	14625
4	Oct 06, 2014	12210	6725	1080	15050
5	Oct 07, 2014	12202,5	6800	1065	15400
6	Oct 08, 2014	12240	6700	1030	14750
7	Oct 09, 2014	12185	6725	1090	14825
8	Oct 10, 2014	12220	6500	1115	14850
9	Oct 13, 2014	12216	6350	1090	15100
10	Oct 14, 2014	12207,5	6400	1090	15100
11	Oct 15, 2014	12225	6400	1110	15625
12	Oct 16, 2014	12247,5	6350	1125	15500
13	Oct 17, 2014	12106,5	6550	1180	16000
14	Oct 20, 2014	12032,5	6600	1165	16000
15	Oct 21, 2014	12000	6500	1140	15700
16	Oct 22, 2014	12012,5	6550	1140	16100
17	Oct 23, 2014	12060	6700	1150	16100
18	Oct 24, 2014	12066	6600	1125	15900
19	Oct 27, 2014	12112,5	6525	1120	15800
20	Oct 28, 2014	12170	6650	1110	15575
21	Oct 29, 2014	12080	6875	1105	16025
22	Oct 30, 2014	12125	6900	1110	15700
23	Oct 31, 2014	12085	6775	1155	15875
24	Nov 03, 2014	12107,5	6875	1240	15775
25	Nov 04, 2014	12107,5	6775	1250	15700

26	Nov 05, 2014	12142,5	6950	1265	15600
27	Nov 06, 2014	12140	6950	1240	15375
28	Nov 07, 2014	12172,5	6950	1250	15300
29	Nov 10, 2014	12152,5	6725	1275	15200
30	Nov 11, 2014	12205	6875	1300	15300
31	Nov 12, 2014	12198,5	7100	1310	15475
32	Nov 13, 2014	12202,5	7100	1315	15600
33	Nov 14, 2014	12211	7175	1310	15975
34	Nov 17, 2014	12204,5	7125	1300	15850
35	Nov 18, 2014	12150	7200	1325	15950
36	Nov 19, 2014	12147,5	7150	1345	16075
37	Nov 20, 2014	12175	6875	1350	16000
38	Nov 21, 2014	12148,5	6950	1390	16100
39	Nov 24, 2014	12151,5	7100	1390	16300
40	Nov 25, 2014	12164	6900	1380	16075
41	Nov 26, 2014	12175	7025	1370	16000
42	Nov 27, 2014	12177	7100	1375	16050
43	Nov 28, 2014	12204	7125	1390	16000
44	Dec 01, 2014	12272,5	7125	1380	16675
45	Dec 02, 2014	12270	7000	1385	16500
46	Dec 03, 2014	12298,5	6900	1440	16575
47	Dec 04, 2014	12307,5	6975	1440	16500
48	Dec 05, 2014	12296,5	7100	1425	16550
49	Dec 08, 2014	12348,5	7100	1375	16625
50	Dec 09, 2014	12329,5	7100	1405	16475
51	Dec 10, 2014	12336,5	7150	1425	16550
52	Dec 11, 2014	12348,5	7100	1445	16375
53	Dec 12, 2014	12457,5	7175	1425	16525
54	Dec 15, 2014	12697,5	7025	1395	16150
55	Dec 16, 2014	12680	7100	1350	15500

56	Dec 17, 2014	12657,5	7025	1330	15350
57	Dec 18, 2014	12562,5	7200	1375	15800
58	Dec 19, 2014	12485	7200	1375	15975
59	Dec 22, 2014	12439	7125	1400	16000
60	Dec 23, 2014	12450	7275	1425	16075
61	Dec 24, 2014	12467,5	7325	1435	16100
62	Dec 25, 2014	12467,5	7325	1435	16100
63	Dec 26, 2014	12467,5	7325	1435	16100
64	Dec 29, 2014	12447	7350	1455	16175
65	Dec 30, 2014	12446,5	7425	1465	16200
66	Dec 31, 2014	12385	7425	1465	16200
67	Jan 01, 2015	12385	7425	1465	16200
68	Jan 02, 2015	12542,5	7400	1445	16200
69	Jan 05, 2015	12627,5	7225	1430	16225
70	Jan 06, 2015	12657,5	7050	1405	15925
71	Jan 07, 2015	12738,5	7150	1400	15975
72	Jan 08, 2015	12680	7075	1380	15875
73	Jan 09, 2015	12651,5	7025	1355	15750
74	Jan 12, 2015	12597,5	7000	1330	15950
75	Jan 13, 2015	12597,5	7175	1325	16150
76	Jan 14, 2015	12613	7050	1325	15925
77	Jan 15, 2015	12560	7275	1325	16200
78	Jan 16, 2015	12587,5	7300	1290	15000
79	Jan 19, 2015	12618,5	7425	1250	14100
80	Jan 20, 2015	12584	7450	1335	14175
81	Jan 21, 2015	12480	7675	1310	14100
82	Jan 22, 2015	12487,5	7750	1310	14400
83	Jan 23, 2015	12472,5	8075	1310	14475
84	Jan 26, 2015	12510	8025	1265	14475
85	Jan 27, 2015	12476,5	7825	1285	14525

86	Jan 28, 2015	12486	7825	1295	14475
87	Jan 29, 2015	12567,5	7750	1300	14400
88	Jan 30, 2015	12667,5	7850	1340	14575
89	Feb 02, 2015	12685	7750	1330	14500
90	Feb 03, 2015	12654	7625	1300	14675
91	Feb 04, 2015	12625	7725	1300	14775
92	Feb 05, 2015	12632,5	7550	1280	14625
93	Feb 06, 2015	12614,5	7600	1280	14775
94	Feb 09, 2015	12647,5	7575	1275	14900
95	Feb 10, 2015	12672,5	7625	1275	14725
96	Feb 11, 2015	12715	7875	1340	14725
97	Feb 12, 2015	12792,5	7925	1305	14400
98	Feb 13, 2015	12787,5	7950	1275	14450
99	Feb 16, 2015	12752,5	7800	1250	14500
100	Feb 17, 2015	12769,5	7800	1245	14675
101	Feb 18, 2015	12842,5	7950	1270	14775
102	Feb 19, 2015	12842,5	7950	1270	14775
103	Feb 20, 2015	12812,5	7850	1295	14750
104	Feb 23, 2015	12834,5	7900	1325	14800
105	Feb 24, 2015	12897,5	8000	1320	14925
106	Feb 25, 2015	12873,5	8150	1395	15150
107	Feb 26, 2015	12837,5	8050	1445	15100
108	Feb 27, 2015	12925	7850	1430	14875
109	Mar 02, 2015	12970	7875	1435	14900
110	Mar 03, 2015	12965	8000	1380	14825
111	Mar 04, 2015	12982,5	7875	1385	14875
112	Mar 05, 2015	12990	7850	1375	14900
113	Mar 06, 2015	12980	8075	1365	14950
114	Mar 09, 2015	13050	7950	1365	14750
115	Mar 10, 2015	13091,5	7975	1360	14700

116	Mar 11, 2015	13190,5	7850	1335	14450
117	Mar 12, 2015	13182,5	7900	1415	14375
118	Mar 13, 2015	13195	7875	1365	14225
119	Mar 16, 2015	13242	7975	1335	14400
120	Mar 17, 2015	13167,5	8000	1335	14500
121	Mar 18, 2015	13170	7975	1330	14250
122	Mar 19, 2015	13035	8050	1310	14400
123	Mar 20, 2015	13116	8100	1300	13800
124	Mar 23, 2015	13019,5	8175	1300	13525
125	Mar 24, 2015	12905	8150	1360	13425
126	Mar 25, 2015	12986	8200	1345	12875
127	Mar 26, 2015	13019	8150	1285	13000
128	Mar 27, 2015	13065	8200	1320	13450
129	Mar 30, 2015	13075	8375	1320	13550
130	Mar 31, 2015	13075	8575	1315	13650
131	Apr 01, 2015	13042,5	8175	1315	13650
132	Apr 02, 2015	13002,5	8075	1295	13600
133	Apr 03, 2015	13002,5	8075	1295	13600
134	Apr 06, 2015	12958,5	8200	1300	13625
135	Apr 07, 2015	12985	8150	1290	13675
136	Apr 08, 2015	12955	7975	1265	13475
137	Apr 09, 2015	12898	8150	1285	13550
138	Apr 10, 2015	12915	8150	1285	13425
139	Apr 13, 2015	12985	8175	1250	13000
140	Apr 14, 2015	12980,5	8200	1230	12850
141	Apr 15, 2015	12900,5	8175	1215	13125
142	Apr 16, 2015	12856	8050	1215	13700
143	Apr 17, 2015	12850	7975	1205	13800
144	Apr 20, 2015	12890	7700	1240	13750
145	Apr 21, 2015	12957,5	7925	1220	13825

146	Apr 22, 2015	12900	7900	1185	13700
147	Apr 23, 2015	12955	7900	1180	13550
148	Apr 24, 2015	12919,5	7875	1190	13525
149	Apr 27, 2015	12980	7450	1100	13325
150	Apr 28, 2015	12980	7375	1150	13225
151	Apr 29, 2015	12940	7100	1150	12975
152	Apr 30, 2015	12962,5	6850	1230	12500
153	May 01, 2015	12962,5	6850	1230	12500
154	May 04, 2015	12980	7100	1250	12725
155	May 05, 2015	13047,5	7275	1235	13000
156	May 06, 2015	13035	7350	1215	13100
157	May 07, 2015	13145	7200	1220	12875
158	May 08, 2015	13127,5	7400	1190	13325
159	May 11, 2015	13155	7325	1155	13275
160	May 12, 2015	13198	7375	1140	13225
161	May 13, 2015	13137,5	7525	1135	13025
162	May 14, 2015	13137,5	7525	1135	13025
163	May 15, 2015	13091	7500	1130	13300
164	May 18, 2015	13137	7550	1195	13375
165	May 19, 2015	13115,5	7700	1170	13325
166	May 20, 2015	13175	7850	1170	13150
167	May 21, 2015	13129,5	7825	1155	13200
168	May 22, 2015	13155	7575	1130	13125
169	May 25, 2015	13186,5	7575	1125	13150
170	May 26, 2015	13210	7500	1115	13250
171	May 27, 2015	13202	7425	1100	13175
172	May 28, 2015	13221,5	7375	1100	13350
173	May 29, 2015	13224	7300	1120	13450
174	Jun 01, 2015	13222,5	7325	1085	13475
175	Jun 02, 2015	13222,5	7325	1085	13475

176	Jun 03, 2015	13221	7050	1060	13300
177	Jun 04, 2015	13282	7025	1045	13250
178	Jun 05, 2015	13275,5	7000	1030	13225
179	Jun 08, 2015	13379,5	6925	995	12975
180	Jun 09, 2015	13302,5	6850	965	12575
181	Jun 10, 2015	13312,5	6850	985	12825
182	Jun 11, 2015	13320,5	6950	990	12650
183	Jun 12, 2015	13332,5	7075	985	12525
184	Jun 15, 2015	13335	6850	965	12300
185	Jun 16, 2015	13353	6975	970	12150
186	Jun 17, 2015	13367,5	7000	985	12400
187	Jun 18, 2015	13305	7025	1005	12300
188	Jun 19, 2015	13331,5	7050	1000	12425
189	Jun 22, 2015	13310	7000	1010	12350
190	Jun 23, 2015	13255	6825	990	12250
191	Jun 24, 2015	13303,5	6950	1000	12300
192	Jun 25, 2015	13327,5	6850	995	12100
193	Jun 26, 2015	13310	6825	995	12075
194	Jun 29, 2015	13345	6875	990	12000
195	Jun 30, 2015	13332,5	7075	995	12000
196	Jul 01, 2015	13326	7025	985	12000
197	Jul 02, 2015	13337,5	7075	995	12350
198	Jul 03, 2015	13320	7050	1045	12250
199	Jul 06, 2015	13349,5	7000	1005	11900
200	Jul 07, 2015	13327,5	6900	1035	11625
201	Jul 08, 2015	13345	6650	1020	11525
202	Jul 09, 2015	13336	6650	1025	11300
203	Jul 10, 2015	13313,5	6675	1015	11200
204	Jul 13, 2015	13300	6800	1020	11300
205	Jul 14, 2015	13335	6850	1120	11550

206	Jul 15, 2015	13344,5	6825	1090	11575
207	Jul 16, 2015	13344,5	6825	1090	11575
208	Jul 17, 2015	13344,5	6825	1090	11575
209	Jul 20, 2015	13344,5	6825	1090	11575
210	Jul 21, 2015	13344,5	6825	1090	11575
211	Jul 22, 2015	13377,5	6950	1070	11600
212	Jul 23, 2015	13422,5	6875	1090	11500
213	Jul 24, 2015	13445	6650	1065	11225
214	Jul 27, 2015	13459	6425	1010	10250
215	Jul 28, 2015	13462,5	6350	1005	10100
216	Jul 29, 2015	13456	6425	985	10275
217	Jul 30, 2015	13467,5	6575	985	9925
218	Jul 31, 2015	13527,5	6650	990	10100
219	Aug 03, 2015	13500	6700	950	9850
220	Aug 04, 2015	13485,5	6625	955	9950
221	Aug 05, 2015	13514	6800	955	10200
222	Aug 06, 2015	13541,5	6750	960	9875
223	Aug 07, 2015	13539,5	6600	960	9950
224	Aug 10, 2015	13549	6500	920	9700
225	Aug 11, 2015	13600	6175	830	9050
226	Aug 12, 2015	13785	6075	785	8650
227	Aug 13, 2015	13745	6400	845	8850
228	Aug 14, 2015	13787,5	6425	840	8725
229	Aug 17, 2015	13787,5	6425	840	8725
230	Aug 18, 2015	13818	6175	800	8225
231	Aug 19, 2015	13842,5	6175	775	8250
232	Aug 20, 2015	13870	6200	740	8075
233	Aug 21, 2015	13942,5	6050	700	7975
234	Aug 24, 2015	14047	5675	645	7200
235	Aug 25, 2015	14065	5600	645	7700

236	Aug 26, 2015	14122,5	5625	620	8675
237	Aug 27, 2015	13992,5	5825	655	8950
238	Aug 28, 2015	13982,5	5775	695	9350
239	Aug 31, 2015	14050	5925	700	9250
240	Sep 01, 2015	14097,5	5700	730	9025
241	Sep 02, 2015	14130	5975	725	9025
242	Sep 03, 2015	14169	6150	715	9225
243	Sep 04, 2015	14165	6200	705	9050
244	Sep 07, 2015	14247,5	5850	695	8375
245	Sep 08, 2015	14280	5875	690	8800
246	Sep 09, 2015	14261,5	6100	705	9250
247	Sep 10, 2015	14332,5	6050	690	10300
248	Sep 11, 2015	14330	6125	665	10300
249	Sep 14, 2015	14347,5	6125	665	10200
250	Sep 15, 2015	14407,5	6025	665	10000
251	Sep 16, 2015	14455	5900	675	9700
252	Sep 17, 2015	14457,5	5925	710	9700
253	Sep 18, 2015	14375	5800	700	9775
254	Sep 21, 2015	14455	5800	690	9750
255	Sep 22, 2015	14497,5	5800	675	9475
256	Sep 23, 2015	14647,5	5500	655	9475
257	Sep 24, 2015	14647,5	5500	655	9475
258	Sep 25, 2015	14685	5550	650	9475
259	Sep 28, 2015	14697,5	5175	615	9150
260	Sep 29, 2015	14682,5	5300	630	9100
261	Sep 30, 2015	14650	5225	640	9050
262	Oct 01, 2015	14670	5275	640	9200
263	Oct 02, 2015	14642,5	5125	625	9100
264	Oct 05, 2015	14495	5325	665	10050
265	Oct 06, 2015	14245,5	5925	660	10075

266	Oct 07, 2015	13825	6125	735	10750
267	Oct 08, 2015	13867,5	6325	735	10450
268	Oct 09, 2015	13420	6700	775	10550
269	Oct 12, 2015	13405	6700	815	10600
270	Oct 13, 2015	13619,5	6125	825	10150
271	Oct 14, 2015	13619,5	6125	825	10150
272	Oct 15, 2015	13455	6400	820	10150
273	Oct 16, 2015	13530	6300	855	10400
274	Oct 19, 2015	13531,5	6500	900	10625
275	Oct 20, 2015	13645	6350	910	10575
276	Oct 21, 2015	13717	6325	885	11250
277	Oct 22, 2015	13657,5	6200	930	10725
278	Oct 23, 2015	13635	6300	935	10850
279	Oct 26, 2015	13645	6300	930	10700
280	Oct 27, 2015	13622,5	6250	915	10325
281	Oct 28, 2015	13477,5	6075	870	10325
282	Oct 29, 2015	13635	5800	830	9800
283	Oct 30, 2015	13687,5	5900	865	9800
284	Nov 02, 2015	13667,5	6250	850	9750
285	Nov 03, 2015	13555	6425	865	10200
286	Nov 04, 2015	13555	6550	880	10600
287	Nov 05, 2015	13565	6500	875	10650
288	Nov 06, 2015	13560	6600	940	10675
289	Nov 09, 2015	13647,5	6425	965	10250
290	Nov 10, 2015	13609,5	6500	980	9950
291	Nov 11, 2015	13602,5	6775	1015	10500
292	Nov 12, 2015	13602,5	6600	960	10150
293	Nov 13, 2015	13665	6600	935	10675
294	Nov 16, 2015	13727,5	6425	975	10800
295	Nov 17, 2015	13747,5	6325	965	11100

296	Nov 18, 2015	13799,5	6350	960	11500
297	Nov 19, 2015	13777,5	6250	955	11400
298	Nov 20, 2015	13655	6300	960	11400
299	Nov 23, 2015	13723	6250	995	11400
300	Nov 24, 2015	13707,5	6250	990	10925
301	Nov 25, 2015	13687,5	6175	980	11050
302	Nov 26, 2015	13728,5	6225	990	11175
303	Nov 27, 2015	13780	6225	970	11025
304	Nov 30, 2015	13835	5925	970	10625
305	Dec 01, 2015	13782,5	6375	975	11025
306	Dec 02, 2015	13797,5	6300	975	11175
307	Dec 03, 2015	13843,5	6300	980	11075
308	Dec 04, 2015	13832	6400	960	10950
309	Dec 07, 2015	13842,5	6525	955	11000
310	Dec 08, 2015	13872,5	6200	925	10975
311	Dec 09, 2015	13872,5	6200	925	10975
312	Dec 10, 2015	13935	6225	865	11200
313	Dec 11, 2015	13947,5	5900	845	10750
314	Dec 14, 2015	14077,5	6125	795	10450
315	Dec 15, 2015	14056,5	6275	825	10400
316	Dec 16, 2015	14069,5	6275	840	10550
317	Dec 17, 2015	14006,5	6400	890	10800
318	Dec 18, 2015	13917,5	6275	870	10475
319	Dec 21, 2015	13772,5	6250	880	10900
320	Dec 22, 2015	13675	6075	865	10975
321	Dec 23, 2015	13642,5	6000	840	11200
322	Dec 24, 2015	13642,5	6000	840	11200
323	Dec 25, 2015	13642,5	6000	840	11200
324	Dec 28, 2015	13650	6000	870	11050
325	Dec 29, 2015	13745	6025	875	11175

326	Dec 30, 2015	13782,5	6000	870	11400
327	Dec 31, 2015	13787,5	6000	870	11400
328	Jan 01, 2016	13787,5	6000	870	11400
329	Jan 04, 2016	13915	5900	850	11125
330	Jan 05, 2016	13862,5	6125	865	11150
331	Jan 06, 2016	13947,5	6075	895	11450
332	Jan 07, 2016	13927,5	5975	885	11050
333	Jan 08, 2016	13922,5	6050	900	10975
334	Jan 11, 2016	13875	5950	880	10700
335	Jan 12, 2016	13910	5925	875	10825
336	Jan 13, 2016	13827,5	5900	890	10900
337	Jan 14, 2016	13910	5875	890	10600
338	Jan 15, 2016	13894,5	6000	945	10600
339	Jan 18, 2016	13932,5	5900	930	10450
340	Jan 19, 2016	13880	5925	935	10575
341	Jan 20, 2016	13960	5775	945	10200
342	Jan 21, 2016	13910	5850	915	10075
343	Jan 22, 2016	13850	5900	910	10350
344	Jan 25, 2016	13872,5	6125	915	10300
345	Jan 26, 2016	13900	6125	930	10050
346	Jan 27, 2016	13878,5	6150	1090	10575
347	Jan 28, 2016	13874,5	6250	1070	10700
348	Jan 29, 2016	13775	6450	1050	11050
349	Feb 01, 2016	13637,5	6350	1105	10975
350	Feb 02, 2016	13687,5	6125	1155	10800
351	Feb 03, 2016	13765	6200	1140	10475
352	Feb 04, 2016	13637,5	6325	1135	10625
353	Feb 05, 2016	13625	6650	1125	10825
354	Feb 08, 2016	13625	6650	1125	10825
355	Feb 09, 2016	13605	6775	1100	10700

356	Feb 10, 2016	13462,5	6800	1080	10750
357	Feb 11, 2016	13462,5	7125	1125	10975
358	Feb 12, 2016	13490	6825	1120	10875
359	Feb 15, 2016	13375	6775	1150	10750
360	Feb 16, 2016	13400	6900	1150	10700
361	Feb 17, 2016	13510	7000	1150	10575
362	Feb 18, 2016	13495	7050	1145	10475
363	Feb 19, 2016	13495	6900	1125	10175
364	Feb 22, 2016	13437,5	6750	1110	10125
365	Feb 23, 2016	13425	6525	1085	10100
366	Feb 24, 2016	13412,5	6400	1100	10100
367	Feb 25, 2016	13410,5	6425	1080	10200
368	Feb 26, 2016	13370	6800	1080	10250
369	Feb 29, 2016	13372	6800	1075	10250
370	Mar 01, 2016	13350	7000	1095	10250
371	Mar 02, 2016	13290	7100	1175	10400
372	Mar 03, 2016	13235	6875	1210	10375
373	Mar 04, 2016	13135	6900	1190	10425
374	Mar 07, 2016	13090	6850	1240	10400
375	Mar 08, 2016	13143	6725	1245	10400
376	Mar 09, 2016	13143	6725	1245	10400
377	Mar 10, 2016	13072,5	6925	1260	10600
378	Mar 11, 2016	13070	7050	1295	10550
379	Mar 14, 2016	13060	7200	1280	10575
380	Mar 15, 2016	13177,5	7100	1255	10475
381	Mar 16, 2016	13267,5	7200	1290	10600
382	Mar 17, 2016	13095	7325	1300	10575
383	Mar 18, 2016	13117,5	7450	1280	10500
384	Mar 21, 2016	13135	7450	1260	10450
385	Mar 22, 2016	13180	7450	1270	10650

386	Mar 23, 2016	13177,5	7400	1285	10725
387	Mar 24, 2016	13252,5	7375	1310	10725
388	Mar 25, 2016	13252,5	7375	1310	10725
389	Mar 28, 2016	13367,5	7250	1270	10600
390	Mar 29, 2016	13397,5	7075	1275	10250
391	Mar 30, 2016	13267,5	7100	1275	10125
392	Mar 31, 2016	13260	7250	1270	10175
393	Apr 01, 2016	13160	7325	1300	10200
394	Apr 04, 2016	13166,5	7400	1290	10225
395	Apr 05, 2016	13219	7275	1275	10250
396	Apr 06, 2016	13222,5	7225	1265	10275
397	Apr 07, 2016	13160	7300	1285	10300
398	Apr 08, 2016	13142,5	7200	1310	10425
399	Apr 11, 2016	13127,5	6975	1335	10425
400	Apr 12, 2016	13113,5	7250	1335	10500
401	Apr 13, 2016	13160	7400	1315	10775
402	Apr 14, 2016	13177,5	7200	1275	10625
403	Apr 15, 2016	13175	7675	1290	10350
404	Apr 18, 2016	13175	7525	1295	10475
405	Apr 19, 2016	13147,5	7600	1315	10325
406	Apr 20, 2016	13141	7575	1285	10425
407	Apr 21, 2016	13157,5	7525	1260	10525
408	Apr 22, 2016	13197,5	7350	1270	10525
409	Apr 25, 2016	13197,5	7350	1335	10550
410	Apr 26, 2016	13200	7200	1285	10325
411	Apr 27, 2016	13194,5	6825	1270	10125
412	Apr 28, 2016	13186,5	6725	1200	10050
413	Apr 29, 2016	13185	6725	1205	9900
414	May 02, 2016	13180	6700	1205	9550
415	May 03, 2016	13194,5	6600	1185	9800

416	May 04, 2016	13241,5	6650	1175	9825
417	May 05, 2016	13241,5	6650	1175	9825
418	May 06, 2016	13241,5	6650	1175	9825
419	May 09, 2016	13290	6400	1135	9275
420	May 10, 2016	13287,5	6525	1145	9400
421	May 11, 2016	13305	6650	1155	9650
422	May 12, 2016	13297,5	6525	1210	9350
423	May 13, 2016	13317,5	6325	1205	9000
424	May 16, 2016	13302,5	6200	1215	9100
425	May 17, 2016	13298,5	6325	1225	9050
426	May 18, 2016	13389	6250	1225	9100
427	May 19, 2016	13555	6250	1210	8850
428	May 20, 2016	13607,5	6350	1175	9000
429	May 23, 2016	13582,5	6375	1170	8825
430	May 24, 2016	13690	6375	1170	8700
431	May 25, 2016	13655	6575	1170	8825
432	May 26, 2016	13603,5	6550	1170	8825
433	May 27, 2016	13583	6700	1195	9100
434	May 30, 2016	13645	6750	1200	9125
435	May 31, 2016	13660	6600	1190	9000
436	Jun 01, 2016	13660	6675	1200	9100
437	Jun 02, 2016	13647,5	6500	1195	9000
438	Jun 03, 2016	13591,5	6600	1195	9025
439	Jun 06, 2016	13377,5	6850	1190	9225
440	Jun 07, 2016	13270	6850	1190	9325
441	Jun 08, 2016	13265	6900	1185	9225
442	Jun 09, 2016	13265	6875	1275	9000
443	Jun 10, 2016	13297,5	6625	1265	8875
444	Jun 13, 2016	13278,5	6575	1225	8850
445	Jun 14, 2016	13365	6700	1190	8800

446	Jun 15, 2016	13372,5	6725	1195	8900
447	Jun 16, 2016	13367,5	6575	1210	8800
448	Jun 17, 2016	13337,5	6600	1190	9050
449	Jun 20, 2016	13265	6750	1220	9125
450	Jun 21, 2016	13262,5	6750	1195	9050
451	Jun 22, 2016	13284	6975	1195	8975
452	Jun 23, 2016	13257,5	6950	1195	8975
453	Jun 24, 2016	13380	6700	1185	8850
454	Jun 27, 2016	13340	6625	1180	8800
455	Jun 28, 2016	13177,5	6975	1125	8825
456	Jun 29, 2016	13161,5	7200	1170	9175
457	Jun 30, 2016	13212,5	7400	1155	9350
458	Jul 01, 2016	13140	7400	1165	9250
459	Jul 04, 2016	13127,5	7400	1165	9250
460	Jul 05, 2016	13127,5	7400	1165	9250
461	Jul 06, 2016	13127,5	7400	1165	9250
462	Jul 07, 2016	13127,5	7400	1165	9250
463	Jul 08, 2016	13127,5	7400	1165	9250
464	Jul 11, 2016	13090	7250	1165	9675
465	Jul 12, 2016	13120	7250	1165	9825
466	Jul 13, 2016	13095	7275	1165	9525
467	Jul 14, 2016	13082,5	7100	1170	9275
468	Jul 15, 2016	13091,5	7100	1170	9050
469	Jul 18, 2016	13087,5	7250	1200	8975
470	Jul 19, 2016	13089	7325	1245	9525
471	Jul 20, 2016	13112,5	7450	1260	9500
472	Jul 21, 2016	13100	7375	1270	9425
473	Jul 22, 2016	13108,5	7350	1265	9300
474	Jul 25, 2016	13140	7500	1255	9400
475	Jul 26, 2016	13167,5	7450	1215	9500

476	Jul 27, 2016	13140	7375	1200	9700
477	Jul 28, 2016	13101	7425	1220	9675
478	Jul 29, 2016	13098,5	7725	1245	9375
479	Aug 01, 2016	13071	8000	1255	10000
480	Aug 02, 2016	13097,5	7975	1265	9900
481	Aug 03, 2016	13125	7950	1455	10175
482	Aug 04, 2016	13137,5	7750	1530	10125
483	Aug 05, 2016	13128,5	7925	1535	10350
484	Aug 08, 2016	13130	8325	1490	10775
485	Aug 09, 2016	13132,5	8125	1450	11600
486	Aug 10, 2016	13113,5	8125	1430	11400
487	Aug 11, 2016	13117	8125	1440	11075
488	Aug 12, 2016	13121	7975	1390	11000
489	Aug 15, 2016	13112,5	7850	1385	10900
490	Aug 16, 2016	13096	7875	1500	11050
491	Aug 17, 2016	13096	7875	1500	11050
492	Aug 18, 2016	13116,5	8300	1530	11225
493	Aug 19, 2016	13157,5	8100	1910	11100
494	Aug 22, 2016	13211,5	8300	1855	11150
495	Aug 23, 2016	13219	8100	2010	10775
496	Aug 24, 2016	13247,5	8200	2070	10400
497	Aug 25, 2016	13241,5	8400	2200	10425
498	Aug 26, 2016	13206	8350	2500	10500
499	Aug 29, 2016	13265	8075	2820	10400
500	Aug 30, 2016	13277,5	8075	2980	10100
501	Aug 31, 2016	13267,5	8150	2980	9900
502	Sep 01, 2016	13268	8025	2810	9800
503	Sep 02, 2016	13247	8100	2720	10000
504	Sep 05, 2016	13152,5	8275	2600	10150
505	Sep 06, 2016	13126,5	8300	2350	10200

506	Sep 07, 2016	13085	8300	2360	10050
507	Sep 08, 2016	13062,5	8300	2600	10050
508	Sep 09, 2016	13099,5	8225	2430	10050
509	Sep 12, 2016	13099,5	8225	2430	10050
510	Sep 13, 2016	13170	7950	2200	9850
511	Sep 14, 2016	13204,5	7725	2050	9700
512	Sep 15, 2016	13175	8150	2270	9950
513	Sep 16, 2016	13157,5	7975	2130	9900
514	Sep 19, 2016	13156	8225	2090	10125
515	Sep 20, 2016	13152,5	8300	2020	10000
516	Sep 21, 2016	13135,5	8550	2310	9825
517	Sep 22, 2016	13090	8775	2500	10100
518	Sep 23, 2016	13076,5	8600	2570	10400
519	Sep 26, 2016	13030	8425	2610	10400
520	Sep 27, 2016	12955	8700	2440	10450
521	Sep 28, 2016	12947,5	8725	2450	10500
522	Sep 29, 2016	12975	8675	2440	10575
523	Sep 30, 2016	13051	8250	2470	10100
524	Oct 03, 2016	12982,5	8475	2660	10400
525	Oct 04, 2016	12981,5	8600	2590	10675
526	Oct 05, 2016	12997,5	8425	2530	10500
527	Oct 06, 2016	12987	8350	2460	10450
528	Oct 07, 2016	12985	8200	2440	10400
529	Oct 10, 2016	12977,5	8275	2530	10300
530	Oct 11, 2016	13012,5	8325	2550	10000
531	Oct 12, 2016	13018,5	8300	2490	10050
532	Oct 13, 2016	13077,5	8200	2510	10075
533	Oct 14, 2016	13044,5	8325	2490	10075
534	Oct 17, 2016	13068,5	8225	2440	9900
535	Oct 18, 2016	13032	8475	2400	10050

536	Oct 19, 2016	13007,5	8375	2330	9975
537	Oct 20, 2016	13007,5	8375	2330	9900
538	Oct 21, 2016	13045	8375	2360	10000
539	Oct 24, 2016	13013	8300	2340	9975
540	Oct 25, 2016	13006	8175	2320	10150
541	Oct 26, 2016	13007,5	8200	2260	10075
542	Oct 27, 2016	13033	8250	2220	10075
543	Oct 28, 2016	13050,5	8175	2140	9975
544	Oct 31, 2016	13048	8225	2170	9850
545	Nov 01, 2016	13041,5	8325	2330	9500
546	Nov 02, 2016	13056	8325	2470	9450
547	Nov 03, 2016	13075	8125	2370	9275
548	Nov 04, 2016	13070	8125	2470	9275
549	Nov 07, 2016	13088	8225	2430	9300
550	Nov 08, 2016	13084	8375	2410	9400
551	Nov 09, 2016	13099	8250	2500	9225
552	Nov 10, 2016	13137,5	8300	2580	9275
553	Nov 11, 2016	13287,5	7700	2510	8850
554	Nov 14, 2016	13357,5	7625	2480	8425
555	Nov 15, 2016	13362,5	7625	2380	8200
556	Nov 16, 2016	13377,5	7825	2340	8450
557	Nov 17, 2016	13372,5	7850	2270	8350
558	Nov 18, 2016	13427,5	7850	2180	8425
559	Nov 21, 2016	13425	7900	2330	8475
560	Nov 22, 2016	13442,5	7750	2890	8425
561	Nov 23, 2016	13482,5	7775	2700	8400
562	Nov 24, 2016	13557,5	7525	2690	8050
563	Nov 25, 2016	13517,5	7625	2590	8200
564	Nov 28, 2016	13530	7825	2600	8675
565	Nov 29, 2016	13572,5	7700	2600	8700

566	Nov 30, 2016	13552,5	7550	2730	8875
567	Dec 01, 2016	13545	7700	2690	9250
568	Dec 02, 2016	13525	7850	2670	9250
569	Dec 05, 2016	13432,5	7875	2600	9225
570	Dec 06, 2016	13382,5	7850	2880	9225
571	Dec 07, 2016	13325	7775	2850	9250
572	Dec 08, 2016	13286,5	7800	2850	9200
573	Dec 09, 2016	13327,5	7825	2770	9300
574	Dec 12, 2016	13327,5	7825	2770	9300
575	Dec 13, 2016	13307,5	7850	2690	9300
576	Dec 14, 2016	13296	7775	2800	9300
577	Dec 15, 2016	13397,5	7750	2780	8975
578	Dec 16, 2016	13390	7575	2780	9175
579	Dec 19, 2016	13384	7625	2820	9100
580	Dec 20, 2016	13427,5	7550	2820	8925
581	Dec 21, 2016	13469	7700	2800	9125
582	Dec 22, 2016	13452,5	7525	2680	8925
583	Dec 23, 2016	13450	7325	2640	9050
584	Dec 26, 2016	13450	7325	2640	9050
585	Dec 27, 2016	13447,5	7625	2700	9075
586	Dec 28, 2016	13442,5	7825	2690	9325
587	Dec 29, 2016	13462,5	8125	2820	9400
588	Dec 30, 2016	13472,5	8275	2750	9175
589	Jan 02, 2017	13472,5	8275	2750	9175
590	Jan 03, 2017	13479,5	8200	2730	9100
591	Jan 04, 2017	13440	8000	2700	9450
592	Jan 05, 2017	13375	8125	2660	9500
593	Jan 06, 2017	13365	8175	2660	9400
594	Jan 09, 2017	13365	8150	2660	9125
595	Jan 10, 2017	13315	8200	2660	9125

596	Jan 11, 2017	13329	8025	2720	8850
597	Jan 12, 2017	13290	7925	2680	8700
598	Jan 13, 2017	13331,5	8000	2430	8775
599	Jan 16, 2017	13366,5	7975	2410	8700
600	Jan 17, 2017	13351,5	8050	2320	8625
601	Jan 18, 2017	13342,5	8125	2270	8750
602	Jan 19, 2017	13373	8150	2410	8725
603	Jan 20, 2017	13410	8000	2370	8625
604	Jan 23, 2017	13360	8025	2280	8600
605	Jan 24, 2017	13331	8050	2200	8700
606	Jan 25, 2017	13360,5	8100	2140	9025
607	Jan 26, 2017	13336	8075	2180	9200
608	Jan 27, 2017	13358,5	8100	2150	9225
609	Jan 30, 2017	13345	7900	2040	9100
610	Jan 31, 2017	13352	7950	2040	9025
611	Feb 01, 2017	13372,5	8050	2090	9025
612	Feb 02, 2017	13352,5	8100	2070	9300
613	Feb 03, 2017	13345	8100	2180	9200
614	Feb 06, 2017	13322,5	8125	2190	9275
615	Feb 07, 2017	13328,5	8125	2180	9150
616	Feb 08, 2017	13325	8050	2090	9250
617	Feb 09, 2017	13302,5	8075	2070	9625
618	Feb 10, 2017	13315,5	8050	2060	9750
619	Feb 13, 2017	13326,5	8100	2060	9825
620	Feb 14, 2017	13330,5	8075	2060	9350
621	Feb 15, 2017	13330,5	8075	2060	9350
622	Feb 16, 2017	13320	8100	2050	9500
623	Feb 17, 2017	13332,5	7900	2000	9275
624	Feb 20, 2017	13354	7950	1920	9200
625	Feb 21, 2017	13372,5	7925	1835	9150

626	Feb 22, 2017	13367	7975	1820	9225
627	Feb 23, 2017	13351	8050	1840	9250
628	Feb 24, 2017	13330,5	8125	1815	9575
629	Feb 27, 2017	13342,5	8025	1785	9525
630	Feb 28, 2017	13336	8200	1750	9625
631	Mar 01, 2017	13362	8325	1845	9400
632	Mar 02, 2017	13358,5	8475	1875	9425
633	Mar 03, 2017	13382,5	8400	2040	9425
634	Mar 06, 2017	13350	8550	1995	9500
635	Mar 07, 2017	13347	8500	1925	9350
636	Mar 08, 2017	13350	8400	1895	9325
637	Mar 09, 2017	13386,5	8250	1900	9250
638	Mar 10, 2017	13379	8150	1870	9425
639	Mar 13, 2017	13356	8250	1820	9400
640	Mar 14, 2017	13371,5	8200	1845	9200
641	Mar 15, 2017	13365	8175	1825	9050
642	Mar 16, 2017	13348,5	8575	1825	9175
643	Mar 17, 2017	13345	8475	1820	9225
644	Mar 20, 2017	13313,5	8500	1860	9350
645	Mar 21, 2017	13319	8475	1885	9150
646	Mar 22, 2017	13329	8400	1860	9225
647	Mar 23, 2017	13324,5	8450	1840	9075
648	Mar 24, 2017	13326,5	8525	1820	8950
649	Mar 27, 2017	13310,5	8525	1800	8775
650	Mar 28, 2017	13310,5	8525	1800	8775
651	Mar 29, 2017	13313,5	8725	1810	9075
652	Mar 30, 2017	13316	8675	1795	8850
653	Mar 31, 2017	13325,5	8625	1795	9000
654	Apr 03, 2017	13322,5	8775	1775	9050
655	Apr 04, 2017	13328	8775	1720	9125

656	Apr 05, 2017	13321	8775	1720	9125
657	Apr 06, 2017	13335,5	8750	1760	9150
658	Apr 07, 2017	13317,5	8575	1700	9175
659	Apr 10, 2017	13286,5	8600	1660	8975
660	Apr 11, 2017	13281,5	8575	1635	8800
661	Apr 12, 2017	13275	8575	2040	8975
662	Apr 13, 2017	13256,5	8500	1980	8875
663	Apr 14, 2017	13256,5	8500	1980	8875
664	Apr 17, 2017	13285,5	8375	2060	8800
665	Apr 18, 2017	13296,5	8375	2310	8750
666	Apr 19, 2017	13296,5	8375	2310	8750
667	Apr 20, 2017	13323,5	8575	2310	8675
668	Apr 21, 2017	13320	9150	2460	8700
669	Apr 24, 2017	13320	9150	2460	8700
670	Apr 25, 2017	13277,5	9025	2490	8975
671	Apr 26, 2017	13285	9025	2450	9000
672	Apr 27, 2017	13314	9000	2480	8825
673	Apr 28, 2017	13329	8950	2450	8825
674	May 01, 2017	13329	8950	2450	8825
675	May 02, 2017	13311,5	9000	2430	8800
676	May 03, 2017	13305,5	8850	2400	8725
677	May 04, 2017	13327,5	8800	2490	8650
678	May 05, 2017	13330	8700	2540	8800
679	May 08, 2017	13309,5	8800	2460	8750
680	May 09, 2017	13350	8700	2450	8750
681	May 10, 2017	13357,5	8600	2450	8650
682	May 11, 2017	13357,5	8600	2450	8650
683	May 12, 2017	13329,5	8675	2420	8850
684	May 15, 2017	13304	8700	2520	8900
685	May 16, 2017	13300,5	8600	2620	9200

686	May 17, 2017	13323,5	8350	2600	9100
687	May 18, 2017	13355,5	8500	2690	9200
688	May 19, 2017	13335	8750	2770	9200
689	May 22, 2017	13302,5	8775	2990	9400
690	May 23, 2017	13302,5	8700	3050	9350
691	May 24, 2017	13308,5	8725	3010	9250
692	May 25, 2017	13308,5	8725	3010	9250
693	May 26, 2017	13294,5	8750	2970	9250
694	May 29, 2017	13321,5	8700	2840	9350
695	May 30, 2017	13323,5	8675	2830	9200
696	May 31, 2017	13322,5	8750	2760	9450
697	Jun 01, 2017	13322,5	8750	2760	9450
698	Jun 02, 2017	13304	9000	2900	9325
699	Jun 05, 2017	13286	9000	2990	9300
700	Jun 06, 2017	13298	8875	2920	9300
701	Jun 07, 2017	13304	8900	2960	9200
702	Jun 08, 2017	13298	8825	2950	9025
703	Jun 09, 2017	13291,5	8650	2880	9375
704	Jun 12, 2017	13298	8725	2870	9650
705	Jun 13, 2017	13291,5	8800	2960	9675
706	Jun 14, 2017	13282,5	9150	2900	9850
707	Jun 15, 2017	13286	8900	2920	10075
708	Jun 16, 2017	13297,5	8725	2900	9850
709	Jun 19, 2017	13289	8725	3000	10150
710	Jun 20, 2017	13288,5	8950	2940	10200
711	Jun 21, 2017	13318,5	8900	2910	10200
712	Jun 22, 2017	13327,5	8925	2890	10000
713	Jun 23, 2017	13327,5	8925	2890	10000
714	Jun 26, 2017	13327,5	8925	2890	10000
715	Jun 27, 2017	13327,5	8925	2890	10000

716	Jun 28, 2017	13327,5	8925	2890	10000
717	Jun 29, 2017	13327,5	8925	2890	10000
718	Jun 30, 2017	13327,5	8925	2890	10000
719	Jul 03, 2017	13367,5	8775	2890	10200
720	Jul 04, 2017	13363,5	8775	2830	10150
721	Jul 05, 2017	13364	8800	2790	9950
722	Jul 06, 2017	13388	8800	2830	10125
723	Jul 07, 2017	13403	8775	2850	10200
724	Jul 10, 2017	13399	8775	2840	10000
725	Jul 11, 2017	13391	8725	2800	10000
726	Jul 12, 2017	13369,5	8725	2900	10025
727	Jul 13, 2017	13347,5	8725	2920	10100
728	Jul 14, 2017	13338,5	8725	3040	10175
729	Jul 17, 2017	13327,5	8725	2980	10100
730	Jul 18, 2017	13309	8675	3040	10300
731	Jul 19, 2017	13318	8475	3170	10175
732	Jul 20, 2017	13334,5	8550	3150	10200
733	Jul 21, 2017	13312,5	8200	3140	10100
734	Jul 24, 2017	13310	8225	3140	10150
735	Jul 25, 2017	13326	8100	3140	10150
736	Jul 26, 2017	13336	8100	3150	10075
737	Jul 27, 2017	13318	8075	3150	10050
738	Jul 28, 2017	13326,5	7950	3230	10050
739	Jul 31, 2017	13325	7975	3200	9950
740	Aug 01, 2017	13324	7850	3190	9925
741	Aug 02, 2017	13324	7825	3030	10700
742	Aug 03, 2017	13325,5	7775	2950	10475
743	Aug 04, 2017	13316	7775	3050	10325
744	Aug 07, 2017	13321	7900	3050	10575
745	Aug 08, 2017	13313	8000	3060	10525

746	Aug 09, 2017	13332,5	8000	3100	10900
747	Aug 10, 2017	13334	7925	3280	10900
748	Aug 11, 2017	13357,5	7775	3230	10675
749	Aug 14, 2017	13349	7850	3200	10975
750	Aug 15, 2017	13361	7825	3180	10900
751	Aug 16, 2017	13378,5	7850	3200	11000
752	Aug 17, 2017	13378,5	7850	3200	11000
753	Aug 18, 2017	13362	7900	3180	10875
754	Aug 21, 2017	13350,5	7875	3200	10850
755	Aug 22, 2017	13343	7925	3160	10850
756	Aug 23, 2017	13358,5	7975	3150	10700
757	Aug 24, 2017	13346,5	7975	3160	10750
758	Aug 25, 2017	13345,5	8000	3270	10575
759	Aug 28, 2017	13340	8000	3200	10525
760	Aug 29, 2017	13339,5	7900	3200	10475
761	Aug 30, 2017	13346,5	7875	3280	10375
762	Aug 31, 2017	13343	7875	3250	10475
763	Sep 01, 2017	13343	7875	3250	10475
764	Sep 04, 2017	13342,5	7750	3220	9975
765	Sep 05, 2017	13337,5	7800	3190	9700
766	Sep 06, 2017	13337,5	7825	3180	9700
767	Sep 07, 2017	13306,5	7650	3160	9825
768	Sep 08, 2017	13204	7825	3120	10300
769	Sep 11, 2017	13162,5	7900	3020	10450
770	Sep 12, 2017	13195	7900	2980	10450
771	Sep 13, 2017	13202,5	7900	2900	10600
772	Sep 14, 2017	13249,5	7900	2980	10500
773	Sep 15, 2017	13240	7850	2960	10375
774	Sep 18, 2017	13255	7850	2930	10000
775	Sep 19, 2017	13278,5	7925	2970	9950

776	Sep 20, 2017	13281,5	7825	2920	10100
777	Sep 21, 2017	13281,5	7825	2920	10100
778	Sep 22, 2017	13312,5	7775	2880	10000
779	Sep 25, 2017	13326	7800	2830	9950
780	Sep 26, 2017	13376,5	7800	2840	9900
781	Sep 27, 2017	13440	7825	2780	9625
782	Sep 28, 2017	13515	7700	2730	9950
783	Sep 29, 2017	13471,5	7900	2740	10125
784	Oct 02, 2017	13537,5	7925	2720	10200
785	Oct 03, 2017	13542,5	8000	2710	10050
786	Oct 04, 2017	13476,5	8000	2710	10300
787	Oct 05, 2017	13457,5	7950	2720	10375
788	Oct 06, 2017	13504	7975	2720	10700
789	Oct 09, 2017	13516,5	7975	2730	10575
790	Oct 10, 2017	13513	7975	2790	10650
791	Oct 11, 2017	13517	8025	2790	10450
792	Oct 12, 2017	13504,5	8200	2760	10750
793	Oct 13, 2017	13499	8475	2790	10850
794	Oct 16, 2017	13482,5	8375	2930	10900
795	Oct 17, 2017	13506,5	8250	2780	10850
796	Oct 18, 2017	13516	8050	2700	10825
797	Oct 19, 2017	13523	7925	2700	10500
798	Oct 20, 2017	13518,5	8000	2700	10425
799	Oct 23, 2017	13542,5	8050	2680	10550
800	Oct 24, 2017	13532,5	8175	2680	10725
801	Oct 25, 2017	13577,5	8150	2680	10875
802	Oct 26, 2017	13581,5	8000	2690	11025
803	Oct 27, 2017	13616,5	7900	2680	10775
804	Oct 30, 2017	13584	8000	2620	10775
805	Oct 31, 2017	13562,5	8000	2770	10900

806	Nov 01, 2017	13580	8075	2720	10500
807	Nov 02, 2017	13551	8150	2680	10425
808	Nov 03, 2017	13497,5	8100	2690	10375
809	Nov 06, 2017	13524,5	8075	2660	10300
810	Nov 07, 2017	13513,5	8200	2640	10325
811	Nov 08, 2017	13517	8300	2650	10500
812	Nov 09, 2017	13515	8275	2640	10100
813	Nov 10, 2017	13532,5	8350	2670	10000
814	Nov 13, 2017	13551,5	8350	2640	10000
815	Nov 14, 2017	13553,5	8300	2620	9900
816	Nov 15, 2017	13535	8175	2560	9850
817	Nov 16, 2017	13542	8250	2550	9950
818	Nov 17, 2017	13527,5	8200	2530	9900
819	Nov 20, 2017	13535	8200	2460	9975
820	Nov 21, 2017	13533,5	8125	2450	9975
821	Nov 22, 2017	13526	8450	2370	9900
822	Nov 23, 2017	13513	8475	2380	10050
823	Nov 24, 2017	13502,5	8550	2370	10150
824	Nov 27, 2017	13518,5	8525	2330	10025
825	Nov 28, 2017	13508,5	8375	2250	10000
826	Nov 29, 2017	13502,5	8350	2260	9900
827	Nov 30, 2017	13526	7975	2270	9400
828	Dec 01, 2017	13526	7975	2270	9400
829	Dec 04, 2017	13526	8100	2250	9600
830	Dec 05, 2017	13519	8200	2150	9350
831	Dec 06, 2017	13539	8350	2270	9375
832	Dec 07, 2017	13553,5	8300	2740	9250
833	Dec 08, 2017	13547,5	8250	2670	9150
834	Dec 11, 2017	13552,5	8400	2520	9375
835	Dec 12, 2017	13568,5	8200	2620	9600

836	Dec 13, 2017	13585	8100	2600	9725
837	Dec 14, 2017	13577,5	8325	2660	9950
838	Dec 15, 2017	13578,5	8300	2650	9850
839	Dec 18, 2017	13581,5	8175	2600	9700
840	Dec 19, 2017	13576,5	8175	2580	9850
841	Dec 20, 2017	13577,5	8000	2560	9550
842	Dec 21, 2017	13557,5	8100	2590	9800
843	Dec 22, 2017	13561	8200	2560	9825
844	Dec 25, 2017	13561	8200	2560	9825
845	Dec 26, 2017	13561	8200	2560	9825
846	Dec 27, 2017	13560,5	8150	2500	10000
847	Dec 28, 2017	13562	8050	2510	10200
848	Dec 29, 2017	13567,5	8300	2700	9900
849	Jan 01, 2018	13567,5	8300	2700	9900
850	Jan 02, 2018	13517,5	8200	2600	10275
851	Jan 03, 2018	13478	8050	2500	10200
852	Jan 04, 2018	13423,5	8225	2510	11000
853	Jan 05, 2018	13415,5	8300	2520	10900
854	Jan 08, 2018	13426,5	8300	2530	11000
855	Jan 09, 2018	13437,5	8175	2520	11200
856	Jan 10, 2018	13436,5	8275	2500	10825
857	Jan 11, 2018	13399,5	8250	2500	10850
858	Jan 12, 2018	13353,5	8175	2470	10575
859	Jan 15, 2018	13334,5	8175	2430	10525
860	Jan 16, 2018	13337,5	8225	2440	10625
861	Jan 17, 2018	13357,5	8200	2490	11400
862	Jan 18, 2018	13346	8300	2500	11075
863	Jan 19, 2018	13313,5	8350	2500	10950
864	Jan 22, 2018	13347,5	8250	2460	10750
865	Jan 23, 2018	13325	8525	2440	10650

866	Jan 24, 2018	13313,5	8725	2450	10725
867	Jan 25, 2018	13288,5	8725	2440	11100
868	Jan 26, 2018	13307	8625	2450	11600
869	Jan 29, 2018	13363,5	8650	2450	11200
870	Jan 30, 2018	13432,5	8425	2460	10900
871	Jan 31, 2018	13388,5	8500	2440	11150
872	Feb 01, 2018	13427	8575	2550	10700
873	Feb 02, 2018	13451,5	8700	2640	10700
874	Feb 05, 2018	13525	8525	2570	10550
875	Feb 06, 2018	13552,5	8425	2440	10175
876	Feb 07, 2018	13553	8450	2440	10175
877	Feb 08, 2018	13605	8375	2440	10300
878	Feb 09, 2018	13627,5	8200	2390	10200
879	Feb 12, 2018	13657,5	8200	2410	10275
880	Feb 13, 2018	13657,5	8275	2420	10525
881	Feb 14, 2018	13628,5	8375	2400	10850
882	Feb 15, 2018	13558,5	8275	2410	11050
883	Feb 16, 2018	13558,5	8275	2410	11050
884	Feb 19, 2018	13560,5	8425	2430	11700
885	Feb 20, 2018	13612,5	8300	2440	11300
886	Feb 21, 2018	13618,5	8175	2460	11575
887	Feb 22, 2018	13682,5	8000	2460	11750
888	Feb 23, 2018	13667,5	8200	2450	11225
889	Feb 26, 2018	13660	8100	2440	11100
890	Feb 27, 2018	13675	8200	2420	11325
891	Feb 28, 2018	13745	8075	2400	11125
892	Mar 01, 2018	13747,5	8075	2400	11050
893	Mar 02, 2018	13757,5	8150	2360	10975
894	Mar 05, 2018	13762,5	8150	2570	10850
895	Mar 06, 2018	13775	8050	2510	10700

896	Mar 07, 2018	13766	7825	2390	10475
897	Mar 08, 2018	13785	7850	2400	10725
898	Mar 09, 2018	13781	7775	2370	10550
899	Mar 12, 2018	13770	7800	2380	10700
900	Mar 13, 2018	13750,5	7700	2310	10525
901	Mar 14, 2018	13736,5	7575	2320	10475
902	Mar 15, 2018	13747,5	7450	2260	10500
903	Mar 16, 2018	13749	7450	2220	10525
904	Mar 19, 2018	13764,5	7275	2150	10475
905	Mar 20, 2018	13750	7300	2100	10450
906	Mar 21, 2018	13762,5	7300	2150	10250
907	Mar 22, 2018	13752,5	7350	2210	10025
908	Mar 23, 2018	13782,5	7275	2130	9650
909	Mar 26, 2018	13740	7225	2120	9850
910	Mar 27, 2018	13742	7300	2170	9900
911	Mar 28, 2018	13763	7100	2210	9875
912	Mar 29, 2018	13765	7300	2190	10350
913	Mar 30, 2018	13765	7300	2190	10350
914	Apr 02, 2018	13754	7550	2200	10625
915	Apr 03, 2018	13764,5	7675	2180	10900
916	Apr 04, 2018	13766,5	7575	2140	10650
917	Apr 05, 2018	13766,5	7600	2160	11000
918	Apr 06, 2018	13773,5	7525	2170	10550
919	Apr 09, 2018	13764,5	7750	2180	10325
920	Apr 10, 2018	13749	7825	2200	10250
921	Apr 11, 2018	13758,5	7950	2230	10250
922	Apr 12, 2018	13769,5	7725	2240	10200
923	Apr 13, 2018	13752,5	7525	2240	10125
924	Apr 16, 2018	13774,5	7600	2200	10025
925	Apr 17, 2018	13766	7625	2180	10000

926	Apr 18, 2018	13774,5	7525	2190	9925
927	Apr 19, 2018	13781	7700	2190	10000
928	Apr 20, 2018	13877,5	7575	2310	10125
929	Apr 23, 2018	13895	7475	2310	10100
930	Apr 24, 2018	13887,5	7325	2260	9900
931	Apr 25, 2018	13920	7150	2160	9675
932	Apr 26, 2018	13887,5	7075	2140	9275
933	Apr 27, 2018	13890	7225	2140	9450
934	Apr 30, 2018	13912,5	7150	2150	9650
935	May 01, 2018	13912,5	7150	2150	9650
936	May 02, 2018	13945	7375	2140	9275
937	May 03, 2018	13937,5	7275	2100	9000
938	May 04, 2018	13940	7250	2080	9000
939	May 07, 2018	14000	7075	2100	9125
940	May 08, 2018	14050	6950	2050	8975
941	May 09, 2018	14080	7100	2100	8950
942	May 10, 2018	14080	7100	2100	8950
943	May 11, 2018	13950	7050	2120	9200
944	May 14, 2018	13970	7025	2100	9000
945	May 15, 2018	14037	6925	2120	8900
946	May 16, 2018	14093	6900	2100	8700
947	May 17, 2018	14052	6725	2030	8700
948	May 18, 2018	14152,5	6525	2040	8700
949	May 21, 2018	14185	6525	2020	8350
950	May 22, 2018	14138	6950	2000	8375
951	May 23, 2018	14207	7000	2010	8300
952	May 24, 2018	14135	7225	2010	8525
953	May 25, 2018	14120	7250	2020	8775
954	May 28, 2018	13990	7175	2030	8750
955	May 29, 2018	13990	7175	2030	8750

956	May 30, 2018	13990	7000	2530	8400
957	May 31, 2018	13895	6900	2540	8400
958	Jun 01, 2018	13895	6900	2540	8400
959	Jun 04, 2018	13872	7000	2610	8675
960	Jun 05, 2018	13879	7000	2700	8800
961	Jun 06, 2018	13852,5	6975	2690	8700
962	Jun 07, 2018	13870	6975	2700	8725
963	Jun 08, 2018	13930	6900	2650	8275
964	Jun 11, 2018	13930	6900	2650	8275
965	Jun 12, 2018	13930	6900	2650	8275
966	Jun 13, 2018	13930	6900	2650	8275
967	Jun 14, 2018	13930	6900	2650	8275
968	Jun 15, 2018	13930	6900	2650	8275
969	Jun 18, 2018	13930	6900	2650	8275
970	Jun 19, 2018	13930	6900	2650	8275
971	Jun 20, 2018	13930	6950	2600	8175
972	Jun 21, 2018	14103	6675	2560	7775
973	Jun 22, 2018	14080	6600	2530	7625
974	Jun 25, 2018	14155	6600	2450	7650
975	Jun 26, 2018	14178	6700	2360	7600
976	Jun 27, 2018	14178	6425	2490	7650
977	Jun 28, 2018	14390	6350	2420	7075
978	Jun 29, 2018	14330	6600	2360	7125
979	Jul 02, 2018	14380	6250	2350	6950
980	Jul 03, 2018	14380	6100	2290	6725
981	Jul 04, 2018	14352	6250	2200	6925
982	Jul 05, 2018	14385	6300	2160	6850
983	Jul 06, 2018	14370	6300	2220	6950
984	Jul 09, 2018	14325	6325	2230	7050
985	Jul 10, 2018	14360	6350	2300	7575

986	Jul 11, 2018	14385	6625	2380	7575
987	Jul 12, 2018	14380	6675	2350	7425
988	Jul 13, 2018	14380	6800	2320	7250
989	Jul 16, 2018	14375	6700	2320	7050
990	Jul 17, 2018	14370	6625	2290	7100
991	Jul 18, 2018	14405	6650	2300	7075
992	Jul 19, 2018	14475	6700	2310	6925
993	Jul 20, 2018	14480	6675	2280	7225
994	Jul 23, 2018	14490	6675	2290	7400
995	Jul 24, 2018	14530	6650	2320	7625
996	Jul 25, 2018	14460	6875	2320	7675
997	Jul 26, 2018	14460	6675	2330	7625
998	Jul 27, 2018	14417,5	6975	2380	7725
999	Jul 30, 2018	14410	7100	2380	7850
1000	Jul 31, 2018	14420	7150	2330	7600
1001	Aug 01, 2018	14440	7475	2340	8625
1002	Aug 02, 2018	14475	7300	2330	8575
1003	Aug 03, 2018	14492,5	7125	2310	8925
1004	Aug 06, 2018	14470	7425	2320	9000
1005	Aug 07, 2018	14440	7375	2390	8950
1006	Aug 08, 2018	14435	7425	2330	8600
1007	Aug 09, 2018	14410	7500	2400	8325
1008	Aug 10, 2018	14475	7400	2410	8400
1009	Aug 13, 2018	14595	7100	2340	8100
1010	Aug 14, 2018	14580	6825	2330	7600
1011	Aug 15, 2018	14600	6975	2340	8000
1012	Aug 16, 2018	14610	7100	2310	8150
1013	Aug 17, 2018	14610	7100	2310	8150
1014	Aug 20, 2018	14590	7400	2340	8450
1015	Aug 21, 2018	14580	7475	2410	8625

1016	Aug 22, 2018	14580	7475	2410	8625
1017	Aug 23, 2018	14630	7425	2420	9075
1018	Aug 24, 2018	14642	7375	2410	8750
1019	Aug 27, 2018	14620	7575	2420	9400
1020	Aug 28, 2018	14622	7350	2410	9200
1021	Aug 29, 2018	14655	7475	2420	9200
1022	Aug 30, 2018	14690	7475	2380	9250
1023	Aug 31, 2018	14730	7250	2360	9450
1024	Sep 03, 2018	14815	7100	2330	9275
1025	Sep 04, 2018	14935	7075	2300	9275
1026	Sep 05, 2018	14935	6775	2140	8850
1027	Sep 06, 2018	14890	6800	2250	8875
1028	Sep 07, 2018	14820	7175	2250	8975
1029	Sep 10, 2018	14857	7175	2210	8775
1030	Sep 11, 2018	14857	7175	2210	8775
1031	Sep 12, 2018	14825	7125	2210	8700
1032	Sep 13, 2018	14840	7075	2280	9000
1033	Sep 14, 2018	14805	7225	2360	9000
1034	Sep 17, 2018	14877,5	6950	2340	8800
1035	Sep 18, 2018	14855	7025	2320	8525
1036	Sep 19, 2018	14875	7400	2360	9000
1037	Sep 20, 2018	14845	7500	2360	9075
1038	Sep 21, 2018	14819	7250	2390	9300
1039	Sep 24, 2018	14867,5	7125	2440	9125
1040	Sep 25, 2018	14920	7200	2600	9025
1041	Sep 26, 2018	14905	7350	2500	9150
1042	Sep 27, 2018	14917	7375	2460	9425
1043	Sep 28, 2018	14901,5	7350	2550	9925
1044	Oct 01, 2018	14910	7325	2460	9600
1045	Oct 02, 2018	15045	7200	2380	9025

1046	Oct 03, 2018	15075	7200	2400	9150
1047	Oct 04, 2018	15170	7075	2350	8850
1048	Oct 05, 2018	15180	6950	2350	8925
1049	Oct 08, 2018	15217,5	6850	2330	9300
1050	Oct 09, 2018	15230	7025	2340	9300
1051	Oct 10, 2018	15203	6950	2420	9125
1052	Oct 11, 2018	15235	6725	2490	8900
1053	Oct 12, 2018	15205	6850	2500	8900
1054	Oct 15, 2018	15210	6850	2480	8825
1055	Oct 16, 2018	15200	6975	2500	8975
1056	Oct 17, 2018	15155	7025	2510	9000
1057	Oct 18, 2018	15193,5	7025	2510	9000
1058	Oct 19, 2018	15187,5	7300	2470	8925
1059	Oct 22, 2018	15185	7275	2450	9000
1060	Oct 23, 2018	15190	7350	2450	9100
1061	Oct 24, 2018	15197	7300	2460	9100
1062	Oct 25, 2018	15187,5	7375	2480	8950
1063	Oct 26, 2018	15216,5	7425	2480	8925
1064	Oct 29, 2018	15220	7500	2530	8600
1065	Oct 30, 2018	15223	7700	2500	8650
1066	Oct 31, 2018	15202,5	7900	2450	9000
1067	Nov 01, 2018	15127,5	8050	2470	9250
1068	Nov 02, 2018	14952,5	8175	2560	9725
1069	Nov 05, 2018	14976	8250	2550	9700
1070	Nov 06, 2018	14802,5	8100	2550	9750
1071	Nov 07, 2018	14580	8225	2580	9725
1072	Nov 08, 2018	14540	8200	2620	9825
1073	Nov 09, 2018	14685	8175	2580	9725
1074	Nov 12, 2018	14815	7875	2550	9150
1075	Nov 13, 2018	14810	8000	2530	9150

1076	Nov 14, 2018	14787	8175	2560	10000
1077	Nov 15, 2018	14677,5	8525	2560	10300
1078	Nov 16, 2018	14611,5	8550	2530	11000
1079	Nov 19, 2018	14590	8500	2570	11100
1080	Nov 20, 2018	14590	8500	2570	11100
1081	Nov 21, 2018	14605	8450	2600	11150
1082	Nov 22, 2018	14577,5	8450	2580	11875
1083	Nov 23, 2018	14540	8400	2610	11525
1084	Nov 26, 2018	14475	8325	2590	11650
1085	Nov 27, 2018	14513,5	8400	2560	11250
1086	Nov 28, 2018	14527,5	8400	2540	11175
1087	Nov 29, 2018	14382,5	8475	2550	12000
1088	Nov 30, 2018	14302,5	8550	2500	12025
1089	Dec 03, 2018	14240	8600	2500	11600
1090	Dec 04, 2018	14290	8525	2500	11775
1091	Dec 05, 2018	14395	8325	2480	11775
1092	Dec 06, 2018	14520	8100	2480	11875
1093	Dec 07, 2018	14470	8225	2490	11875
1094	Dec 10, 2018	14555	8150	2480	11950
1095	Dec 11, 2018	14600	8150	2480	11600
1096	Dec 12, 2018	14597,5	8250	2550	11600
1097	Dec 13, 2018	14497,5	8450	2850	11600
1098	Dec 14, 2018	14585	8450	2730	11425
1099	Dec 17, 2018	14575	8300	2740	11400
1100	Dec 18, 2018	14500	8375	2670	11375
1101	Dec 19, 2018	14442,5	8425	2680	11500
1102	Dec 20, 2018	14470	8475	2670	11475
1103	Dec 21, 2018	14555	8425	2670	11500
1104	Dec 24, 2018	14555	8425	2670	11500
1105	Dec 25, 2018	14555	8425	2670	11500

1106	Dec 26, 2018	14575	8125	2700	11550
1107	Dec 27, 2018	14560	8225	2680	11675
1108	Dec 28, 2018	14560	8225	2600	11500
1109	Dec 31, 2018	14380	8225	2600	11500
1110	Jan 01, 2019	14380	8225	2600	11500
1111	Jan 02, 2019	14450	8200	2520	11475
1112	Jan 03, 2019	14410	8375	2490	11525
1113	Jan 04, 2019	14270	8350	2510	11500
1114	Jan 07, 2019	14090	8150	2500	11400
1115	Jan 08, 2019	14145	8175	2470	11300
1116	Jan 09, 2019	14125	8200	2590	11200
1117	Jan 10, 2019	14055	8200	2570	11925
1118	Jan 11, 2019	14045	8300	2570	11575
1119	Jan 14, 2019	14124	8150	2540	11575
1120	Jan 15, 2019	14092,5	8150	2590	11800
1121	Jan 16, 2019	14122,5	8250	2580	11925
1122	Jan 17, 2019	14180	8275	2620	12425
1123	Jan 18, 2019	14175	8475	2590	12700
1124	Jan 21, 2019	14222,5	8325	2580	12975
1125	Jan 22, 2019	14215	8200	2570	13075
1126	Jan 23, 2019	14180	8175	2570	12975
1127	Jan 24, 2019	14165	8425	2700	13200
1128	Jan 25, 2019	14085	8425	3100	13200
1129	Jan 28, 2019	14070	8375	3240	13075
1130	Jan 29, 2019	14095	8375	3400	12875
1131	Jan 30, 2019	14130	8350	3280	12550
1132	Jan 31, 2019	13972,5	8450	2950	12675
1133	Feb 01, 2019	13940	8450	2750	12725
1134	Feb 04, 2019	13955	8200	2810	12250
1135	Feb 05, 2019	13955	8200	2810	12250

1136	Feb 06, 2019	13922	8225	3200	12900
1137	Feb 07, 2019	13972,5	8200	3030	12800
1138	Feb 08, 2019	13965	8150	2990	12500
1139	Feb 11, 2019	14040	8000	2950	12475
1140	Feb 12, 2019	14068,5	7650	2940	12300
1141	Feb 13, 2019	14057,5	7675	2940	12675
1142	Feb 14, 2019	14090	7600	2880	12400
1143	Feb 15, 2019	14142,5	7600	3020	12025
1144	Feb 18, 2019	14106,5	7875	3100	12500
1145	Feb 19, 2019	14102	7775	3370	12475
1146	Feb 20, 2019	14040	7775	3390	12900
1147	Feb 21, 2019	14063	7700	3360	12925
1148	Feb 22, 2019	14057,5	7625	3310	12575
1149	Feb 25, 2019	14017,5	7650	3350	12950
1150	Feb 26, 2019	13991	7600	3290	12925
1151	Feb 27, 2019	14030	7600	3230	12600
1152	Feb 28, 2019	14065	7150	3190	12650
1153	Mar 01, 2019	14115	7225	3160	12875
1154	Mar 04, 2019	14130	7150	3180	12900
1155	Mar 05, 2019	14120	7300	3150	12850
1156	Mar 06, 2019	14140	7325	3130	12700
1157	Mar 07, 2019	14140	7325	3130	12700
1158	Mar 08, 2019	14310	7150	3100	12475
1159	Mar 11, 2019	14290	7175	3060	12525
1160	Mar 12, 2019	14265	7175	2980	12375
1161	Mar 13, 2019	14265	7100	2970	12700
1162	Mar 14, 2019	14267	7275	2960	13000
1163	Mar 15, 2019	14259	7225	2930	13075
1164	Mar 18, 2019	14237,5	7400	3100	13300
1165	Mar 19, 2019	14230	7300	3050	13100

1166	Mar 20, 2019	14185	7250	3100	13025
1167	Mar 21, 2019	14140	7250	3250	13700
1168	Mar 22, 2019	14165	7250	3360	13675
1169	Mar 25, 2019	14180	7050	3250	13400
1170	Mar 26, 2019	14170	7150	3170	13875
1171	Mar 27, 2019	14195	7100	3280	13775
1172	Mar 28, 2019	14242	7125	3260	13900
1173	Mar 29, 2019	14240	7325	3560	13950
1174	Apr 01, 2019	14225	7275	3800	13800
1175	Apr 02, 2019	14220	7450	3660	13600
1176	Apr 03, 2019	14220	7450	3660	13600
1177	Apr 04, 2019	14180	7575	3660	13850
1178	Apr 05, 2019	14125	7600	3700	13650
1179	Apr 08, 2019	14163	7550	3590	13575
1180	Apr 09, 2019	14133	7700	3590	13950
1181	Apr 10, 2019	14150	7675	3230	14300
1182	Apr 11, 2019	14135	7550	3610	13650
1183	Apr 12, 2019	14092,5	7475	3580	13000
1184	Apr 15, 2019	14060	7600	3560	12825
1185	Apr 16, 2019	14085	7750	3300	13325
1186	Apr 17, 2019	14085	7750	3300	13325
1187	Apr 18, 2019	14042,5	7850	3200	13725
1188	Apr 19, 2019	14042,5	7850	3200	13725
1189	Apr 22, 2019	14075	7525	3100	13175
1190	Apr 23, 2019	14075	7650	3060	13725
1191	Apr 24, 2019	14095	7650	3050	13450
1192	Apr 25, 2019	14185	7550	3000	13350
1193	Apr 26, 2019	14187,5	7650	2990	13700
1194	Apr 29, 2019	14200	7600	3000	13525
1195	Apr 30, 2019	14250	7625	3000	13500

1196	May 01, 2019	14250	7625	3000	13500
1197	May 02, 2019	14250	7475	3010	12900
1198	May 03, 2019	14255	7425	3000	12250
1199	May 06, 2019	14292,5	7425	2900	11150
1200	May 07, 2019	14280	7525	3100	11900
1201	May 08, 2019	14295	7400	3300	11325
1202	May 09, 2019	14350	7150	3160	10900
1203	May 10, 2019	14325	7175	3370	11150
1204	May 13, 2019	14415	7025	3290	10475
1205	May 14, 2019	14430	7000	3210	10675
1206	May 15, 2019	14460	6950	3180	10550
1207	May 16, 2019	14450	6775	3190	10700
1208	May 17, 2019	14450	6700	3190	10550
1209	May 20, 2019	14455	6900	3190	11250
1210	May 21, 2019	14480	7000	3180	10825
1211	May 22, 2019	14525	7000	3420	10825
1212	May 23, 2019	14460	7100	3340	10900
1213	May 24, 2019	14392,5	7175	3280	10800
1214	May 27, 2019	14380	7125	3330	11375
1215	May 28, 2019	14375	7075	3390	11050
1216	May 29, 2019	14400	7200	3390	11200
1217	May 30, 2019	14400	7200	3390	11200
1218	May 31, 2019	14275	7450	3390	11550
1219	Jun 03, 2019	14275	7450	3390	11550
1220	Jun 04, 2019	14275	7450	3390	11550
1221	Jun 05, 2019	14275	7450	3390	11550
1222	Jun 06, 2019	14275	7450	3390	11550
1223	Jun 07, 2019	14275	7450	3390	11550
1224	Jun 10, 2019	14250	7675	3370	12175
1225	Jun 11, 2019	14237,5	7625	3400	11975

1226	Jun 12, 2019	14235	7500	3400	11600
1227	Jun 13, 2019	14280	7500	3420	11475
1228	Jun 14, 2019	14325	7425	3400	11450
1229	Jun 17, 2019	14335	7375	3370	11600
1230	Jun 18, 2019	14322,5	7500	3350	11450
1231	Jun 19, 2019	14269,5	7650	3360	11600
1232	Jun 20, 2019	14182,5	7600	3370	11425
1233	Jun 21, 2019	14155	7450	3350	11375
1234	Jun 24, 2019	14140	7350	3350	11300
1235	Jun 25, 2019	14125	7350	3380	11450
1236	Jun 26, 2019	14175	7250	3370	11450
1237	Jun 27, 2019	14140	7375	3360	11625
1238	Jun 28, 2019	14127,5	7450	3360	11575
1239	Jul 01, 2019	14112,5	7375	3300	12475
1240	Jul 02, 2019	14137,5	7300	3300	12700
1241	Jul 03, 2019	14117,5	7275	3340	12700
1242	Jul 04, 2019	14140	7250	3300	12575
1243	Jul 05, 2019	14082,5	7150	3330	12600
1244	Jul 08, 2019	14110	7300	3300	12225
1245	Jul 09, 2019	14130	7275	3320	12425
1246	Jul 10, 2019	14130	7450	3320	12550
1247	Jul 11, 2019	14065	7525	3290	12425
1248	Jul 12, 2019	14007	7450	3280	12400
1249	Jul 15, 2019	13919,5	7425	3280	12500
1250	Jul 16, 2019	13935	7450	3280	12350
1251	Jul 17, 2019	13980	7100	3270	12500
1252	Jul 18, 2019	13960	7150	3250	12550
1253	Jul 19, 2019	13935	7100	3250	12575
1254	Jul 22, 2019	13945	7100	3230	12450
1255	Jul 23, 2019	13984	7150	3390	12525

1256	Jul 24, 2019	13993	7175	3310	12600
1257	Jul 25, 2019	13977,5	7300	3280	12475
1258	Jul 26, 2019	14004	7075	3220	12400
1259	Jul 29, 2019	14020	7175	3210	12550
1260	Jul 30, 2019	14020	7275	3210	12650
1261	Jul 31, 2019	14017	7000	3200	12875
1262	Aug 01, 2019	14116	7025	3140	13050
1263	Aug 02, 2019	14180	7075	3200	12950
1264	Aug 05, 2019	14255	6925	3200	12400
1265	Aug 06, 2019	14265	6750	3100	12575
1266	Aug 07, 2019	14222,5	6725	3140	12725
1267	Aug 08, 2019	14208	6900	3150	12900
1268	Aug 09, 2019	14190	6775	3140	12800
1269	Aug 12, 2019	14247,5	6750	3120	12800
1270	Aug 13, 2019	14317,5	6675	3080	12400
1271	Aug 14, 2019	14245	6675	3100	12850
1272	Aug 15, 2019	14267,5	6525	3060	12950
1273	Aug 16, 2019	14235	6500	3400	12900
1274	Aug 19, 2019	14235	6425	3360	13250
1275	Aug 20, 2019	14260	6425	3260	13225
1276	Aug 21, 2019	14240	6350	3240	12975
1277	Aug 22, 2019	14235	6325	3150	13025
1278	Aug 23, 2019	14212,5	6575	3210	13075
1279	Aug 26, 2019	14240	6575	3070	12875
1280	Aug 27, 2019	14255	6525	3080	12900
1281	Aug 28, 2019	14255	6450	3090	12950
1282	Aug 29, 2019	14237,5	6425	3060	13100
1283	Aug 30, 2019	14185	6675	3060	13250
1284	Sep 02, 2019	14194	6550	2990	13275
1285	Sep 03, 2019	14225	6475	2930	13300

1286	Sep 04, 2019	14152,5	6500	2870	13350
1287	Sep 05, 2019	14150	6700	2890	13425
1288	Sep 06, 2019	14095	6750	2910	13450
1289	Sep 09, 2019	14031	6650	3030	13425
1290	Sep 10, 2019	14050	6675	2960	12850
1291	Sep 11, 2019	14060	6925	3020	12175
1292	Sep 12, 2019	13990	6750	2990	12475
1293	Sep 13, 2019	13965	6750	2980	12800
1294	Sep 16, 2019	14040	6700	2900	12900
1295	Sep 17, 2019	14095	6475	2990	12725
1296	Sep 18, 2019	14060	6700	2980	12825
1297	Sep 19, 2019	14060	6600	2950	12450
1298	Sep 20, 2019	14055	6575	2960	12850
1299	Sep 23, 2019	14085	6625	2940	12500
1300	Sep 24, 2019	14112,5	6475	2940	12275
1301	Sep 25, 2019	14150	6500	2910	12225
1302	Sep 26, 2019	14177,5	6700	2930	12250
1303	Sep 27, 2019	14165	6650	2920	11850
1304	Sep 30, 2019	14195	6600	2900	11550

LAMPIRAN B

Hasil Peramalan Model Terbaik Univariat dan Multivariat

Aktual		Prediksi		
Date	No.	<i>Predictor</i>	Univariat	Multivariat
		<i>Timestep</i>	5	2
		<i>Hidden</i>	50	30
		<i>Droupout</i>	0.1	0.3
		<i>Optimizer</i>	RMSprop	RMSprop
		<i>Epoch</i>	150	200
		<i>Batch Size</i>	32	32
		<i>MAPE</i>	1,3465	1,3512
		<i>Time</i>	38,956	33,5328
		<i>Loss</i>	0,0016	0,0019
Mar 30, 2018	913	7300	7287,34	7272,5
Apr 02, 2018	914	7550	7284,49	7292,33
Apr 03, 2018	915	7675	7521,05	7517,87
Apr 04, 2018	916	7575	7638,03	7651,9
Apr 05, 2018	917	7600	7551,19	7572,34
Apr 06, 2018	918	7525	7587,14	7586,82
Apr 09, 2018	919	7750	7517,53	7520,46
Apr 10, 2018	920	7825	7734,76	7719,91
Apr 11, 2018	921	7950	7795,26	7807,53
Apr 12, 2018	922	7725	7921,21	7925,94
Apr 13, 2018	923	7525	7702,02	7728,59
Apr 16, 2018	924	7600	7534,24	7533,08
Apr 17, 2018	925	7625	7606,03	7580,59
Apr 18, 2018	926	7525	7617,2	7612,35
Apr 19, 2018	927	7700	7517,51	7522,42
Apr 20, 2018	928	7575	7685,95	7672,92

Apr 23, 2018	929	7475	7559,16	7565,06
Apr 24, 2018	930	7325	7474,38	7471,3
Apr 25, 2018	931	7150	7333,55	7329,99
Apr 26, 2018	932	7075	7170,52	7156,39
Apr 27, 2018	933	7225	7092,34	7079,25
Apr 30, 2018	934	7150	7217,73	7202,34
May 01, 2018	935	7150	7144,66	7148,05
May 02, 2018	936	7375	7144,32	7142,79
May 03, 2018	937	7275	7350,2	7341,69
May 04, 2018	938	7250	7260,53	7275,78
May 07, 2018	939	7075	7243,32	7243,43
May 08, 2018	940	6950	7084,57	7079,17
May 09, 2018	941	7100	6969,58	6951,81
May 10, 2018	942	7100	7093,52	7074,58
May 11, 2018	943	7050	7091,19	7091,58
May 14, 2018	944	7025	7046,03	7059,63
May 15, 2018	945	6925	7023,11	7019,57
May 16, 2018	946	6900	6933,42	6923,64
May 17, 2018	947	6725	6905,95	6891,68
May 18, 2018	948	6525	6747,08	6744,07
May 21, 2018	949	6525	6562,34	6537,83
May 22, 2018	950	6950	6542,21	6521,27
May 23, 2018	951	7000	6904,29	6902,8
May 24, 2018	952	7225	6970,25	6980,53
May 25, 2018	953	7250	7183,36	7200,55
May 28, 2018	954	7175	7220,5	7238,92
May 29, 2018	955	7175	7164,8	7184,92
May 30, 2018	956	7000	7168,96	7166,69
May 31, 2018	957	6900	7011,86	7010,92
Jun 01, 2018	958	6900	6917,14	6915,03

Jun 04, 2018	959	7000	6907,28	6896,76
Jun 05, 2018	960	7000	6990,66	6986,91
Jun 06, 2018	961	6975	6990,8	6994,75
Jun 07, 2018	962	6975	6969,96	6975,88
Jun 08, 2018	963	6900	6970,67	6969,41
Jun 11, 2018	964	6900	6904,48	6899,04
Jun 12, 2018	965	6900	6900,96	6896,24
Jun 13, 2018	966	6900	6898,61	6896,24
Jun 14, 2018	967	6900	6897,38	6896,24
Jun 15, 2018	968	6900	6896,47	6896,24
Jun 18, 2018	969	6900	6896,47	6896,24
Jun 19, 2018	970	6900	6896,47	6896,24
Jun 20, 2018	971	6950	6896,47	6896,24
Jun 21, 2018	972	6675	6940,87	6940,24
Jun 22, 2018	973	6600	6701,41	6686,56
Jun 25, 2018	974	6600	6623,06	6609,37
Jun 26, 2018	975	6700	6611,46	6591,83
Jun 27, 2018	976	6425	6692,25	6683,28
Jun 28, 2018	977	6350	6459,57	6456,2
Jun 29, 2018	978	6600	6376,58	6339,29
Jul 02, 2018	979	6250	6576,37	6573,28
Jul 03, 2018	980	6100	6297,96	6284,66
Jul 04, 2018	981	6250	6144,77	6122,25
Jul 05, 2018	982	6300	6245,41	6237,02
Jul 06, 2018	983	6300	6297,53	6291,61
Jul 09, 2018	984	6325	6301,26	6301,33
Jul 10, 2018	985	6350	6323,82	6326,37
Jul 11, 2018	986	6625	6349,32	6343,58
Jul 12, 2018	987	6675	6585,92	6587,75
Jul 13, 2018	988	6800	6654,02	6663,22

Jul 16, 2018	989	6700	6773,46	6779,01
Jul 17, 2018	990	6625	6699,94	6702,75
Jul 18, 2018	991	6650	6635,68	6626,67
Jul 19, 2018	992	6700	6652,05	6637,29
Jul 20, 2018	993	6675	6695,09	6680,15
Jul 23, 2018	994	6675	6675,18	6668,24
Jul 24, 2018	995	6650	6674,29	6665,24
Jul 25, 2018	996	6875	6653,08	6639,75
Jul 26, 2018	997	6675	6847,96	6849,28
Jul 27, 2018	998	6975	6685,94	6685,59
Jul 30, 2018	999	7100	6942,97	6939,79
Jul 31, 2018	1000	7150	7069,06	7078,14
Aug 01, 2018	1001	7475	7125,88	7132,91
Aug 02, 2018	1002	7300	7431,84	7435,61
Aug 03, 2018	1003	7125	7278,99	7296,74
Aug 06, 2018	1004	7425	7132,03	7124,86
Aug 07, 2018	1005	7375	7406,84	7391,19
Aug 08, 2018	1006	7425	7357,6	7368,69
Aug 09, 2018	1007	7500	7408,6	7408,96
Aug 10, 2018	1008	7400	7479,75	7484,15
Aug 13, 2018	1009	7100	7390,2	7387,98
Aug 14, 2018	1010	6825	7118,51	7098,36
Aug 15, 2018	1011	6975	6868,3	6838,43
Aug 16, 2018	1012	7100	6982,3	6947,46
Aug 17, 2018	1013	7100	7086,26	7075,59
Aug 20, 2018	1014	7400	7085,86	7086,72
Aug 21, 2018	1015	7475	7362,88	7366,3
Aug 22, 2018	1016	7475	7440,08	7457,62
Aug 23, 2018	1017	7425	7450,51	7461,74
Aug 24, 2018	1018	7375	7411,67	7410,04

Aug 27, 2018	1019	7575	7371,15	7363,67
Aug 28, 2018	1020	7350	7558,45	7551,09
Aug 29, 2018	1021	7475	7342,06	7351,22
Aug 30, 2018	1022	7475	7467,15	7450,13
Aug 31, 2018	1023	7250	7460,99	7458,13
Sep 03, 2018	1024	7100	7255,21	7247,2
Sep 04, 2018	1025	7075	7118,07	7087,98
Sep 05, 2018	1026	6775	7087,58	7049,84
Sep 06, 2018	1027	6800	6810,92	6782,97
Sep 07, 2018	1028	7175	6814,57	6787,14
Sep 10, 2018	1029	7175	7140,52	7138,1
Sep 11, 2018	1030	7175	7149,74	7156,63
Sep 12, 2018	1031	7125	7156,71	7160,18
Sep 13, 2018	1032	7075	7117,92	7116,92
Sep 14, 2018	1033	7225	7076,42	7062,38
Sep 17, 2018	1034	6950	7210,05	7203,05
Sep 18, 2018	1035	7025	6962,4	6948,21
Sep 19, 2018	1036	7400	7025,19	7006,37
Sep 20, 2018	1037	7500	7364,21	7358,85
Sep 21, 2018	1038	7250	7461,93	7483,53
Sep 24, 2018	1039	7125	7238,91	7254,13
Sep 25, 2018	1040	7200	7135,91	7114,08
Sep 26, 2018	1041	7350	7201,28	7174,76
Sep 27, 2018	1042	7375	7333,42	7327,46
Sep 28, 2018	1043	7350	7354,21	7358,06
Oct 01, 2018	1044	7325	7335,43	7338,74
Oct 02, 2018	1045	7200	7316,83	7311,25
Oct 03, 2018	1046	7200	7203,56	7178,9
Oct 04, 2018	1047	7075	7201,78	7181,46
Oct 05, 2018	1048	6950	7083,42	7056,82

Oct 08, 2018	1049	6850	6966,1	6940,15
Oct 09, 2018	1050	7025	6867,89	6835,53
Oct 10, 2018	1051	6950	7013,82	6994,8
Oct 11, 2018	1052	6725	6947,46	6940,29
Oct 12, 2018	1053	6850	6747,96	6719,94
Oct 15, 2018	1054	6850	6845,82	6825,97
Oct 16, 2018	1055	6975	6847,57	6831,75
Oct 17, 2018	1056	7025	6957,16	6950,03
Oct 18, 2018	1057	7025	7006,76	7009,2
Oct 19, 2018	1058	7300	7013,45	7004,22
Oct 22, 2018	1059	7275	7266,5	7268,96
Oct 23, 2018	1060	7350	7251,52	7261,37
Oct 24, 2018	1061	7300	7329,18	7330,74
Oct 25, 2018	1062	7375	7287,37	7286,92
Oct 26, 2018	1063	7425	7362,27	7357,51
Oct 29, 2018	1064	7500	7408,12	7405,57
Oct 30, 2018	1065	7700	7480,57	7482,9
Oct 31, 2018	1066	7900	7671,3	7680,47
Nov 01, 2018	1067	8050	7862,97	7886,77
Nov 02, 2018	1068	8175	8009,68	8046,09
Nov 05, 2018	1069	8250	8136,74	8182,05
Nov 06, 2018	1070	8100	8215,12	8238,02
Nov 07, 2018	1071	8225	8070,53	8112,27
Nov 08, 2018	1072	8200	8219,22	8232,2
Nov 09, 2018	1073	8175	8176,47	8193,04
Nov 12, 2018	1074	7875	8160,03	8149,78
Nov 13, 2018	1075	8000	7864,15	7860,71
Nov 14, 2018	1076	8175	8011,66	7984,98
Nov 15, 2018	1077	8525	8159,55	8161,84
Nov 16, 2018	1078	8550	8499,06	8518,96

Nov 19, 2018	1079	8500	8490,3	8545,44
Nov 20, 2018	1080	8500	8463,8	8491,62
Nov 21, 2018	1081	8450	8481,28	8488,55
Nov 22, 2018	1082	8450	8432,86	8438,05
Nov 23, 2018	1083	8400	8439,52	8441,37
Nov 26, 2018	1084	8325	8383,76	8393,2
Nov 27, 2018	1085	8400	8313,18	8321,44
Nov 28, 2018	1086	8400	8394,57	8381,88
Nov 29, 2018	1087	8475	8379,28	8386,54
Nov 30, 2018	1088	8550	8459,07	8474,48
Dec 03, 2018	1089	8600	8526,18	8541,68
Dec 04, 2018	1090	8525	8573,97	8589,59
Dec 05, 2018	1091	8325	8495,63	8506,91
Dec 06, 2018	1092	8100	8308,21	8306,72
Dec 07, 2018	1093	8225	8104,35	8082,94
Dec 10, 2018	1094	8150	8240,26	8212,95
Dec 11, 2018	1095	8150	8133,58	8131,99
Dec 12, 2018	1096	8250	8141,29	8133,8
Dec 13, 2018	1097	8450	8235,55	8235,65
Dec 14, 2018	1098	8450	8428,99	8442,67
Dec 17, 2018	1099	8300	8409,65	8429,3
Dec 18, 2018	1100	8375	8272,03	8293,18
Dec 19, 2018	1101	8425	8371,79	8368,46
Dec 20, 2018	1102	8475	8407,19	8416,78
Dec 21, 2018	1103	8425	8454,58	8458,28
Dec 24, 2018	1104	8425	8398,63	8405,36
Dec 25, 2018	1105	8425	8411,01	8413,25
Dec 26, 2018	1106	8125	8409,17	8413,25
Dec 27, 2018	1107	8225	8105,94	8120,28
Dec 28, 2018	1108	8225	8239,29	8211,36

Dec 31, 2018	1109	8225	8210,22	8213,26
Jan 01, 2019	1110	8225	8211,1	8230,25
Jan 02, 2019	1111	8200	8207,65	8211,94
Jan 03, 2019	1112	8375	8184,24	8181,23
Jan 04, 2019	1113	8350	8363,73	8360,25
Jan 07, 2019	1114	8150	8316,79	8350,92
Jan 08, 2019	1115	8175	8129,14	8162,43
Jan 09, 2019	1116	8200	8176,72	8154,03
Jan 10, 2019	1117	8200	8189,71	8186,18
Jan 11, 2019	1118	8300	8184,7	8191,84
Jan 14, 2019	1119	8150	8283,9	8280,73
Jan 15, 2019	1120	8150	8123,19	8134,83
Jan 16, 2019	1121	8250	8145,44	8138,51
Jan 17, 2019	1122	8275	8238,61	8227,56
Jan 18, 2019	1123	8475	8252,49	8253,69
Jan 21, 2019	1124	8325	8456,66	8452,77
Jan 22, 2019	1125	8200	8282,35	8310,95
Jan 23, 2019	1126	8175	8190,5	8191,88
Jan 24, 2019	1127	8425	8173,14	8165,41
Jan 25, 2019	1128	8425	8422,18	8401,16
Jan 28, 2019	1129	8375	8386,45	8416,95
Jan 29, 2019	1130	8375	8349,29	8362,58
Jan 30, 2019	1131	8350	8359,3	8356,86
Jan 31, 2019	1132	8450	8334,85	8332,23
Feb 01, 2019	1133	8450	8439,28	8444,26
Feb 04, 2019	1134	8200	8423,76	8435,78
Feb 05, 2019	1135	8200	8176,64	8194,8
Feb 06, 2019	1136	8225	8207,32	8184,5
Feb 07, 2019	1137	8200	8218,28	8211,02
Feb 08, 2019	1138	8150	8186,19	8181,01

Feb 11, 2019	1139	8000	8135,92	8138,24
Feb 12, 2019	1140	7650	7990,87	7987,19
Feb 13, 2019	1141	7675	7660,63	7658,51
Feb 14, 2019	1142	7600	7696,2	7661,65
Feb 15, 2019	1143	7600	7603,86	7590,32
Feb 18, 2019	1144	7875	7598,8	7582,79
Feb 19, 2019	1145	7775	7855,13	7846,26
Feb 20, 2019	1146	7775	7744,83	7768,95
Feb 21, 2019	1147	7700	7760,83	7767,76
Feb 22, 2019	1148	7625	7689,43	7690,48
Feb 25, 2019	1149	7650	7623,48	7618,76
Feb 26, 2019	1150	7600	7645,5	7639,46
Feb 27, 2019	1151	7600	7592,54	7594,33
Feb 28, 2019	1152	7150	7592,7	7584,4
Mar 01, 2019	1153	7225	7171,3	7176,86
Mar 04, 2019	1154	7150	7242,26	7203,92
Mar 05, 2019	1155	7300	7158,5	7146
Mar 06, 2019	1156	7325	7289,24	7277,06
Mar 07, 2019	1157	7325	7306,75	7310,2
Mar 08, 2019	1158	7150	7311,18	7314,1
Mar 11, 2019	1159	7175	7153,25	7138,3
Mar 12, 2019	1160	7175	7176,68	7163,57
Mar 13, 2019	1161	7100	7171,96	7166,38
Mar 14, 2019	1162	7275	7101,54	7096,3
Mar 15, 2019	1163	7225	7257,71	7248,38
Mar 18, 2019	1164	7400	7212,73	7218,81
Mar 19, 2019	1165	7300	7377,58	7375,73
Mar 20, 2019	1166	7250	7286,22	7297,47
Mar 21, 2019	1167	7250	7247,28	7247,58
Mar 22, 2019	1168	7250	7246,18	7243,63

Mar 25, 2019	1169	7050	7245,16	7237,22
Mar 26, 2019	1170	7150	7061,03	7057,77
Mar 27, 2019	1171	7100	7147,17	7131,92
Mar 28, 2019	1172	7125	7098,13	7092,71
Mar 29, 2019	1173	7325	7119,16	7108,34
Apr 01, 2019	1174	7275	7300,23	7296,65
Apr 02, 2019	1175	7450	7257,96	7269,34
Apr 03, 2019	1176	7450	7425,65	7424,36
Apr 04, 2019	1177	7575	7427,62	7437,98
Apr 05, 2019	1178	7600	7552,71	7556,83
Apr 08, 2019	1179	7550	7576,52	7590,87
Apr 09, 2019	1180	7700	7535,6	7537,99
Apr 10, 2019	1181	7675	7682,76	7679,16
Apr 11, 2019	1182	7550	7654,34	7662,47
Apr 12, 2019	1183	7475	7541,95	7548,47
Apr 15, 2019	1184	7600	7476,17	7473,21
Apr 16, 2019	1185	7750	7592,78	7581,04
Apr 17, 2019	1186	7750	7727,4	7724,02
Apr 18, 2019	1187	7850	7723,32	7737,08
Apr 19, 2019	1188	7850	7827,16	7833,83
Apr 22, 2019	1189	7525	7826,62	7836,63
Apr 23, 2019	1190	7650	7522,19	7533,97
Apr 24, 2019	1191	7650	7655,94	7628,1
Apr 25, 2019	1192	7550	7640,09	7635,67
Apr 26, 2019	1193	7650	7544,09	7536,66
Apr 29, 2019	1194	7600	7639,53	7629,9
Apr 30, 2019	1195	7625	7586,85	7589,88
May 01, 2019	1196	7625	7614,31	7605,88
May 02, 2019	1197	7475	7611,94	7612,3
May 03, 2019	1198	7425	7471,7	7473,73

May 06, 2019	1199	7425	7428,24	7416,29
May 07, 2019	1200	7525	7423,74	7409,29
May 08, 2019	1201	7400	7513	7506,19
May 09, 2019	1202	7150	7391,3	7395,85
May 10, 2019	1203	7175	7165,47	7153,95
May 13, 2019	1204	7025	7184,61	7163,76
May 14, 2019	1205	7000	7040,08	7018,53
May 15, 2019	1206	6950	7008,84	6989,64
May 16, 2019	1207	6775	6956,05	6940,56
May 17, 2019	1208	6700	6796,5	6782,61
May 20, 2019	1209	6900	6718,93	6698,61
May 21, 2019	1210	7000	6884,31	6870,14
May 22, 2019	1211	7000	6978,74	6977,22
May 23, 2019	1212	7100	6984,92	6983,78
May 24, 2019	1213	7175	7079,67	7085,25
May 27, 2019	1214	7125	7154,85	7162,9
May 28, 2019	1215	7075	7115,27	7118,83
May 29, 2019	1216	7200	7072,9	7068,59
May 30, 2019	1217	7200	7186,2	7175,2
May 31, 2019	1218	7450	7187,45	7187,95
Jun 03, 2019	1219	7450	7420,28	7429,12
Jun 04, 2019	1220	7450	7422,44	7437,74
Jun 05, 2019	1221	7450	7432,21	7437,74
Jun 06, 2019	1222	7450	7436,71	7437,74
Jun 07, 2019	1223	7450	7440,17	7437,74
Jun 10, 2019	1224	7675	7440,17	7437,74
Jun 11, 2019	1225	7625	7652,75	7648,44
Jun 12, 2019	1226	7500	7599,56	7616,95
Jun 13, 2019	1227	7500	7491,59	7497,08
Jun 14, 2019	1228	7425	7496,92	7483,39

Jun 17, 2019	1229	7375	7424,19	7414,01
Jun 18, 2019	1230	7500	7375,7	7365,61
Jun 19, 2019	1231	7650	7488,55	7479,23
Jun 20, 2019	1232	7600	7625,68	7631,59
Jun 21, 2019	1233	7450	7576,86	7599,21
Jun 24, 2019	1234	7350	7444,31	7452,32
Jun 25, 2019	1235	7350	7356,78	7348,49
Jun 26, 2019	1236	7250	7353,47	7340,38
Jun 27, 2019	1237	7375	7254,14	7243,38
Jun 28, 2019	1238	7450	7365,52	7356,33
Jul 01, 2019	1239	7375	7430,85	7433,44
Jul 02, 2019	1240	7300	7362,77	7371,46
Jul 03, 2019	1241	7275	7297,32	7293,39
Jul 04, 2019	1242	7250	7274,86	7268,57
Jul 05, 2019	1243	7150	7248,97	7239,82
Jul 08, 2019	1244	7300	7154,21	7155,15
Jul 09, 2019	1245	7275	7288,03	7273,8
Jul 10, 2019	1246	7450	7262,78	7264,91
Jul 11, 2019	1247	7525	7427,36	7423,9
Jul 12, 2019	1248	7450	7497,72	7513,13
Jul 15, 2019	1249	7425	7433,78	7450,4
Jul 16, 2019	1250	7450	7417,03	7424,65
Jul 17, 2019	1251	7100	7441,85	7435,94
Jul 18, 2019	1252	7150	7117,96	7120,88
Jul 19, 2019	1253	7100	7160,99	7139,17
Jul 22, 2019	1254	7100	7105,44	7100,17
Jul 23, 2019	1255	7150	7100,08	7092,22
Jul 24, 2019	1256	7175	7140,13	7133,92
Jul 25, 2019	1257	7300	7163,76	7163,53
Jul 26, 2019	1258	7075	7279,47	7280,4

Jul 29, 2019	1259	7175	7077,56	7086,53
Jul 30, 2019	1260	7275	7169,45	7155,56
Jul 31, 2019	1261	7000	7258,78	7256,3
Aug 01, 2019	1262	7025	7011,22	7020
Aug 02, 2019	1263	7075	7029,61	7006,14
Aug 05, 2019	1264	6925	7070,39	7055,57
Aug 06, 2019	1265	6750	6934,8	6923,92
Aug 07, 2019	1266	6725	6773,47	6759,87
Aug 08, 2019	1267	6900	6739,88	6725,69
Aug 09, 2019	1268	6775	6885,71	6876,15
Aug 12, 2019	1269	6750	6779,86	6783,34
Aug 13, 2019	1270	6675	6753,5	6741,46
Aug 14, 2019	1271	6675	6685,98	6670,42
Aug 15, 2019	1272	6525	6680,66	6676,07
Aug 16, 2019	1273	6500	6547,85	6536,21
Aug 19, 2019	1274	6425	6514,02	6503,8
Aug 20, 2019	1275	6425	6443,71	6433,3
Aug 21, 2019	1276	6350	6434,4	6422,55
Aug 22, 2019	1277	6325	6367,49	6361,73
Aug 23, 2019	1278	6575	6338,22	6330,74
Aug 26, 2019	1279	6575	6544,4	6546,82
Aug 27, 2019	1280	6525	6565,24	6569,59
Aug 28, 2019	1281	6450	6527,54	6526,64
Aug 29, 2019	1282	6425	6463,06	6457,24
Aug 30, 2019	1283	6675	6436,9	6429,21
Sep 02, 2019	1284	6550	6645,64	6648,43
Sep 03, 2019	1285	6475	6556,24	6560,79
Sep 04, 2019	1286	6500	6487,89	6479,79
Sep 05, 2019	1287	6700	6503,14	6503,18
Sep 06, 2019	1288	6750	6675,98	6674,95

Sep 09, 2019	1289	6650	6732,72	6745,49
Sep 10, 2019	1290	6675	6653,8	6665,26
Sep 11, 2019	1291	6925	6673,21	6669,13
Sep 12, 2019	1292	6750	6894,43	6892,3
Sep 13, 2019	1293	6750	6754,57	6772,18
Sep 16, 2019	1294	6700	6750,74	6750,43
Sep 17, 2019	1295	6475	6706,86	6697,3
Sep 18, 2019	1296	6700	6510,44	6497,18
Sep 19, 2019	1297	6600	6683,86	6675,88
Sep 20, 2019	1298	6575	6607,84	6610,62
Sep 23, 2019	1299	6625	6581,05	6578,54
Sep 24, 2019	1300	6475	6620,44	6615,86
Sep 25, 2019	1301	6500	6496,29	6490,84
Sep 26, 2019	1302	6700	6505,45	6494,37
Sep 27, 2019	1303	6650	6675,98	6672,17
Sep 30, 2019	1304	6600	6646,92	6653,11