



TUGAS AKHIR - IS 184853

## PERAMALAN HARGA EMAS DUNIA MENGGUNAKAN METODE RECURRENT NEURAL NETWORK (RNN)

*FORECASTING OF WORLD GOLD PRICE USING  
RECURRENT NEURAL NETWORK (RNN) METHOD*

LUDIA ROSEMA DEWI  
NRP 05211640000025

Dosen Pembimbing :  
Edwin Riksakomara, S.Kom., MT.

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





**ITS**  
Institut  
Teknologi  
Sepuluh Nopember

**TUGAS AKHIR - IS 184853**

## **PERAMALAN HARGA EMAS DUNIA MENGGUNAKAN METODE RECURRENT NEURAL NETWORK (RNN)**

LUDIA ROSEMA DEWI  
NRP 0521164000025

Dosen Pembimbing :  
Edwin Riksakomara, S.Kom., MT.

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



**ITS**  
Institut  
Teknologi  
Sepuluh Nopember

TUGAS AKHIR - IS 184853

## **FORECASTING OF WORLD GOLD PRICE USING RECURRENT NEURAL NETWORK (RNN) METHOD**

LUDIA ROSEMA DEWI  
NRP 05211640000025

SUPERVISOR :  
Edwin Riksakomara, S.Kom., MT.

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

# LEMBAR PENGESAHAN

## Peramalan Harga Emas Dunia Menggunakan Metode Recurrent Neural Network (RNN)

### 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

Ludia Rosema Dewi

0521164000025

Surabaya, 14 Agustus 2020

Kepala Departemen Sistem Informasi

Dr. Muijahidin, ST., MT.  
NIP. 197010102003121001



# LEMBAR PERSETUJUAN

## PERAMALAN HARGA EMAS DUNIA MENGGUNAKAN METODE RECURRENT NEURAL NETWORK (RNN)

### TUGAS AKHIR

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

**LUDIA ROSEMA DEWI**  
**NRP. 05211640000025**

Disetujui Tim Penguji : Tanggal Ujian : 14 Juli 2020  
Periode Wisuda : September 2020

**Edwin Riksakomara, S.Kom., MT.**

**(Pembimbing I)**

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

**(Pengaji I)**

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

**(Pengaji II)**

# **PERAMALAN HARGA EMAS DUNIA MENGGUNAKAN METODE RECURRENT NEURAL NETWORK (RNN)**

**Nama Mahasiswa : Ludia Rosema Dewi**  
**NRP : 05211640000025**  
**Departemen : Sistem Informasi FTEIC-ITS**  
**Pembimbing 1 : Edwin Riksakomara, S.Kom., MT.**

## **ABSTRAK**

*Pertumbuhan ekonomi suatu negara sangat dipengaruhi oleh peningkatan investasi pada negara tersebut. Masyarakat kecil maupun atas menggemari investasi karena dapat menjadi pemasukan tambahan bagi investor. Secara harsfiah, investasi ialah cara menanam sejumlah dana pada masa ini dengan harapan memperoleh keuntungan di masa depan. Dua sisi yang perlu diperhatikan dalam berinvestasi adalah sisi return dan risiko. Hukum yang berlaku dalam investasi yaitu semakin tinggi return yang ditawarkan semakin tinggi pula risiko yang ditanggung investor. Harga emas yang selalu mengalami perubahan atau terjadi ketidakstabilan harga menjadi masalah bagi investor. Fluktuasi harga menimbulkan masalah kapan waktu yang tepat untuk investor melakukan keputusan melakukan investasi karena harga pasar selalu berubah. Salah satu cara untuk menyelesaikan permasalahan dengan meramalkan harga emas di masa yang akan datang. Peramalan dibutuhkan investor karena berhadapan dengan ketidakpastian harga emas mendatang, mengurangi risiko dan membantu pengambilan keputusan. Penelitian tugas akhir dimaksudkan untuk menyelesaikan permasalahan tersebut. Penelitian ini memerlukan data, yaitu data harga emas dunia serta harga minyak dunia didapatkan secara daring. Periode masing-masing data dipilih dari tanggal 1 Januari 2014 hingga tanggal 1 Januari 2019. Penelitian ini membutuhkan model peramalan yang efektif sehingga mengetahui hasil dan akurasi peramalan harga emas*

*dunia. Penelitian menggunakan metode peramalan dengan recurrent neural network sebagai pemberi hasil ramalan. Recurrent neural network (RNN) adalah jenis jaringan saraf yang lebih fleksibel dengan penambahan umpan balik (feedback) dari output kembali ke input. Recurrent neural network memiliki memori internal dari input sebelumnya yang adaptif, sehingga recurrent neural network memiliki kemampuan komputasi yang lebih baik dan konvergensi yang lebih cepat dibandingkan dengan neural network lainnya. Hasil peramalan emas menggunakan metode recurrent neural network menunjukkan nilai mean absolute percentage error terkecil yaitu 0.621%.*

**Kata kunci:** *investasi, peramalan, harga emas dunia, recurrent neural network, mean absolute percentage error*

# **FORECASTING OF WORLD GOLD PRICE USING RECURRENT NEURAL NETWORK (RNN) METHOD**

**Student Name : Ludia Rosema Dewi**  
**NRP : 05211640000025**  
**Department : Information Systems ELECTICS-ITS**  
**Supervisor 1 : Edwin Riksakomara, S.Kom., MT.**

## **ABSTRACT**

*A country's economic growth is strongly influenced by increased investment in the country. Small communities and above are fond of investment because it can be an additional income for investors. Literally, investment is a way to invest a number of funds in this period in the hope of earning profits in the future. Two sides that need to be considered in investing are return and risk. The law applicable to investment is that the higher the return offered the higher the risk borne by the investor. The price of gold that is always experiencing changes or price instability becomes a problem for investors. Price fluctuations cause problems when the right time for investors make investment decisions because market prices always change. One way to solve the problem is by predicting the price of gold in the future. Forecasting is needed by investors because it is dealing with the uncertainty of future gold prices, reducing risk and helping decision making. Final assignment research is intended to solve these problems. This research requires data, namely data on world gold prices and world oil prices obtained online. The period of each data was chosen from January 1<sup>st</sup>, 2014 to January 1<sup>st</sup>, 2019. This research requires an effective forecasting model so that it knows the results and forecasting accuracy of the world gold price. The study uses forecasting methods with recurrent neural network as a predictor. Recurrent Neural Network (RNN) is a type of neural network that is more flexible with the addition of feedback from the output back to the input. Recurrent neural networks have internal memory from previous input that is adaptive, so recurrent neural networks have*

*better computational capabilities and faster convergence compared to other neural networks. The results of gold forecasting using the recurrent neural network method show the smallest mean absolute percentage error, which is 0.621%.*

***Keywords: investment, forecasting, world gold prices, recurrent neural network, mean absolute percentage error***

## **SURAT PERNYATAAN BEBAS PLAGIARISME**

Saya yang bertandatangan di bawah ini:

Nama : Ludia Rosema Dewi

NRP : 05211640000025

Tempat/Tanggal lahir : Serang/14 Juli 1998

Fakultas/Departemen : Fakultas Teknologi Elektro dan Informatika  
Cerdas/Sistem Informasi

Nomor Telp/Hp/email : 081383540022/

25ludiarosemadewi@gmail.com

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

**PERAMALAN HARGA EMAS DUNIA MENGGUNAKAN METODE RECURRENT NEURAL NETWORK (RNN)**

**Bebas Dari Plagiarisme Dan Bukan Hasil Karya Orang Lain.**

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

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

Surabaya, 14 Juli 2020



Ludia Rosema Dewi  
NRP. 05211640000025

*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 EMAS DUNIA MENGGUNAKAN METODE RECURRENT NEURAL NETWORK (RNN)**

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 Hadi Santoso dan Ibu Luluk Hariyati selaku kedua orang tua serta Jehant Fatra Hadi dan Santi Kurnia Dewi selaku saudara kandung dari penulis yang senantiasa memberikan dukungan dan semangat.
2. Bapak Edwin Riksakomara, S.Kom., MT. selaku dosen pembimbing dan sebagai narasumber yang senantiasa meluangkan waktu, memberikan ilmu dan petunjuk, serta memotivasi untuk kelancaran tugas akhir.
3. Bapak Ahmad Muklason, S.Kom., M.Sc., Ph.D. dan Bapak Faizal Mahananto, S.Kom., M.Eng., Ph.D., selaku dosen penguji yang telah memberikan saran dan kritik untuk perbaikan tugas akhir.
4. Bapak Ir. Achmad Holil Noor Ali, M.Kom selaku dosen wali yang telah memberikan dukungan selama masa perkuliahan.
5. Seluruh Bapak/Ibu dosen Departemen Sistem Informasi ITS yang telah memberikan ilmu yang bermanfaat kepada penulis.

6. Mas Ricky selaku admin laboratorium Rekayasa Data dan Intelegensi Bisnis yang membantu penulis menjadwalkan sidang tugas akhir.
7. Nevada Veterino yang telah membantu dan memberikan semangat kepada penulis setiap hari dalam penyelesaian tugas akhir.
8. Sahabat-sahabat BOSS BABY yaitu Ayun, Ajun, Nidia, Iqo, Vita yang memberikan informasi, motivasi, canda tawa, dan kebersamaan yang tidak terlupakan.
9. Tim Poster Sidang ARTEMIS yang saling membantu dalam membuat poster sidang untuk saya dan teman-teman angkatan lainnya.
10. Repa, Muslikh, Mira, dan teman-teman seperjuangan penghuni laboratorium Rekayasa Data dan Intelegensi Bisnis yang senantiasa membantu penulis dalam mencari solusi pada setiap permasalahan atas kesulitan dalam penulisan tugas akhir ini.
11. Teman-teman ARTEMIS yang telah memberikan banyak dukungan.
12. Berbagai pihak yang tidak bisa disebutkan satu persatu yang telah turut serta menyukseskan penulis dalam menyelesaikan tugas akhir.

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, 14 Juli 2020

Penulis

## DAFTAR ISI

ABSTRAK .....	v
ABSTRACT .....	vii
KATA PENGANTAR.....	xi
DAFTAR ISI .....	xiii
DAFTAR GAMBAR .....	xvii
DAFTAR TABEL .....	xxi
DAFTAR KODE.....	xxiii
BAB I PENDAHULUAN .....	1
1.1.    Latar Belakang .....	1
1.2.    Rumusan Masalah .....	4
1.3.    Batasan Permasalahan .....	5
1.4.    Tujuan Penelitian.....	5
1.5.    Manfaat Penelitian.....	5
1.6.    Relevansi .....	5
1.7.    Sistematika Penulisan.....	6
BAB II TINJAUAN PUSTAKA .....	9
2.1.    Penelitian Sebelumnya .....	9
2.2.    Landasan Teori .....	13
2.2.1.    Investasi.....	13
2.2.2.    Harga Emas Dunia.....	13
2.2.3.    Ekonomi Makro.....	14
2.2.4.    Harga Minyak Dunia .....	14
2.2.5.    Peramalan ( <i>Forecasting</i> ) .....	15
2.2.6. <i>Recurrent Neural Network</i> (RNN) .....	16
2.2.7.    Normalisasi.....	19
2.2.8.    Uji Akurasi Model Peramalan .....	19
BAB III METODOLOGI PENELITIAN .....	21
3.1.    Studi Literatur.....	22
3.2.    Pengambilan Data.....	22
3.3.    Praproses Data.....	22
3.4.    Pemodelan Peramalan Recurrent Neural Network.....	23
3.5.    Uji Coba Proporsi Data dan Uji Coba Dataset Lain....	24
3.6.    Penyusunan Buku Tugas Akhir .....	24

<b>BAB IV PERANCANGAN .....</b>	<b>25</b>
4.1.    Pengambilan Data.....	25
4.2.    Praproses Data .....	26
4.2.1.    Pemilihan Data .....	26
4.2.2.    Pencarian Missing Value .....	26
4.2.3.    Cleaning Data .....	26
4.2.4.    Pembagian Data.....	27
4.3.    Pemodelan Peramalan <i>Recurrent Neural Network</i> .....	27
4.3.1.    Normalisasi Data .....	27
4.3.2.    Mengubah Dataset menjadi Matriks .....	28
4.3.3.    Pembentukan Model .....	30
4.3.4.    Denormalisasi Hasil Prediksi.....	34
4.3.5.    Menghitung <i>Mean Absolute Percentage Error</i> ..	34
4.3.6.    Menyimpan Hasil Prediksi .....	34
4.4.    Uji Coba Proporsi Data dan Uji Coba Dataset Lain ....	34
<b>BAB V IMPLEMENTASI .....</b>	<b>35</b>
5.1.    Persiapan Implementasi.....	35
5.2.    Pengambilan Data.....	36
5.3.    Praproses Data.....	36
5.3.1.    Pemilihan Data .....	36
5.3.2.    Pencarian Missing Value .....	36
5.3.3.    Cleaning Data .....	37
5.3.4.    Pembagian Data.....	38
5.4.    Pemodelan Peramalan <i>Recurrent Neural Network</i> .....	38
5.4.1.    Normalisasi Data .....	38
5.4.2.    Mengubah Dataset Menjadi Matriks .....	39
5.4.3.    Membentuk Model .....	41
5.4.4.    Denormalisasi .....	42
5.4.5.    Menghitung <i>Mean Absolute Percentage rrор</i> .....	43
5.4.6.    Menyimpan hasil prediksi .....	44
5.5.    Uji Coba Proporsi Data dan Uji Coba Dataset Lain ...	45
<b>BAB VI HASIL DAN PEMBAHASAN.....</b>	<b>47</b>
6.1.    Hasil Pengambilan Data .....	47
6.2.    Hasil Pra-Proses Data .....	49

6.3.	Hasil Pemodelan Peramalan <i>Recurrent Neural Network</i> dengan <i>Univariate</i> .....	49
6.3.1.	Hasil Pemodelan Peramalan RNN untuk Periode 1 dengan <i>Univariate</i> .....	50
6.3.2.	Hasil Pemodelan Peramalan RNN untuk Periode 2 dengan <i>Univariate</i> .....	51
6.3.3.	Hasil Pemodelan Peramalan RNN untuk Periode 3 dengan <i>Univariate</i> .....	52
6.3.4.	Hasil Pemodelan Peramalan RNN untuk Periode 4 dengan <i>Univariate</i> .....	53
6.3.5.	Hasil Pemodelan Peramalan RNN untuk Periode 5 dengan <i>Univariate</i> .....	54
6.3.6.	Hasil Pemodelan Peramalan RNN untuk Periode 6 dengan <i>Univariate</i> .....	55
6.3.7.	Hasil Pemodelan Peramalan RNN untuk Periode 7 dengan <i>Univariate</i> .....	56
6.4.	Hasil Pemodelan Peramalan <i>Recurrent Neural Network</i> dengan <i>Multivariate</i> .....	57
6.4.1.	Hasil Pemodelan Peramalan RNN untuk Periode 1 dengan <i>Multivariate</i> .....	57
6.4.2.	Hasil Pemodelan Peramalan RNN untuk Periode 2 dengan <i>Multivariate</i> .....	58
6.4.3.	Hasil Pemodelan Peramalan RNN untuk Periode 3 dengan <i>Multivariate</i> .....	59
6.4.4.	Hasil Pemodelan Peramalan RNN untuk Periode 4 dengan <i>Multivariate</i> .....	60
6.4.5.	Hasil Pemodelan Peramalan RNN untuk Periode 5 dengan <i>Multivariate</i> .....	61
6.4.6.	Hasil Pemodelan Peramalan RNN untuk Periode 6 dengan <i>Multivariate</i> .....	62
6.4.7.	Hasil Pemodelan Peramalan RNN untuk Periode 7 dengan <i>Multivariate</i> .....	63
6.5.	Perbandingan Hasil Pemodelan Peramalan RNN antara <i>Univariate</i> dengan <i>Multivariate</i> .....	64
6.6.	Hasil Uji Coba Proporsi Data .....	66

6.6.1.	Uji Coba Proporsi Data 50:50 .....	66
6.6.2.	Uji Coba Proporsi Data 60:40 .....	69
6.6.3.	Uji Coba Proporsi Data 80:20 .....	71
6.7.	Perbandingan Nilai MAPE antar Proporsi Data .....	74
6.8.	Hasil Uji Coba Menggunakan Dataset Lain .....	74
6.9.	Perbandingan Nilai MAPE Pada Dataset Lain .....	76
6.10.	Kesimpulan Hasil Peramalan.....	77
BAB VII	KESIMPULAN DAN SARAN .....	79
7.1.	Kesimpulan.....	79
7.2.	Saran .....	80
DAFTAR PUSTAKA.....		81
BIODATA PENULIS .....		85
LAMPIRAN A .....		87
LAMPIRAN B.....		131

## DAFTAR GAMBAR

Gambar 1.1 Grafik fluktuasi harga emas dunia selama 5 tahun (Januari 2014 - Januari 2019) [5] .....	3
Gambar 1.2 Grafik fluktuasi harga minyak dunia (WTI) selama 5 tahun (Januari 2014 - Januari 2019) [7] .....	4
Gambar 1.3 Daftar bidang-bidang keilmuan di laboratorium Rekayasa Data dan Intelektensi Bisnis (RDIB) yang memiliki relevansi dengan dengan penilitian tugas akhir.....	6
Gambar 2.1 Ilustrasi <i>simple recurrent neural network</i> [19].....	17
Gambar 2.2 Ilustrasi model Elman [20] .....	17
Gambar 2.3 Ilustrasi model Hopfield [21] .....	18
Gambar 3.1 Alur metode pengerjaan tugas akhir .....	21
Gambar 4.1 Salah satu tampilan <i>website</i> investing.com .....	25
Gambar 4.2 Grafik yang konvergen antara <i>errors</i> dengan <i>epoch</i> .....	31
Gambar 4.3 Grafik fungsi <i>sigmoid gompertz</i> .....	32
Gambar 4.4 Grafik fungsi <i>sigmoid logistic</i> .....	32
Gambar 4.5 Arsitektur model RNN univariate.....	33
Gambar 4.6 Arsitektur model RNN multivariate .....	34
Gambar 6.1 Grafik fluktuasi harga emas dunia selama 5 tahun (Januari 2014 - Januari 2019).....	48
Gambar 6.2 Grafik fluktuasi harga minyak dunia (WTI) selama 5 tahun (Januari 2014 - Januari 2019) .....	49
Gambar 6.3 Grafik antara data aktual dengan data hasil peramalan <i>univariate</i> periode 1.....	50
Gambar 6.4 Grafik data aktual dengan data hasil peramalan <i>univariate</i> periode 2.....	51
Gambar 6.5 Grafik data aktual dengan data hasil peramalan <i>univariate</i> periode 3.....	52
Gambar 6.6 Grafik data aktual dengan data hasil peramalan <i>univariate</i> periode 4.....	53
Gambar 6.7 Grafik data aktual dengan data hasil peramalan <i>univariate</i> periode 5.....	54
Gambar 6.8 Grafik data aktual dengan data hasil peramalan <i>univariate</i> periode 6.....	55

Gambar 6.9 Grafik data aktual dengan data hasil peramalan <i>univariate</i> periode 7.....	56
Gambar 6.10 Grafik data aktual dengan data hasil peramalan <i>multivariate</i> periode 1.....	58
Gambar 6.11 Grafik data aktual dengan data hasil peramalan <i>multivariate</i> periode 2.....	59
Gambar 6.12 Grafik data aktual dengan data hasil peramalan <i>multivariate</i> periode 3.....	60
Gambar 6.13 Grafik data aktual dengan data hasil peramalan <i>multivariate</i> periode 4.....	61
Gambar 6.14 Grafik data aktual dengan data hasil peramalan <i>multivariate</i> periode 5.....	62
Gambar 6.15 Grafik data aktual dengan data hasil peramalan <i>multivariate</i> periode 6.....	63
Gambar 6.16 Grafik data aktual dengan data hasil peramalan <i>multivariate</i> periode 7.....	64
Gambar 6.17 Grafik perbandingan nilai MAPE terkecil di setiap periode pada proporsi data 70:30.....	66
Gambar 6.18 Grafik perbandingan nilai MAPE terkecil di setiap periode pada proporsi data 50:50.....	67
Gambar 6.19 Grafik antara data aktual dengan data hasil peramalan menggunakan model univariate periode ke-4 dengan proporsi data 50:50.....	68
Gambar 6.20 Grafik antara data aktual dengan data hasil peramalan menggunakan model multivariate periode ke-3 dengan proporsi data 50:50 .....	68
Gambar 6.21 Grafik perbandingan nilai MAPE terkecil di setiap periode pada proporsi data 60:40.....	70
Gambar 6.22 Grafik antara data aktual dengan data hasil peramalan menggunakan model univariate periode ke-2 dengan proporsi data 60:40 .....	70
Gambar 6.23 Grafik antara data aktual dengan data hasil peramalan menggunakan model multivariate periode ke-2 dengan proporsi data 60:40 .....	71

Gambar 6.24 Grafik perbandingan nilai MAPE terkecil di setiap periode pada proporsi data 80:20 .....	72
Gambar 6.25 Grafik antara data aktual dengan data hasil peramalan menggunakan model univariate periode ke-4 dengan proporsi data 80:20.....	73
Gambar 6.26 Grafik antara data aktual dengan data hasil peramalan menggunakan model multivariate periode ke-4 dengan proporsi data 80:20 .....	73
Gambar 6.27 Grafik perbandingan nilai MAPE terkecil di setiap proporsi data .....	74
Gambar 6.28 Grafik perbandingan nilai MAPE terkecil di setiap proporsi data pada harga pasar induk kramat jati.....	77

*Halaman ini sengaja dikosongkan*

## DAFTAR TABEL

Tabel 2.1 Ringkasan Jurnal Penelitian 1 .....	9
Tabel 2.2 Ringkasan Jurnal Penelitian 2 .....	10
Tabel 2.3 Ringkasan Jurnal Penelitian 3 .....	11
Tabel 2.4 Ringkasan Jurnal Penelitian 4 .....	11
Tabel 4.1 Matriks input yang terbentuk untuk 7 periode pada setiap variabel .....	28
Tabel 4.2 Parameter untuk pelatihan model peramalan .....	31
Tabel 5.1 Spesifikasi Perangkat Keras PC di Laboratorium RDIB .....	35
Tabel 5.2 Daftar Library.....	35
Tabel 5.3 Penambahan kolom <i>day</i> untuk melihat hari yang terlewatkann .....	37
Tabel 5.4 Pengurangan baris hari Minggu (blok merah).....	37
Tabel 5.5 Penjelasan dari Kode 5.1 .....	38
Tabel 5.6 Penjelasan dari Kode 5.2.....	39
Tabel 5.7 Penjelasan dari Kode 5.3 dan Kode 5.4.....	40
Tabel 5.8 Penjelasan dari Kode 5.5 .....	41
Tabel 5.9 Penjelasan dari Kode 5.6.....	43
Tabel 5.10 Penjelasan dari Kode 5.7 .....	43
Tabel 5.11 Penjelasan dari Kode 5.8.....	44
Tabel 6.1 Contoh beberapa harga emas dunia yang berhasil disimpan .....	47
Tabel 6.2 Contoh beberapa harga minyak dunia yang berhasil disimpan .....	48
Tabel 6.3 Perbandingan penambahan dan pengurangan baris data pada masing-masing data harga .....	49
Tabel 6.4 Urutan 10 MAPE terkecil pada periode 1 variabel <i>univariate</i> .....	50
Tabel 6.5 Urutan 10 MAPE terkecil pada periode 2 variabel <i>univariate</i> .....	51
Tabel 6.6 Urutan 10 MAPE terkecil pada periode 3 variabel <i>univariate</i> .....	52
Tabel 6.7 Urutan 10 MAPE terkecil pada periode 4 variabel <i>univariate</i> .....	53

Tabel 6.8 Urutan 10 MAPE terkecil pada periode 5 variabel <i>univariate</i> .....	54
Tabel 6.9 Urutan 10 MAPE terkecil pada periode 6 variabel <i>univariate</i> .....	55
Tabel 6.10 Urutan 10 MAPE terkecil pada periode 7 variabel <i>univariate</i> .....	56
Tabel 6.11 Urutan 10 MAPE terkecil pada periode 1 variabel <i>multivariate</i> .....	57
Tabel 6.12 Urutan 10 MAPE terkecil pada periode 2 variabel <i>multivariate</i> .....	58
Tabel 6.13 Urutan 10 MAPE terkecil pada periode 3 variabel <i>multivariate</i> .....	59
Tabel 6.14 Urutan 10 MAPE terkecil pada periode 4 variabel <i>multivariate</i> .....	60
Tabel 6.15 Urutan 10 MAPE terkecil pada periode 5 variabel <i>multivariate</i> .....	61
Tabel 6.16 Urutan 10 MAPE terkecil pada periode 6 variabel <i>multivariate</i> .....	62
Tabel 6.17 Urutan 10 MAPE terkecil pada periode 7 variabel <i>multivariate</i> .....	63
Tabel 6.18 Model pada proporsi data 70:30 disetiap periode yang memiliki nilai MAPE terkecil .....	65
Tabel 6.19 Nilai MAPE terkecil pada proporsi data 50:50 .....	66
Tabel 6.20 Nilai MAPE terkecil pada proporsi data 60:40 .....	69
Tabel 6.21 Nilai MAPE terkecil pada proporsi data 80:20 .....	71
Tabel 6.22 Nilai MAPE terkecil pada setiap proporsi data .....	74
Tabel 6.23 Nilai MAPE terkecil pada proporsi data 50:50 .....	75
Tabel 6.24 Nilai MAPE terkecil pada proporsi data 60:40 .....	75
Tabel 6.25 Nilai MAPE terkecil pada proporsi data 70:30 .....	75
Tabel 6.26 Nilai MAPE terkecil pada proporsi data 80:20 .....	76
Tabel 6.27 Nilai MAPE setiap komoditi pada proporsi data berbeda .....	76

## **DAFTAR KODE**

Kode 5.1 Proses pembagian data training dan data testing .....	38
Kode 5.2 Proses normalisasi data training dan data testing .....	39
Kode 5.3 Proses mengubah dataset menjadi matriks untuk variabel <i>univariate</i> .....	39
Kode 5.4 Proses mengubah dataset menjadi matriks untuk variabel multivariate.....	40
Kode 5.5 Proses pembentukan model peramalan dengan parameter .....	41
Kode 5.6 Proses denormalisasi data aktual dan data hasil prediksi .....	43
Kode 5.7 Proses menghitung MAPE antara data aktual dengan data prediksi .....	43
Kode 5.8 Proses menyimpan data aktual, data hasil prediksi dan data nilai MAPE .....	44
Kode 5.9 Pembagian data training dan data testing sesuai dengan proporsi data yang akan digunakan .....	45
Kode 5.10 Matriks data training dan data testing univariate sesuai dengan proporsi data yang akan digunakan.....	46
Kode 5.11 Matriks data training dan data testing multivariate sesuai dengan proporsi data yang akan digunakan.....	46
Kode 5.12 Model sesuai dengan model terbaik yang akan digunakan .....	46

*Halaman ini sengaja dikosongkan*

## **BAB I**

### **PENDAHULUAN**

Pada bagian pertama, pendahuluan, akan dijelaskan urutan dari proses identifikasi penelitian tugas akhir yang meliputi latar belakang masalah, perumusan masalah, batasan masalah, tujuan tugas akhir, manfaat yang akan diperoleh, dan relevansi penelitian tugas akhir ini. Dengan harapan dapat memberikan gambaran umum dari permasalahan serta penyelesaian masalah pada tugas akhir agar mudah dipahami.

#### **1.1. Latar Belakang**

Pada era sekarang yang serba *digital*, dunia mulai berubah pesat seiring perkembangan teknologi informasi membuat *internet* menjadi salah satu sumber kebutuhan manusia saat ini. Kebutuhan akan penggunaan *internet* tidak lepas dari sisi bisnis yang memasarkan produk maupun jasa dari segala sektor secara *online*.

Bisnis jasa secara *online* mulai berkembang khususnya di bidang *investment* yang menghubungkan antara penjual dengan pembeli. Pembeli atau masyarakat yang ingin menginvestasikan uangnya dalam bentuk penanaman modal baik itu saham, komoditi, properti, nilai tukar mata uang, dan sebagainya diuntungkan dari sisi kenyamanan dan kemudahan. Investasi sangat diyakini membawa pengaruh yang besar bagi investor untuk memperoleh keuntungan di masa mendatang. Keuntungan yang didapat bisa dalam berbagai bentuk tergantung pada jenis investasi yang dipilihnya.

Investasi memiliki masing-masing kelebihan dan kekurangan, jika memiliki investasi saham sangat besar keuntungan yang didapat apabila pada suatu waktu harga saham mengalami kenaikan yang signifikan, namun risiko yang dimiliki sangat besar apabila suatu saat harga saham turun tajam. Jika ingin berinvestasi properti perlu jangka waktu yang lama untuk investor mendapat keuntungan yang menjanjikan dari harga properti yang stabil kenaikannya dan tahan terhadap inflasi.

Investasi emas memiliki kemampuan beradaptasi dengan inflasi yang membuat barang dan jasa semakin mahal. Peneliti juga menemukan bahwa emas dapat melindungi nilai dan tempat yang aman dalam kondisi pasar saham yang ekstrim. [1] Hal ini membuat emas sebagai unsur dominan dalam pasar keuangan dan menjadi sarana untuk meneliti mekanisme pembentukan harganya. [2]

Lalu yang menjadi permasalahan ialah waktu yang tepat untuk investor melakukan keputusan melakukan investasi yang menguntungkan di masa depan, terutama dalam membeli atau menjual emas. Keputusan membeli emas berarti investor ingin mendapat keuntungan dari harga emas yang akan turun. Begitu pun sebaliknya, menjual emas ketika ingin mendapat keuntungan dari harga emas yang akan naik.

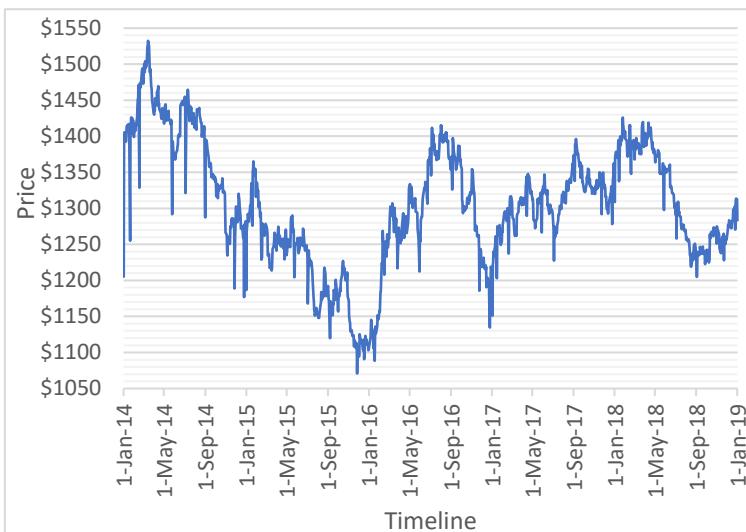
Strategi dalam berinvestasi sangat diperlukan untuk memperoleh keuntungan yang besar. Strategi yang dapat dilakukan oleh investor adalah dengan melakukan peramalan harga emas. Cara ini memberikan investor analisa kapan harga emas dunia akan naik dan sebaliknya.

Pada penelitian sebelumnya yang dilakukan oleh Sri Herawati pada tahun 2017 dengan judul “*Implementing Method of Ensemble Empirical Mode Decomposition and Recurrent Neural Network for Gold Price Forecasting*” melakukan peramalan terhadap harga emas menggunakan metode *Feedforward Neural Network* (FNN), *Recurrent Neural Network* (RNN), dan *Ensemble Empirical Mode Decomposition* (EEMD). Hasil dari penelitian tersebut menyatakan bahwa metode peramalan dengan menggunakan EEMD-RNN lebih baik dibandingkan dengan metode EEMD-FNN. [3]

Penelitian lain yang dilakukan oleh Werner Kristjanpoller dan Marcel C. Minutolo dengan judul “*Gold Price Volatility: A Forecasting Approach Using The Artificial Neural Network–GARCH Model*” menggunakan gabungan dari metode *Artificial Neural Network* dan *Generalized Autoregressive Conditional Heteroskedasticity* (ANN-GARCH) untuk memperkirakan

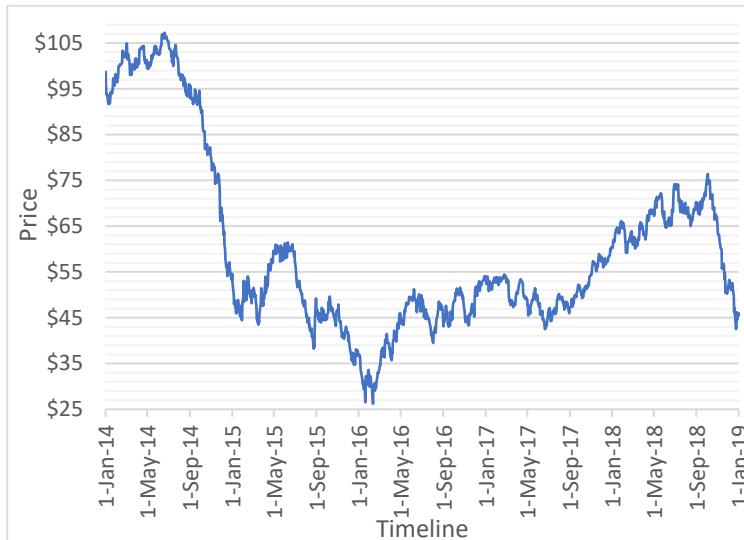
harga emas. Penelitian ini menunjukkan hasil terbaik perkiraan harga emas dengan memasukkan Euro/Dollar, Yen/Dollar, FTSE variation, DJI variation, dan harga minyak sebagai *input* pada ANN. [4]

Oleh karena itu, ekonomi makro menjadi faktor penting yang mempengaruhi perubahan harga emas dunia karena tingkat fluktuasi yang tinggi. Gambar 1.1 menunjukkan fluktuasi harga emas dunia yang terjadi dari bulan Januari 2014 hingga bulan Januari 2019.



**Gambar 0.1 Grafik fluktuasi harga emas dunia selama 5 tahun (Januari 2014 - Januari 2019) [5]**

Peramalan dengan menambahkan salah satu faktor ekonomi makro memberikan peningkatan hasil peramalan. Faktor yang dapat mempengaruhi pasar emas dunia ialah harga minyak dunia dan tingkat inflasi. [6] Terdapat korelasi positif antara harga emas dan minyak mentah. Gambar 1.2 merupakan grafik dari fluktuasi harga minyak dunia, khususnya harga minyak hasil produksi *West Texas Intermediate* (WTI) dari bulan Januari 2014 hingga bulan Januari 2019.



**Gambar 0.2 Grafik fluktuasi harga minyak dunia (WTI) selama 5 tahun (Januari 2014 - Januari 2019) [7]**

Oleh karena itu, dilakukan penelitian dengan metode *recurrent neural network* (RNN) sebagai pemberi hasil ramalan harga emas dunia. RNN adalah jenis jaringan saraf yang lebih fleksibel dengan penambahan umpan balik (*feedback*) dari *output* kembali ke *input*. RNN memiliki memori internal dari *input* sebelumnya yang adaptif, sehingga RNN memiliki kemampuan komputasi yang lebih baik dan konvergensi yang lebih cepat dibandingkan dengan *neural network* lainnya.

## 1.2. Rumusan Masalah

Berdasarkan uraian latar belakang, rumusan masalah dari penelitian ini adalah:

1. Bagaimanakah membangun model peramalan harga emas dunia dengan menggunakan metode *recurrent neural network* (RNN)?
2. Bagaimana akurasi dari hasil peramalan harga emas dunia?

### **1.3. Batasan Permasalahan**

Berdasarkan permasalahan yang disebutkan di atas, maka batasan masalah pada penelitian tugas akhir ini adalah sebagai berikut:

1. Variabel yang digunakan untuk peramalan adalah harga emas dunia dan harga minyak dunia.
2. Data yang digunakan pada penelitian ini merupakan data harga emas dunia dan harga minyak dunia, bersumber dari investing.com dalam periode harian dengan periode 1 Januari 2014 sampai dengan 1 Januari 2019.
3. Penelitian ini menggunakan *tools* Rstudio.

### **1.4. Tujuan Penelitian**

Tujuan dari pengerjaan penelitian tugas akhir ini adalah sebagai berikut:

1. Mengetahui hasil dari peramalan harga emas dunia dengan menggunakan metode *recurrent neural network* (RNN).
2. Mengetahui akurasi dari hasil peramalan harga emas dunia dengan berbagai metode validasi.

### **1.5. Manfaat Penelitian**

Manfaat yang diharapkan dapat diperoleh dari tugas akhir ini adalah:

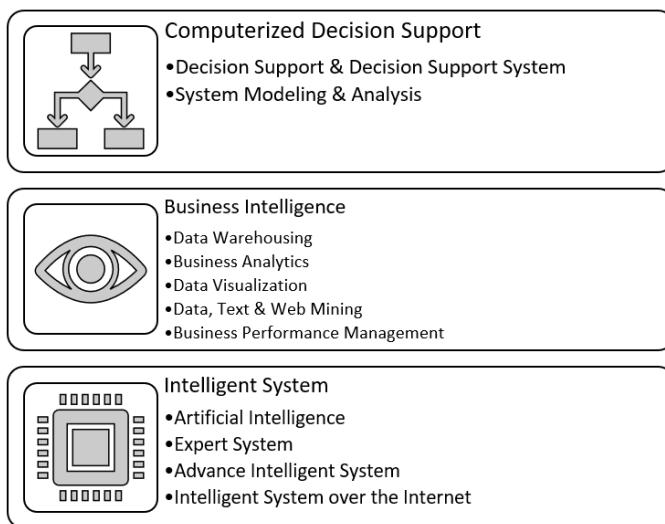
1. Memberikan akan informasi bagi investor dalam mengambil keputusan dalam membeli investasi emas pada pasar komoditi dunia.
2. Pembelajaran dalam menganalisis harga emas dunia sehingga menambah kemampuan berpikir serta bertambahnya ilmu pengetahuan.

### **1.6. Relevansi**

Penelitian pada tugas akhir ini bersifat menyelesaikan permasalahan sehari-hari. Permasalahan yang dimaksud terkait dengan investasi sehingga diperlukan sebuah penelitian yang dapat melakukan analisis peramalan harga emas dunia. Analisis tersebut memberikan investor pandangan terhadap keputusan yang sesuai dengan permasalahan yang dihadapinya.

Penelitian tugas akhir ini memiliki relevansi dengan salah satu bidang minat yang ada pada laboratorium Rekayasa Data dan Intelelegensi Bisnis. Penelitian ini sesuai dengan bidang keilmuan yang ada dalam laboratorium tersebut yaitu *Business Analytics (Forecasting)*, *Computerized Decision Support (Decision Support)* serta *Intelligent System (Artificial Intelligence)* seperti yang dapat dilihat pada Gambar 1.3.

Penelitian ini memiliki keterkaitan dengan mata kuliah wajib yang ada di Departemen Sistem Informasi seperti Analitika Bisnis serta mata kuliah pilihan; Sistem Pengambil Keputusan, Penggalian Data dan Teknik Peramalan, dimana mata kuliah tersebut merupakan mata kuliah pilihan yang disediakan di laboratorium Rekayasa Data dan Intelelegensi Bisnis (RDIB).



**Gambar 1.3 Daftar bidang-bidang keilmuan di laboratorium Rekayasa Data dan Intelelegensi Bisnis (RDIB) yang memiliki relevansi dengan penilitian tugas akhir**

### 1.7. Sistematika Penulisan

Sistematika penulisan laporan tugas akhir disesuaikan dengan format yang telah ditentukan, yaitu terdiri dari tujuh bab sebagai berikut,

## **BAB I PENDAHULUAN**

Pada bab ini dijelaskan hal yang mendasari pengerjaan penelitian tugas akhir ini. Dijelaskan pula batasan masalah, tujuan, manfaat, dan relevansi dari penelitian tugas akhir.

## **BAB II TINJAUAN PUSTAKA**

Pada bab ini dijelaskan mengenai penelitian-penelitian yang sudah ada sebelumnya. Penelitian-penelitian tersebut memiliki permasalahan atau topik serupa dan teori-teori yang menunjang dalam pengerjaan penelitian tugas akhir.

## **BAB III METODOLOGI PENELITIAN**

Pada bab ini dijelaskan mengenai langkah-langkah pengerjaan pada penelitian tugas akhir.

## **BAB IV PERANCANGAN**

Pada bab ini dijelaskan mengenai rancangan penelitian tugas akhir yang digunakan untuk implemetasi dari metode yang digunakan.

## **BAB V IMPLEMENTASI**

Pada bab ini dijelaskan mengenai hal-hal yang dilakukan dalam mengerjakan penelitian tugas akhir sesuai dengan metode yang digunakan.

## **BAB VI HASIL DAN PEMBAHASAN**

Pada bab ini dijelaskan mengenai hasil yang diperoleh dari metode peramalan RNN yang digunakan dan tentang analisa dari hasil prediksi tersebut.

## **BAB VII KESIMPULAN DAN SARAN**

Pada bab ini dijelaskan mengenai kesimpulan yang didapat untuk menyempurnakan penelitian di masa yang akan datang. Laporan ini diharapkan dapat bermanfaat sebagai referensi dalam pembuatan tugas akhir lain serta sebagai acuan untuk pengembangan lebih lanjut terkait penelitian serupa.

*Halaman ini sengaja dikosongkan*

## **BAB II**

### **TINJAUAN PUSTAKA**

Pada bab selanjutnya, bagian ini akan menjelaskan mengenai pembahasan penelitian terdahulu dan membahas dasar teori yang digunakan sebagai acuan atau landasan dalam penggeraan tugas akhir. Penelitian sebelumnya merupakan penelitian yang memiliki keterkaitan dengan penggeraan tugas akhir ini. Dasar teori merupakan gambaran umum tentang studi kasus dan penjelasan teori mengenai metode yang akan diterapkan pada studi kasus.

#### **2.1. Penelitian Sebelumnya**

Dalam penggeraan tugas akhir ini, terdapat referensi dari beberapa penelitian yang berhubungan dengan tugas akhir. Referensi penelitian terdahulu adalah penelitian yang memiliki kesamaan topik dan metode pada tugas akhir. Penjelasan singkat dari penelitian yang ada dijelaskan pada Tabel 2.1 sampai dengan Tabel 2.4.

**Tabel 2.1 Ringkasan Jurnal Penelitian 1**

Judul Penelitian	<i>A Novel Hybrid Model On The Prediction Of Time Series And Its Application For The Gold Price Analysis And Forecasting [2]</i>
Nama Peneliti	Jianwei E., Jimin Ye, Haihong Jin
Tahun Penelitian	2018
Deskripsi Umum Penelitian	Dalam jurnal ini, menggunakan teknik kombinasi baru berdasarkan pada <i>independent component analysis</i> (ICA) dan <i>gate recurrent unit neural network</i> (GRUNN), yang disebut ICA-GRUNN. Pertama, ICA merupakan teknik analisis multisaluran campuran, teknik <i>variational mode decomposition</i> (VMD) digunakan untuk menguraikan seri temporal asli menjadi multisaluran campuran sinyal virtual. Kedua, komponen independent (IC) secara statistik dipisahkan dari urutan waktu melalui ICA serta faktor-faktor pengaruh harga emas dianalisis dari aspek IC. Hasil menunjukkan bahwa fluktuasi harga emas akan

	terganggu oleh tren jangka panjang, faktor berulang berulang dan peristiwa acak. Ketiga, menerapkan GRUNN pada IC untuk memperoleh seri prediksi komponen independen (ICP) dan hasil perkiraan harga emas adalah kombinasi dari ICP. Percobaan menunjukkan bahwa ICA-GRUNN memberikan prediksi dengan akurasi tinggi dan mengungguli metode <i>autoregressive integrated moving average</i> (ARIMA), <i>radial function neural network</i> (RBFNN), <i>long short term memory neural network</i> (LSTM), GRUNN dan ICA -LSTM.
Relevansi Penelitian	Keterkaitan penelitian jurnal ini dengan penelitian tugas akhir adalah objek yang digunakan dalam peramalan sama dengan objek penelitian tugas akhir ini, yaitu harga emas.

**Tabel 2.2 Ringkasan Jurnal Penelitian 2**

Judul Penelitian	<i>A Boosting Approach to Forecasting the Volatility of Gold-Price Fluctuations Under Flexible Loss [8]</i>
Nama Peneliti	Christian Pierdzioch, Marian Risse, Sebastian Rohloff
Tahun Penelitian	2015
Deskripsi Umum Penelitian	Pendekatan informasi menggunakan <i>out-of-sample</i> yang bervariasi dari variabel keuangan dan makroekonomi untuk memperkirakan volatilitas fluktuasi harga emas. Jurnal ini menggunakan metode statistik yaitu $R^2$ <i>out-of-sample</i> untuk mengevaluasi perkiraan sebagai fungsi dari bentuk fungsi kehilangan ( <i>loss function</i> ). Ketika fungsi ini dibandingkan dengan perkiraan patokan autoregresif, cenderung mendapatkan manfaat dari menggunakan prediksi yang tersirat oleh pendekatan yang menghadapi kerugian yang lebih besar volatilitas masa depan dari fluktuasi harga emas.
Relevansi Penelitian	Keterkaitan penelitian jurnal dengan penelitian tugas akhir adalah variabel yang digunakan membuktikan bahwa harga emas dan makroekonomi saling berkaitan khususnya dengan harga minyak.

**Tabel 2.3 Ringkasan Jurnal Penelitian 3**

Judul Penelitian	<i>Gold Price Volatility: A Forecasting Approach Using The ANN-GARCH Model [4]</i>
Nama Peneliti	Werner Kristjanpoller, Marcel C. Minutolo
Tahun Penelitian	2015
Deskripsi Umum Penelitian	Salah satu metode yang paling banyak digunakan untuk memperkirakan volatilitas harga adalah model <i>generalized autoregressive conditional heteroskedasticity</i> (GARCH). Meskipun demikian, kesalahan dalam prediksi menggunakan pendekatan ini masih tergolong cukup tinggi. Oleh karena itu, penelitian lanjutan dilakukan untuk meningkatkan model peramalan menggunakan berbagai teknik. Jurnal memperluas bidang sistem pakar, peramalan dan model dengan menerapkan Jaringan Saraf Tiruan (JST) ke metode GARCH menghasilkan JST-GARCH. Model gabungan dari ANN-GARCH diterapkan untuk memperkirakan volatilitas harga emas (sekarang dan masa depan). Hasil menunjukkan peningkatan keseluruhan dalam perkiraan menggunakan ANN-GARCH dibandingkan dengan metode GARCH saja. Pengurangan keseluruhan 25% dalam rata-rata kesalahan persen direalisasikan menggunakan ANN-GARCH. Hasilnya direalisasikan menggunakan nilai tukar Euro/Dolar dan Yen/Dolar, indeks pasar saham DJI dan FTSE, dan harga minyak sebagai <i>input</i> .
Relevansi Penelitian	Keterkaitan penelitian jurnal ini dengan penelitian tugas akhir adalah variabel yang digunakan membuktikan bahwa harga emas dan makroekonomi saling berkaitan khususnya dengan harga minyak.

**Tabel 2.4 Ringkasan Jurnal Penelitian 4**

Judul Penelitian	<i>Implementing Method of Ensemble Empirical Mode Decomposition and Recurrent Neural Network for Gold Price Forecasting [3]</i>
Nama Peneliti	Sri Herawati, Firmansyah Adiputra, M. Latif, Aeri Rachmad

Tahun Penelitian	2017
Deskripsi Umum Penelitian	<p>Emas menjadi salah satu opsi investasi jangka panjang dan digunakan sebagai perlindungan nilai terhadap inflasi atau penurunan aset lainnya. Fluktuasi harga emas cenderung tidak linier dan tidak pasti. Sebagian besar peneliti dan praktisi bisnis gagal menghasilkan analisis harga yang konsisten, karena kompleksitas pasar emas yang dinamis dan fluktuatif. Salah satu metode yang dapat mengakomodasi fluktuasi harga emas adalah menggunakan <i>ensemble empirical mode decomposition</i> (EEMD). Hasil analisis harga emas dapat digunakan dalam peramalan. Peramalan fluktuasi harga emas diperlukan oleh importir, investor, dan masyarakat untuk mengurangi risiko dan membantu dalam pengambilan keputusan. Peramalan yang telah dilakukan adalah integrasi antara EEMD dan <i>feedforward neural network</i> (FNN) dengan hasil peramalan yang baik. Namun, penggunaan FNN kurang fleksibel untuk penggunaan parameter bebas, seperti jenis fungsi aktivasi, inisialisasi awal, jumlah <i>neuron input</i>, dan <i>neuron output</i>. Pengaturan parameter bebas fleksibel dapat memengaruhi kinerja jaringan saraf dan meningkatkan akurasi perkiraan. Salah satu cara untuk mengatasi kelemahan FNN dalam penggunaan parameter gratis adalah, dapat menggunakan <i>recurrent neural network</i> (RNN). Uji coba dalam penelitian ini menggunakan data bulanan harga emas dunia. Hasilnya membuktikan bahwa kinerja peramalan metode EEMD-RNN lebih baik daripada EEMD-FNN.</p>
Relevansi Penelitian	Keterkaitan penelitian jurnal ini dengan penelitian tugas akhir adalah variabel yang digunakan serta metode peramalan. Penelitian membuktikan bahwa harga emas dan harga minyak serta metode RNN memberikan hasil ramalan yang lebih baik.

## **2.2. Landasan Teori**

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

### **2.2.1. Investasi**

Investasi merupakan salah satu faktor penentu dalam laju pertumbuhan ekonomi suatu negara. Investasi adalah mobilisasi sumber daya untuk menciptakan atau menambah kapasitas produksi atau pendapatan di masa yang akan datang. [9] Tujuan utama adanya investasi, yaitu mengganti bagian dari penyediaan modal yang tidak terlalu bagus dan tambahan penyediaan modal yang ada. Investasi dikenal juga dengan kegiatan menanam modal dalam bentuk uang maupun benda dengan tujuan untuk memperoleh keuntungan selama satu periode. [10] Investasi memiliki unsur ketidakpastian (uncertainty) atau risiko sehingga investor tidak dapat memperkirakan secara pasti hasil dari keuntungan atau kerugian yang akan diperoleh dari investasi yang dilakukan.

### **2.2.2. Harga Emas Dunia**

Emas memiliki wujud logam yang padat, lembut, berkilau serta diyakini sebagai logam paling lentur diantara logam-logam lainnya. Emas memiliki beberapa kelebihan, yaitu tidak mudah berubah warna, tidak mudah berkarat, tidak pudar meskipun sudah disimpan dalam waktu yang lama serta memikat orang untuk memilikinya. Sifat-sifat inilah yang menjadikan nilai maupun harga emas menjadi sangat bernilai. Tiga faktor kelebihan emas [11] :

- Keterbatasan jumlahnya yang termasuk barang tambang (sumber daya alam yang tidak dapat diperbarui) karena prosesnya yang alami oleh alam serta proses penambangannya tidak mudah.
- Tidak terikat dengan sistem bunga seperti halnya uang kertas.
- Kemampuan emas terhadap daya beli terkini, dengan kata lain emas mampu beradaptasi dengan inflasi yang membuat barang dan jasa semakin mahal.

Dimulai pada tahun 1968, *London Gold Fixing* (LGF), standar pasar emas London yang menjadi patokan harga emas di seluruh dunia. Proses penentuan harga emas dilakukan mulai dari Presiden LGF mengumumkan harga tertentu yang kemudian diteruskan oleh lima anggota pasar LGF (*Bank of Nova Scotia, Barclaya Capital, Deutsche Bank, Hongkong and Shanghai Banking Corporation* (HSBC), *Societe Generale*) ke *dealer-dealer* yang berhubungan langsung dengan pembeli. Proses penentuan emas dilakukan dua kali sehari di jam 10.30 GMT (*London Gold AM Fix*) dan 15.00 GMT (*London Gold PM Fix*), pada waktu inilah sering digunakan sebagai harga penutupan di hari perdagangan dan sebagai tetapan nilai kontrak emas seluruh dunia. Harga emas ditentukan kedalam beberapa bentuk mata uang (USD, GBP, EUR). [12]

### **2.2.3. Ekonomi Makro**

Ekonomi makro sebagai salah satu faktor penting yang diperhatikan oleh investor. Ketika kondisi ekonomi makro suatu negara mengalami perubahan baik yang positif maupun negatif, investor dapat mengkalkulasi dampak terhadap investasi di masa yang akan datang, kemudian mengambil suatu keputusan untuk berinvestasi. Faktor-faktor ekonomi makro, antara lain, [13]

- tingkat inflasi,
- nilai tukar mata uang,
- siklus ekonomi,
- produk domestik bruto,
- tingkat suku bunga bank,
- harga minyak dunia, dan
- kondisi perekonomian internasional.

### **2.2.4. Harga Minyak Dunia**

Minyak mentah atau biasa disebut dengan crude oil salah satu sumber energi penting yang dibutuhkan banyak negara di dunia. Hasil dari pengolahan minyak mentah dapat menjadi energi untuk menjalankan berbagai kegiatan produksi seperti *Liquified Petroleum Gas* (LPG), bensin, solar, minyak pelumas, minyak bakar dan sejenisnya. Harga minyak mentah dunia diukur dari

harga *spot* pasar minyak dunia. Fluktuatif harga minyak dunia dapat berpengaruh terhadap pasar modal. Bagi negara pengekspor minyak dan perusahaan sektor pertimbangan, kenaikan harga minyak dunia memberikan keuntungan sehingga menarik minat investor untuk berinvestasi. [14]

Brent (*Brent Crude*) merupakan lahan tambang minyak di laut utara Eropa yang dibuka sejak tahun 1970. Harga minyak Brent menjadi standar umum nilai standarisasi minyak hampir 40% di seluruh dunia dan masih dijadikan patokan hingga sekarang. Namun produksi Brent mengalami penurunan sejak 2007 sehingga standarisasi harga minyak mulai beralih dari Brent ke minyak hasil produksi *West Texas Intermediate* (WTI) di Texas, Amerika Serikat. Minyak hasil produksi WTI dimanfaatkan menjadi bensin industri dan paling banyak diminati karena berkualitas tinggi.

Harga minyak *Organization of the Petroleum Exporting Countries* (OPEC) merupakan harga minyak campuran dari negara-negara yang bergabung kedalam OPEC (Algeria, Indonesia, Nigeria, Saudi Arabia, Venezuela, dan Meksiko). Harga minyak OPEC lebih rendah dibandingkan harga minyak lainnya karena minyak dari sebagian negara anggota OPEC memiliki kadar *sulfur* (belerang) yang tinggi sehingga sulit dijadikan bahan bakar. Beberapa hal yang mempengaruhi harga minyak dunia antara lain :

- Penawaran minyak dunia ditentukan oleh OPEC terutama pada kuota suplai.
- Pemintaan minyak dunia meningkat pada musim-musim tertentu di masing-masing negara.
- Cadangan minyak Amerika Serikat tersimpan dalam lokasi yang strategis. [12]

### **2.2.5. Peramalan (*Forecasting*)**

Peramalan merupakan cara memprediksikan nilai atau keadaan untuk masa yang akan datang dengan satu/banyak variabel. Tujuan peramalan adalah untuk mengurangi tingkat ketidakpastian, tetapi tetap memerlukan penilaian manajemen. Peramalan memiliki peran penting dalam pengambilan

keputusan bagi investor untuk berinvestasi. Oleh karena itu, pemilihan metode peramalan menjadi salah satu faktor penting dalam mengestimasi nilai harga investasi selain variabel-variabel yang terlibat. [15] Pengembangan metode peramalan dan pengetahuan memungkinkan dilakukannya penerapan langsung oleh praktisi.

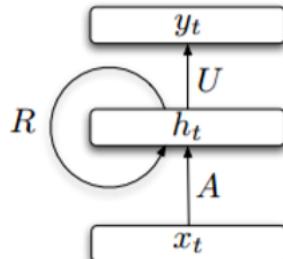
Tahap melakukan peramalan diawali dengan mendefinisikan permasalahan yang ingin diselesaikan. Setelah permasalahan teridentifikasi, pengumpulan data dan informasi diperlukan untuk mendukung penyelesaian masalah. Data dianalisa untuk menentukan metode peramalan yang sesuai. Model dibentuk ketika akan memulai peramalan dan menguji tingkat akurasi model yang telah dibangun. Model telah diuji dan diterapkan dengan memasukkan data *input* untuk menghasilkan nilai ramalan yang diinginkan. [16]

Berdasarkan sifat peramalan terbagi menjadi dua kategori utama, yaitu peramalan kualitatif dan peramalan kuantitatif. Peramalan kualitatif bersifat subjektif karena data berasal dari pengamatan kejadian di masa lampau. Terdapat dua metode kualitatif, yakni metode eksploratif dan metode normatif. Peramalan kuantitatif bersifat objektif karena diperoleh dari data numerik pada masa lampau. Terdapat dua metode kuantitatif, yakni metode deret berkala (*time series*) dan metode kausal (sebab-akibat). [17]

### **2.2.6. Recurrent Neural Network (RNN)**

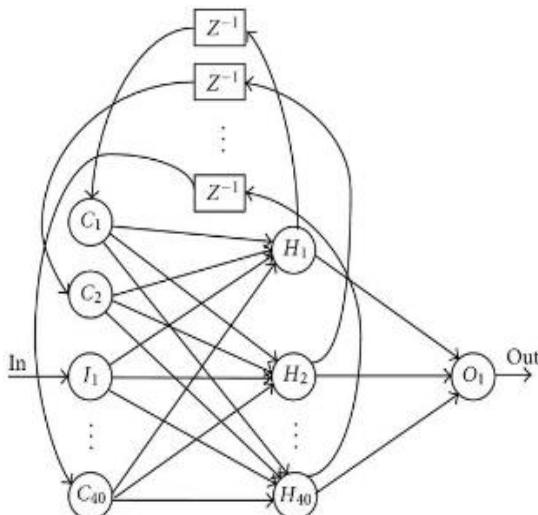
RNN dibentuk dari pengembangan *artificial neural network* (ANN) yang mempunyai memori pengingat data historis masa lalu. RNN dapat diartikan dengan jaringan umpan balik, jaringan yang mengakomodasikan luaran (*output*) jaringan sebagai masukan (*input*) jaringan tersebut dan digunakan untuk menghasilkan *output* baru. Susunan RNN umumnya berisi tiga lapisan, termasuk satu lapisan *input*, beberapa lapisan tengah (lapisan tersembunyi) dan satu lapisan *output*. Tidak ada batasan teoritis tentang batasan jumlah lapisan tersembunyi tetapi biasanya terdapat minimal satu atau dua. [18] Gambar 2.1

menggambarkan arsitektur jaringan saraf tiruan RNN yang digunakan dalam penelitian ini.

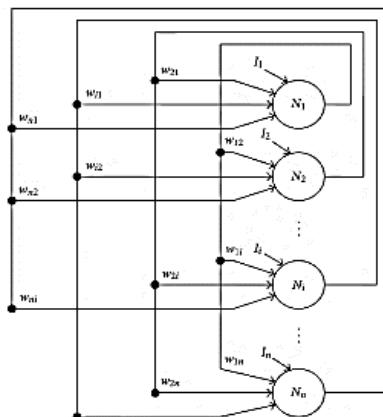


**Gambar 0.1 Ilustrasi simple recurrent neural network [19]**

Terdapat dua macam model RNN, model Hopfield dan model Elman. Model Hopfield memiliki umpan balik di seluruh *neuron* yang terbentuk. Model Elman merupakan model yang dinamis pada lapisan tersembunyi untuk mengekstraksi informasi. [19] Perbedaan susunan jaringan antara model Elman dan model Hopfield dapat dilihat di Gambar 2.2 dan Gambar 2.3.



**Gambar 0.2 Ilustrasi model Elman [20]**



Gambar 0.3 Ilustrasi model Hopfield [21]

Perbedaan rumus antara model Elman dan model Hopfield dapat dilihat di persamaan di bawah ini :

Persamaan model Elman, [22]

$$net_j = \sum_i^n x_i(t) v_{ij} + \sum_h^m y_h(t-1) u_{jh} + \theta_j$$

Keterangan :

$x_i$  : Input dari 1, 2, ..., n

$v_{ji}$  : Bobot dari input ke hidden layer

$y_h$  : Hasil duplikat dari hidden layer waktu ke (t-1)

$u_{jh}$  : Bobot dari context ke hidden layer

$\theta_j$  : Bias

$n$  : Jumlah node masukan

$i$  : Node input

$m$  : Jumlah node hidden

$h$  : Node context

$net_j$ : Hidden layer

Persamaan model Hopfield, [22]

$$C_i \frac{du_i(t)}{dt} = -\frac{u_i}{R_i} + \sum_{j=1}^n T_{ij} v_i(t) + I_i$$

$$v_i(t) = g_i(u_i(t))$$

untuk  $i = 1, 2, \dots, n$  dan  $C_i, R_i, t \geq 0$

Keterangan :

$u_i$  : Keadaan *neuron*

$v_i$  : *Output neuron*

$g_i$  : Fungsi *sigmoid*

$T_{ij}$  : Jumlah koneksi sinaptik antara *neuron* i dan j

### 2.2.7. Normalisasi

Normalisasi adalah langkah untuk mengubah data tiap variabel masukan menjadi rentang [0, 1]. Normalisasi dilakukan apabila data tidak setara satu sama lain sehingga dapat meminimalkan eror. Jenis normalisasi dikategorikan berdasarkan permasalahan sehingga dipilih jenis yang paling efektif. Salah satu rumus normalisasi data, Normalisasi min-max : [23]

$$\text{Normalisasi min-max} = \frac{(x - \min)}{(\max - \min)}$$

Keterangan :

$x$  : Data yang akan dinormalisasi

$\min$  : Nilai minimum dari data  $x$

$\max$  : Nilai maksimum dari data  $x$

### 2.2.8. Uji Akurasi Model Peramalan

Pengujian eror sangat diperlukan untuk mengetahui keakuratan suatu metode peramalan. Pengukuran untuk menguji seberapa besar penyimpangan antara data aktual dengan data peramalan disebut dengan MAPE (*Mean Absolute Percentage Error*). Perhitungan MAPE dilakukan dengan cara merata-ratakan persentase hasil dari eror mutlak di setiap periode dibagi dengan nilai observasi nyata di periode yang sama. Batas tertinggi dikatakan hasil peramalan baik jika MAPE tidak melebihi batas 20%, semakin kecil nilai rata-rata maka akan semakin bagus. Persamaan MAPE, [24]

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{a_t - f_t}{a_t} \right|$$

Keterangan :

$a_t$  : Data sebenarnya

$f_t$  : Data hasil peramalan

$t : 1, 2, \dots n$

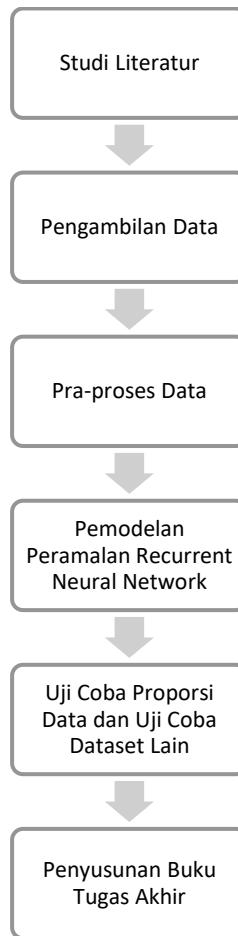
$n$  : Banyaknya data peramalan

*Halaman ini sengaja dikosongkan*

### BAB III

## METODOLOGI PENELITIAN

Bagian ini dijelaskan secara detail mengenai langkah-langkah sistematis penggerjaan penelitian tugas akhir. Setiap langkah yang telah dibuat akan digunakan sebagai pedoman agar penggerjaan tugas akhir berjalan sesuai dengan runtutan yang benar. Metode penggerjaan dapat dilihat pada Gambar 3.1.



**Gambar 0.1 Alur metode penggerjaan tugas akhir**

### **3.1. Studi Literatur**

Studi literatur dilakukan untuk mengumpulkan teori maupun mendapatkan informasi yang bersumber dari *paper*, buku, atau jurnal terkait serta situs-situs terpercaya di *internet* sebagai penunjang penelitian tugas akhir. Studi literatur yang didapatkan harus memiliki hubungan dengan permasalahan yang akan diteliti solusinya pada penelitian tugas akhir. Teori yang berkaitan dengan penelitian tugas akhir ialah investasi, harga emas dunia, harga minyak dunia, ekonomi makro, peramalan dan *recurrent neural network* serta uji akurasi model peramalan.

### **3.2. Pengambilan Data**

Tahap pengambilan data ditentukan data yang akan diproses untuk menyelesaikan penelitian tugas akhir. Data yang dibutuhkan yaitu data harga emas dunia dan data harga minyak dunia (*Crude Oil West Texas Intermediate (WTI)*). Masing-masing data diunduh mulai dari data historis tanggal 1 Januari 2014 sampai dengan 1 Januari 2019 dalam periode waktu skala harian. Data harga emas dunia yang berhasil diunduh sebanyak 1321 baris data dan data harga minyak dunia 1317 baris data. Semua data diperoleh secara *online* melalui situs [investing.com](http://investing.com).

### **3.3. Praproses Data**

Praproses data perlu dilakukan filtering agar data layak digunakan dan data lebih terstruktur ketika akan dilakukan tahap pemrosesan selanjutnya. Pada data yang diperoleh masih terdapat nilai yang tidak konsisten, nilai yang hilang (*missing value*), format nilai tidak sama/setara. *Cleaning data* perlu dilakukan untuk mengurangi ketidak sempurnaan data. *Missing value* diatasi dengan mengisi nilai secara manual berdasarkan baris data sebelumnya.

Standardisasi data adalah menyamakan format antara data harga emas dunia dan harga minyak dunia. Hal ini dilakukan karena adanya perbedaan format tipe data yang dimiliki oleh dua data tersebut terutama pada variabel tanggal. Normalisasi data adalah mengubah tiap nilai pada variabel masukan menjadi skala 0 hingga 1. Normalisasi dilakukan apabila data tidak setara satu

sama lain. Setelah melalui proses *cleaning*, *missing value*, standarisasi dan normalisasi, data harga emas dunia dan data minyak dunia menjadi layak untuk digunakan sebagai dataset. Dataset terbagi menjadi data pelatihan (*training*) dan data pengujian (*testing*) yang masing-masing memiliki rasio 70% : 30%. Data *training* untuk melatih atau membangun model peramalan. Data *testing* untuk menguji model setelah proses melatih model peramalan selesai.

### 3.4. Pemodelan Peramalan Recurrent Neural Network

Pada tahapan ini dilakukan pembuatan model peramalan *recurrent neural network* (RNN) untuk melakukan peramalan harga emas. Persamaan model peramalan RNN yang akan digunakan, yaitu :

$$y_{t+1} = f(y_t, \dots, y_{t-h}; x_t; \theta)$$

Keterangan :

$y_{t+1}$  : Hasil dari fungsi *hidden state* sebelumnya

$x_t$  : Masukan data

$\theta$  : Parameter yang diikutsertakan

$f$  : Fungsi aktivasi *non-linear*

Pembuatan model RNN dilakukan dengan menetapkan nilai dari parameter yang digunakan untuk Membantu peramalan. Parameter pembelajaran yang dibutuhkan yaitu :

- *Epoch*

Parameter *epoch* adalah jumlah iterasi yang digunakan dalam model RNN. Jumlah *epoch* yang digunakan sebanyak 100 iterasi pada setiap model RNN.

- *Momentum*

Parameter *momentum* mendefinisikan kemiringan batas kesalahan maksimal yang boleh dihasilkan model peramalan. Skala *momentum* yang digunakan antara 0.1 hingga 0.9 pada model peramalan.

- *Learning rate*

Parameter *learning rate* merupakan lama proses pembelajaran model peramalan untuk setiap iterasi. Skala penentuan *learning rate* yang digunakan antara 0.1 hingga 0.9. [25]

- *Hidden layer*

Parameter *hidden layer* merupakan unit-unit yang tersembunyi dimana luarannya tidak dapat diamati secara langsung. *Hidden layer* terletak di antara lapis masukan dan lapis luaran yang dapat terdiri atas beberapa lapisan tersembunyi. Jumlah *hidden layer* yang digunakan untuk proses pembelajaran model peramalan sebanyak  $n$ -*input* sampai dengan  $3n$ -*input*.

- *Sigmoid*

Parameter *sigmoid* digunakan sebagai fungsi aktivasi dalam proses pembelajaran model peramalan. Jenis fungsi aktivasi yang dipilih adalah *sigmoid logistic* dan *sigmoid gompertz*.

- *Rule*

Parameter *rule* digunakan sebagai *optimizer* atau fungsi pembantu dalam menentukan bobot yang lebih tepat sehingga dapat mengurangi jumlah *trial and error* secara drastis saat melakukan proses pembelajaran model peramalan. *Optimizer* yang digunakan sebagai proses pembelajaran model peramalan ialah *sgd* (*stochastic gradient descent*) dan *adagard* (*adaptive gradient*).

Kombinasi parameter yang berbeda menghasilkan model yang berbeda pula. Setiap model tersebut dilakukan pembelajaran menggunakan data pelatihan. Hasil luaran dari pembelajaran didenormalisasi untuk mengembalikan angka yang sebenarnya.

### **3.5. Uji Coba Proporsi Data dan Uji Coba Dataset Lain**

Pada tahap ini model pembelajaran terbaik di setiap variabel *univariate* dan *multivariate* diuji menggunakan proporsi data yang berbeda antara lain 50:50, 60:40 dan 80:20. Model terbaik ini juga akan diujikan pada jenis data yang berbeda.

### **3.6. Penyusunan Buku Tugas Akhir**

Tahap terakhir dari penelitian ini adalah penyusunan buku tugas akhir. Buku tugas akhir berisi dokumentasi proses penelitian secara rinci mulai dari awal sampai akhir sehingga analisa didapat dengan menarik kesimpulan.

## BAB IV

### PERANCANGAN

Pada bab ini akan menguraikan rancangan dari luaran penelitian tugas akhir ini. Perancangan yang dibuat berupa rancangan pengambilan data, rancangan pra-proses data, dan rancangan model peramalan *recurrent neural network* (RNN).

#### 4.1. Pengambilan Data

Tahap awal pada perancangan dimulai dengan mengunduh data historis harga emas dan data harga minyak yang dibutuhkan dari website investing.com. Pengambilan data dilakukan dengan cara mengunduh data historis harga emas di website investing.com (Gambar 4.1).

The screenshot shows the Investing.com homepage with a search bar at the top. Below it is a navigation menu with links to Markets, News, Analysis, Charts, Technical, Brokers, Tools, Portfolio, and Education. A secondary navigation bar below the main menu includes links for Commodities, Real Time Commodities, Metals, Softs, Meats, Energy, Grains, Commodity Indices, and a search icon.

The main content area displays information for "Gold Futures - Feb 20 (GCGO)". It shows the current price as **1,567.35**, which has decreased by **-2.45 (-0.16%)** from the previous close. The time is listed as 02:46:05. There are buttons for "Add to Portfolio" and "Create Alert".

Below this, there is a summary of the day's range: Prev. Close: **1,569.80**, Open: **1,565.40**, Day's Range: **1,562.35 - 1,569.10**. A "Start Trading" button is visible, along with an "AD" indicator.

The "General" tab is selected in the navigation bar. Under "Historical Data", the "Gold Futures Historical Data" section is shown. It includes a "Time Frame" dropdown set to "Daily", a "Download Data" button, and a date range from 12/29/2019 to 01/29/2020. A table displays historical data for four dates in January 2020:

Date	Price	Open	High	Low	Vol.	Change %
Jan 29, 2020	1,567.45	1,567.65	1,568.25	1,562.35	-	-0.00%
Jan 28, 2020	1,567.50	1,580.30	1,582.15	1,564.60	-	-0.63%
Jan 27, 2020	1,577.40	1,580.50	1,588.40	1,575.30	398.06K	-0.29%
Jan 26, 2020	1,581.95	1,571.65	1,588.10	1,571.65	-	0.64%

At the bottom of the historical data section, there are social media sharing icons for Facebook, Twitter, LinkedIn, and Email.

Gambar 0.1 Salah satu tampilan website investing.com

Data yang dibutuhkan ialah harga emas dunia dan data harga minyak dunia (*Crude Oil West Texas Intermediate (WTI)*). Masing-masing data diunduh mulai dari data historis tanggal 1 Januari 2014 sampai dengan 1 Januari 2019. Semua data diperoleh secara *online* melalui *website* investing.com. Data-data yang diperoleh memiliki periode waktu dengan skala harian.

## 4.2. Praproses Data

Pada tahap ini dilakukan beberapa langkah seperti pemilihan data, pencarian *missing value*, *cleaning data*, pembagian data, hingga data siap digunakan dalam model peramalan.

### 4.2.1. Pemilihan Data

Tahapan pemilihan data dilakukan untuk memilih kolom data mana yang dibutuhkan dalam proses peramalan harga emas menggunakan *recurrent neural network*. Data historis yang diunduh dari *website* investing.com memiliki tujuh kolom yaitu *date, price, open, high, low, volume, change*. Proses peramalan ini hanya memanfaatkan kolom *date* dan *price*. *Date* mewakilkan kolom tanggal sesuai dengan harga pada saat itu. *Price* merupakan kolom harga yang ditutup pada hari tersebut.

### 4.2.2. Pencarian Missing Value

Data historis yang diperoleh belum sepenuhnya sempurna dan tidak dapat langsung digunakan dalam pemodelan peramalan. Data historis yang telah melalui proses pemilihan data selanjutnya dicari baris data yang belum lengkap. Pencarian dilakukan dengan menambahkan kolom baru, *day* untuk mengetahui hari apa saja yang terdapat dalam data. Penambahan kolom *day* berguna untuk mengetahui hari yang terlewatkan selama lima hari kerja (Senin, Selasa, Rabu, Kamis, Jumat) dalam seminggu.

### 4.2.3. Cleaning Data

Tahap *cleaning data* ialah melakukan penambahan dan pengurangan baris data historis. Penambahan baris diperlukan apabila terdapat susunan lima hari kerja yang terlewatkan. Pengurangan baris menghapus hari yang tidak digunakan dalam

proses pembelajaran peramalan seperti hari Sabtu dan Minggu. Pengurangan kolom yang tidak digunakan dalam proses pelatihan peramalan seperti kolom *open, high, low, volume*, dan *change*.

#### **4.2.4. Pembagian Data**

Tahap pembagian data diperlukan untuk menentukan data yang akan dijadikan data pelatihan (*training data*) dan data pengujian (*testing data*). Pada penelitian tugas akhir ini, pembagian data menggunakan perbandingan 70% : 30%, masing-masing untuk data pelatihan dan data pengujian.

Setelah melalui proses *cleaning, missing value*, standarisasi dan normalisasi, sebanyak 1305 baris data harga emas dunia dan 1305 baris data minyak dunia yang layak digunakan sebagai dataset. Sebanyak 1305 baris data harga emas digabungkan dengan 1305 baris data minyak dunia berdasarkan tanggal yang sama menjadi dataset. Dataset terbagi menjadi data pelatihan (*training*) dan data pengujian (*testing*) yang masing-masing memiliki rasio 70% : 30%. 913 baris dataset yang dijadikan data *training* untuk melatih atau membangun model peramalan. 392 baris dataset yang dijadikan data *testing* untuk menguji model.

### **4.3. Pemodelan Peramalan *Recurrent Neural Network***

Pada tahap ini model pembelajaran diawali dengan menormalisasikan data, mengubah dataset menjadi matriks, membentuk model peramalan, denormalisasi hasil prediksi, menghitung MAPE (*Mean Absolute Percentage Error*) dan menyimpan hasil prediksi dalam bentuk CSV (*Comma Separated Values*).

#### **4.3.1. Normalisasi Data**

Sebelum data pelatihan dan data pengujian digunakan dalam proses peramalan terlebih dahulu dinormalisasikan menggunakan *library RSNNS (Stuttgart Neural Network Simulator)* yang tersedia pada aplikasi Rstudio. Normalisasi dibentuk berdasarkan rentang nilai 0 sampai dengan 1 agar data yang diproses dalam model peramalan tidak memiliki nilai yang terlalu besar.

### 4.3.2. Mengubah Dataset menjadi Matriks

Data pelatihan dan data pengujian yang telah dinormalisasi akan dibentuk menjadi matriks. Matriks akan bertambah sesuai dengan banyaknya *timestep* yang diperlukan. *Current timestep* (waktu saat ini) dan *previous timestep* (waktu sebelumnya) digunakan untuk mendefinisikan satu *timestep*. Setiap periode *timestep* dibentuk menjadi dua model berbeda berdasarkan variabel yang digunakan, *univariate* (satu variabel) dan *multivariate* (banyak variabel).

Variabel *univariate* menggunakan satu data harga emas dunia sedangkan variabel *multivariate* membutuhkan dua data, harga emas dunia dan harga minyak dunia. Banyaknya periode yang digunakan sebanyak 7 periode. Sebagai gambaran matriks yang akan terbentuk sebagai *input* pada model peramalan *univariate* maupun *multivariate* dapat dilihat dalam Tabel 4.1.

**Tabel 0.1 Matriks input yang terbentuk untuk 7 periode pada setiap variabel**

Periode	Univariate	Multivariate
1	[1:xgold <sub>(t-1)</sub> ]	[1:xgold <sub>(t-1)</sub> ] [1:xoil <sub>(t-1)</sub> ]
2	[1:xgold <sub>(t-2)</sub> ] [2:xgold <sub>(t-1)</sub> ]	[1:xgold <sub>(t-2)</sub> ] [2:xgold <sub>(t-1)</sub> ] [1:xoil <sub>(t-2)</sub> ] [2:xoil <sub>(t-1)</sub> ]
3	[1:xgold <sub>(t-3)</sub> ] [2:xgold <sub>(t-2)</sub> ] [3:xgold <sub>(t-1)</sub> ]	[1:xgold <sub>(t-3)</sub> ] [2:xgold <sub>(t-2)</sub> ] [3:xgold <sub>(t-1)</sub> ] [1:xoil <sub>(t-3)</sub> ] [2:xoil <sub>(t-2)</sub> ] [3:xoil <sub>(t-1)</sub> ]
4	[1:xgold <sub>(t-4)</sub> ] [2:xgold <sub>(t-3)</sub> ] [3:xgold <sub>(t-2)</sub> ] [4:xgold <sub>(t-1)</sub> ]	[1:xgold <sub>(t-4)</sub> ] [2:xgold <sub>(t-3)</sub> ] [3:xgold <sub>(t-2)</sub> ] [4:xgold <sub>(t-1)</sub> ] [1:xoil <sub>(t-4)</sub> ] [2:xoil <sub>(t-3)</sub> ] [3:xoil <sub>(t-2)</sub> ] [4:xoil <sub>(t-1)</sub> ]

5	$[1:xgold_{(t-5)}]$ $[2:xgold_{(t-4)}]$ $[3:xgold_{(t-3)}]$ $[4:xgold_{(t-2)}]$ $[5:xgold_{(t-1)}]$	$[1:xgold_{(t-5)}]$ $[2:xgold_{(t-4)}]$ $[3:xgold_{(t-3)}]$ $[4:xgold_{(t-2)}]$ $[5:xgold_{(t-1)}]$ $[1:xoil_{(t-5)}]$ $[2:xoil_{(t-4)}]$ $[3:xoil_{(t-3)}]$ $[4:xoil_{(t-2)}]$ $[5:xoil_{(t-1)}]$
6	$[1:xgold_{(t-6)}]$ $[2:xgold_{(t-5)}]$ $[3:xgold_{(t-4)}]$ $[4:xgold_{(t-3)}]$ $[5:xgold_{(t-2)}]$ $[6:xgold_{(t-1)}]$	$[1:xgold_{(t-6)}]$ $[2:xgold_{(t-5)}]$ $[3:xgold_{(t-4)}]$ $[4:xgold_{(t-3)}]$ $[5:xgold_{(t-2)}]$ $[6:xgold_{(t-1)}]$ $[1:xoil_{(t-6)}]$ $[2:xoil_{(t-5)}]$ $[3:xoil_{(t-4)}]$ $[4:xoil_{(t-3)}]$ $[5:xoil_{(t-2)}]$ $[6:xoil_{(t-1)}]$
7	$[1:xgold_{(t-7)}]$ $[2:xgold_{(t-6)}]$ $[3:xgold_{(t-5)}]$ $[4:xgold_{(t-4)}]$ $[5:xgold_{(t-3)}]$ $[6:xgold_{(t-2)}]$ $[7:xgold_{(t-1)}]$	$[1:xgold_{(t-7)}]$ $[2:xgold_{(t-6)}]$ $[3:xgold_{(t-5)}]$ $[4:xgold_{(t-4)}]$ $[5:xgold_{(t-3)}]$ $[6:xgold_{(t-2)}]$ $[7:xgold_{(t-1)}]$ $[1:xoil_{(t-7)}]$ $[2:xoil_{(t-6)}]$ $[3:xoil_{(t-5)}]$ $[4:xoil_{(t-4)}]$ $[5:xoil_{(t-3)}]$ $[6:xoil_{(t-2)}]$ $[7:xoil_{(t-1)}]$

Keterangan :

- $t$  : Jumlah periode waktu sesuai dengan proporsi data.
- $x_{gold_{(t-n)}}$  : Pengurangan sebanyak  $n$  waktu dari urutan waktu paling terakhir *dataset training* atau *testing* harga emas dunia sesuai dengan proporsi data.
- $x_{oil_{(t-n)}}$  : Pengurangan sebanyak  $n$  waktu dari urutan waktu paling terakhir *dataset training* atau *testing* harga minyak dunia sesuai dengan proporsi data.

#### 4.3.3. Pembentukan Model

Model dibentuk menggunakan dokumentasi yang tersedia di *library rnn*. Fungsi-fungsi yang diperlukan antara lain ialah *trainr* dan *predictr*. *Trainr* sebagai pembelajaran model peramalan, sedangkan *predictr* sebagai model untuk membuat prediksi. Pada *trainr* dibentuk pemodelan menggunakan kombinasi parameter *epoch*, *momentum*, *learning rate*, *hidden layer*, *sigmoid*, dan *rule*.

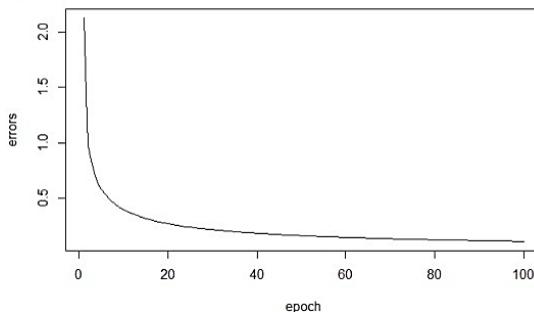
Parameter *epoch* digunakan untuk menentukan jumlah iterasi yang digunakan dalam model RNN. Parameter *momentum* mendefinisikan kemiringan batas kesalahan maksimal yang boleh dihasilkan model peramalan. Parameter *learning rate* merupakan kecepatan proses pembelajaran model peramalan untuk setiap iterasi. Parameter *hidden layer* merupakan unit-unit yang tersembunyi di antara lapis masukan dan lapis luaran serta tidak dapat diamati secara langsung. Banyak matriks yang terbentuk sebagai *input* pada model peramalan dinotasikan sebagai  $n$ . Parameter *sigmoid* digunakan sebagai fungsi aktivasi dalam proses pembelajaran model peramalan. Paramaeter *rule* digunakan sebagai *optimizer* atau fungsi pembantu dalam menentukan bobot yang lebih tepat sehingga dapat mengurangi jumlah *trial and error* secara drastis saat melakukan proses pembelajaran model peramalan.

Inisiasi ukuran setiap parameter diperlukan untuk membangun model peramalan. Inisiasi ukuran setiap parameter untuk peramalan bisa dilihat dalam Tabel 4.2.

**Tabel 0.2 Parameter untuk pelatihan model peramalan**

Paramater	Ukuran
<i>Epoch</i>	100
<i>Momentum</i>	0,1 – 0,9
<i>Learning rate</i>	0,1 – 0,9
<i>Hidden layer</i>	$n - 3n$
<i>Sigmoid</i>	<i>logistic</i> dan <i>gompertz</i>
<i>Rule</i>	<i>sgd</i> dan <i>adagrad</i>

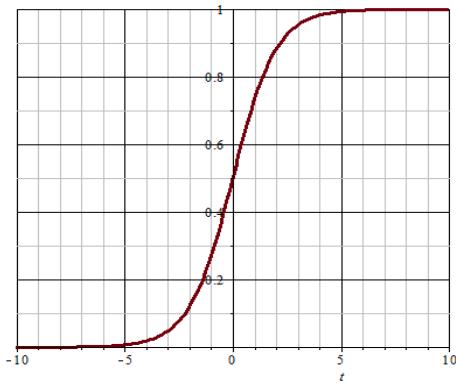
Ukuran nilai maksimum *epoch* ditentukan terlebih dahulu toleransi *error* yang dapat diterima model peramalan yang kemudian dilakukan hingga mencapai ambang titik tertentu atau konvergensi. Gambar 4.2 menunjukkan grafik yang konvergen terhadap *epoch* di angka 100. Sehingga maksimum *epoch* menggunakan 100 iterasi.

**Gambar 0.2 Grafik yang konvergen antara *errors* dengan *epoch***

*Sigmoid* pada model peramalan menggunakan fungsi yang sudah tersedia di R Documentation, yaitu *logistic* dan *gompertz*. *Sigmoid gompertz* adalah fungsi *sigmoid* yang menggambarkan pertumbuhan lambat pada periode tertentu. Model matematika deret waktu dari fungsi *sigmoid gompertz*,

$$\sigma_{\alpha,\beta}(t) = ae^{-\alpha e^{-\beta t}},$$

dimana  $\alpha$  merupakan asimtot positif ketika waktu mendekati  $+\infty$  [26]. Pertumbuhan *sigmoid gompertz* yang lambat bisa dilihat pada Gambar 4.3 yang menampilkan grafik dari fungsi *sigmoid gompertz*.

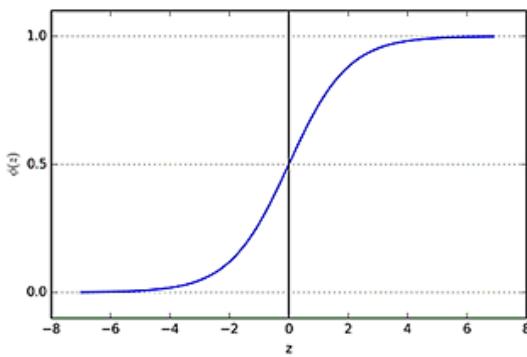


**Gambar 0.3 Grafik fungsi *sigmoid gompertz***

*Sigmoid logistic* memiliki keunggulan yaitu memetakan luaran dalam bentuk kisaran  $[0,1]$ , yang berguna untuk menekan *outlier* ke 0 atau 1. Model matematika dari fungsi *sigmoid gompertz logistic*, [27]

$$y = \sigma(z) = \frac{1}{1 + e^{-z}}$$

Nama lain dari *sigmoid logistic* bisa disebut dengan kurva *sigmoid* karena karakteristik kurva yang cenderung berbentuk S. Kurva *sigmoid* dapat dilihat pada Gambar 4.4.



**Gambar 0.4 Grafik fungsi *sigmoid logistic***

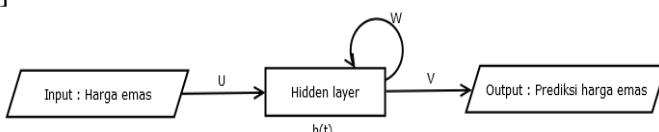
*Rule* pada model peramalan menggunakan *optimizer* yang sudah tersedia di *R Documentation*, yaitu menggunakan *sgd* dan

*adagrad*. *Stochastic Gradient Descent* (SGD) adalah algoritma pembelajaran iteratif yang menggunakan data *training* untuk memperbarui model. Algoritma ini bersifat iteratif yang artinya setiap langkah akan berusaha untuk sedikit meningkatkan parameter model. Setiap iterasi melibatkan penggunaan model dengan parameter saat itu untuk membuat prediksi pada beberapa data *training*, membandingkan prediksi dengan hasil yang diharapkan, menghitung kesalahan, dan menggunakan *error* untuk memperbarui parameter model [28]. *Adaptive Gradient* (AdaGrad) adalah algoritma turunan dari *sgd* yang menyesuaikan dengan tingkat pembelajaran dengan parameter dan pembaruan model yang lebih kecil. Namun, *adagrad* pada R *Documentation* masih dalam tahap pengembangan.

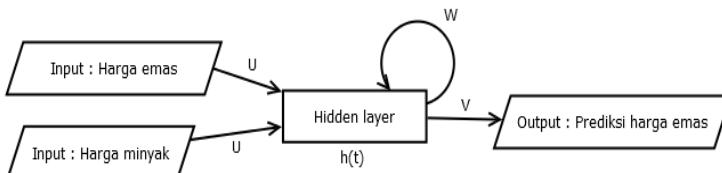
Sebagai gambaran umum dari arsitektur model RNN yang akan digunakan dalam penilitian tugas akhir dapat dilihat pada ilustrasi di Gambar 4.2 dan Gambar 4.3. Gambar 4.2 menunjukkan diagram sederhana dari arsitektur RNN yang menggunakan variabel harga emas saja sedangkan Gambar 4.3 diagram arsitektur RNN yang menggunakan variabel harga emas dan harga minyak. Keterangan notasi U mewakili bobot parameter antara *input* dengan *hidden layer*. Notasi V mewakili bobot parameter antara *hidden layer* dengan *output*. Notasi W mewakili bobot parameter antara *hidden layer* dengan *hidden layer* sebelumnya. Tidak seperti *neural network* lain yang identik dengan parameter yang berbeda setiap *layer*, RNN sebaliknya menyamakan semua parameternya. Notasi  $h(t)$  mewakili persamaan :

$$h(t) = f(Ux_{(t)}, Wh_{(t-1)}, b),$$

dimana  $h(t)$  ialah *hidden state* pada waktu ke-t tergantung *input* pada waktu ke-t ( $x_{(t)}$ ),  $f$  adalah fungsi aktivasi *non-linear*,  $h_{(t-1)}$  sebagai *hidden state* sebelumnya dan diinisiasi dari 0. [29]



Gambar 0.5 Arsitektur model RNN univariate



Gambar 0.6 Arsitektur model RNN multivariate

#### 4.3.4. Denormalisasi Hasil Prediksi

Sebelum menghitung MAPE antara data aktual dengan data prediksi, data-data tersebut dikembalikan ke bentuk sebelum dinormalisasi. Alasan data-data tersebut perlu denormalisasi karena data masih berupa nilai rentang antara 0 dan 1 sehingga data aktual dan data prediksi dapat dibandingkan menggunakan MAPE.

#### 4.3.5. Menghitung *Mean Absolute Percentage Error*

MAPE mengevaluasi perbandingan antara data aktual dengan data prediksi. Perbandingan tersebut mengindikasikan besaran eror setiap model-model pelatihan peramalan yang telah dibentuk dan dilatih. Model terbaik dipilih berdasarkan nilai MAPE terkecil.

#### 4.3.6. Menyimpan Hasil Prediksi

Data aktual dan data hasil prediksi yang telah didenormalisasi serta nilai MAPE disimpan dalam bentuk *file csv* (*comma separated values*) untuk mempermudah analisis dari model peramalan yang terbaik.

### 4.4. Uji Coba Proporsi Data dan Uji Coba Dataset Lain

Pada tahap ini mencari model pembelajaran terbaik pada setiap periode baik menggunakan variabel *univariate* maupun *multivariate*. Model tersebut diuji menggunakan proporsi data yang berbeda, yaitu 50:50, 60:40 dan 80:20. Selain itu, model juga akan diujikan pada harga komoditi Pasar Induk Kramat Jati mulai 1 September 2018 sampai dengan 31 Januari 2020 sehingga model bisa dikatakan layak digunakan untuk jenis data lainnya.

## BAB V

### IMPLEMENTASI

Pada bab ini, akan dijelaskan mengenai implementasi dari perancangan yang telah dilakukan sesuai dengan metode peramalan yang dibuat. Bagian implementasi akan menjelaskan mengenai persiapan implementasi, pengambilan data, praproses data, pemodelan peramalan *recurrent neural network* (RNN), dan uji coba proporsi data.

#### **5.1. Persiapan Implementasi**

Penelitian ini menggunakan perangkat keras dan lunak untuk membantu proses penggerjaan. Spesifikasi perangkat keras yang digunakan dapat dilihat pada Tabel 5.1.

**Tabel 0.1 Spesifikasi Perangkat Keras PC di Laboratorium RDIB**

<b>Nama Perangkat</b>	PC
<b>Processor</b>	AMD Ryzen 5 2600 Six-Core Processor 3.40 GHz
<b>Memory</b>	8.00 GB RAM
<b>Sistem Operasi</b>	Windows 10 Pro
<b>Arsitektur Sistem</b>	64-bit <i>Operating System, x64-based processor</i>

Aplikasi yang digunakan dalam proses peramalan ialah Rstudio dengan spesifikasi yang disajikan dalam Tabel 5.2.

**Tabel 0.2 Daftar Library**

<b>Bahasa Pemrograman</b>	R
<b>Antarmuka Bahasa Pemograman</b>	Rstudio
<b>Database</b>	Excel
<b>Library</b>	<ul style="list-style-type: none"> <li>• rnn</li> <li>• dplyr</li> <li>• tidyverse</li> <li>• Metrics</li> <li>• BBmisc</li> <li>• RSNNS</li> </ul>

## 5.2. Pengambilan Data

Pengambilan data harga emas dan data harga minyak dunia (*Crude Oil West Texas Intermediate (WTI)*) diunduh melalui situs daring investing.com. Data-data tersebut disimpan dalam bentuk *file excel*.

## 5.3. Praproses Data

Pada tahap ini dilakukan persiapan data sebelum digunakan dalam pembelajaran model peramalan. Terdapat beberapa langkah dalam mempersiapkan data seperti pemilihan data, pencarian *missing value*, *cleaning data*, pembagian data, hingga data siap digunakan dalam pembelajaran model peramalan.

### 5.3.1. Pemilihan Data

Pada data harga emas dunia dan data harga minyak dunia masing-masing mempunyai lima variabel yaitu *date*, *open*, *high*, *low*, dan *price*. Hanya variabel *date* dan *price* yang digunakan dalam pembelajaran model peramalan karena variabel lain memiliki korelasi yang kuat satu sama lainnya.

### 5.3.2. Pencarian Missing Value

Pencarian *missing value* pada harga emas dunia dan data harga minyak dunia dilakukan dengan mudah menggunakan aplikasi Ms. Excel. *Missing value* dilakukan dengan mencari periode waktu pada data harga yang tidak lengkap berdasarkan lima hari kerja dalam seminggu (Senin, Selasa, Rabu, Kamis, Jumat). Penambahan kolom *day* diperlukan untuk membantu melihat hari-hari yang terlewat pada masing-masing data seperti Tabel 5.3. Pada data harga emas dunia dibutuhkan empat baris tambahan pada hari Jumat sedangkan data harga minyak dunia dibutuhkan enam baris tambahan pada hari yang sama.

**Tabel 0.3 Penambahan kolom day untuk melihat hari yang terlewatkan**

Date	Price	Day
13-Apr-18	1,406.60	Friday
12-Apr-18	1,400.30	Thursday
11-Apr-18	1,418.90	Wednesday
10-Apr-18	1,404.40	Tuesday
9-Apr-18	1,398.50	Monday
6-Apr-18	1,394.80	Friday
5-Apr-18	1,387.00	Thursday
4-Apr-18	1,398.60	Wednesday
3-Apr-18	1,395.40	Tuesday
2-Apr-18	1,404.70	Monday
29-Mar-18	1,384.90	Thursday
28-Mar-18	1,387.80	Wednesday
27-Mar-18	1,406.70	Tuesday
26-Mar-18	1,419.90	Monday
23-Mar-18	1,413.90	Friday
22-Mar-18	1,391.10	Thursday
21-Mar-18	1,385.50	Wednesday
20-Mar-18	1,375.10	Tuesday
19-Mar-18	1,380.60	Monday
16-Mar-18	1,375.20	Friday
15-Mar-18	1,380.60	Thursday
14-Mar-18	1,388.60	Wednesday
13-Mar-18	1,390.30	Tuesday
12-Mar-18	1,383.70	Monday

### 5.3.3. Cleaning Data

Data-data harga yang tidak lengkap berdasarkan lima hari kerja ditambahkan dengan menduplikasi nilai berdasarkan tanggal sehari sebelumnya. Pengurangan baris diperlukan untuk menghapus hari yang tidak digunakan dalam proses peramalan seperti hari Sabtu dan Minggu. Pada data harga emas dunia ditemukan 19 hari Minggu sedangkan data harga minyak dunia ditemukan 17 hari Minggu seperti yang disajikan di Tabel 5.4.

**Tabel 0.4 Pengurangan baris hari Minggu (blok merah)**

Date	Price	Day
20-Jan-17	1,266.90	Friday
19-Jan-17	1,263.20	Thursday
18-Jan-17	1,273.40	Wednesday
17-Jan-17	1,275.10	Tuesday
16-Jan-17	1,202.85	Monday
15-Jan-17	1,203.35	Sunday
13-Jan-17	1,259.00	Friday
12-Jan-17	1,261.00	Thursday
11-Jan-17	1,257.70	Wednesday
10-Jan-17	1,246.20	Tuesday
9-Jan-17	1,245.30	Monday
6-Jan-17	1,233.40	Friday
5-Jan-17	1,239.80	Thursday
4-Jan-17	1,224.80	Wednesday
3-Jan-17	1,222.40	Tuesday
2-Jan-17	1,151.05	Monday
30-Dec-16	1,212.20	Friday
29-Dec-16	1,218.90	Thursday
28-Dec-16	1,201.70	Wednesday
27-Dec-16	1,199.60	Tuesday
26-Dec-16	1,134.55	Monday
25-Dec-16	1,135.00	Sunday
23-Dec-16	1,194.50	Friday
22-Dec-16	1,191.50	Thursday

### 5.3.4. Pembagian Data

Pembagian dataset mencakup data harga emas dan data harga minyak dengan perbandingan 70% : 30%, masing-masing untuk data pelatihan dan data pengujian. Pembagian dataset sebesar 70% (0.7) ditunjukkan pada Kode 5.1 menghasilkan 913 baris data *training* untuk melatih model.

```
train_size <- nrow(dataset)*0.7
train <- dataset[0:train_size,]
test <- dataset[-(0:train_size),]
```

**Kode 0.1 Proses pembagian data training dan data testing**

Keterangan Kode 5.1 dijelaskan pada Tabel 5.5.

**Tabel 0.5 Penjelasan dari Kode 5.1**

Atribut	Penjelasan
train_size	Jumlah baris yang dikembalikan
nrow	Fungsi untuk mengembalikan jumlah baris dalam <i>dataframe</i> atau matriks data
train	Data <i>training</i>
test	Data <i>testing</i>
dataset	Data keseluruhan mencakup data harga emas dan data harga minyak
dataset[0:train_size , ]	Baris <i>dataset</i> yang dikembalikan sesuai dengan jumlah <i>train_size</i>
dataset[-(0:train_size), ]	Baris <i>dataset</i> yang dikembalikan dari sisa jumlah <i>train_size</i>

### 5.4. Pemodelan Peramalan *Recurrent Neural Network*

Pada tahap ini menjelaskan kode yang digunakan untuk menormalisasikan data, mengubah dataset menjadi matriks, membentuk model peramalan, denormalisasi hasil prediksi, menghitung MAPE (*Mean Absolute Percentage Error*) dan menyimpan hasil prediksi dalam bentuk CSV (*Comma Separated Values*) dalam bahasa R.

#### 5.4.1. Normalisasi Data

Penggunaan *normalizeData()* di *library RSNNS* diperlukan untuk normalisasi min-max data *training* dan data *testing*. Tipe

normalisasi dengan rentang nilai 0 sampai dengan 1 dapat dilakukan dengan menambahkan `type='0_1'`.

```
train_norm <- normalizeData(train[2:3], type = '0_1')
test_norm <- normalizeData(test[2:3], type = '0_1')
```

#### Kode 0.2 Proses normalisasi data training dan data testing

Keterangan Kode 5.2 dijelaskan pada Tabel 5.6.

**Tabel 0.6 Penjelasan dari Kode 5.2**

Atribut	Penjelasan
<code>train_norm</code>	Data <i>training</i> yang telah dinormalisasi
<code>test_norm</code>	Data <i>testing</i> yang telah dinormalisasi
<code>normalizeData()</code>	Fungsi untuk menormalisasi nilai data
<code>train[2:3]/</code> <code>test[2:3]</code>	Data <i>training/testing</i> yang dinormalisasi hanya kolom 2 (data harga emas) dan kolom 3 (data harga minyak)
<code>type = '0_1'</code>	Atribut pada <code>normalizeData</code> untuk menentukan jenis normalisasi yang digunakan yaitu '0_1', maka nilai data dinormalisasi ke interval [0, 1]

#### 5.4.2. Mengubah Dataset Menjadi Matriks

Data pelatihan dan data pengujian yang telah dinormalisasi diubah dari *dataframe* menjadi matriks menggunakan Kode 5.3 dan Kode 5.4. Pengubahan data tersebut berguna untuk menyamakan definisi *input* dan *output* pada fungsi `trainr()` dan `predictr()` yang memerlukan *array* berdimensi.

```
X <- as.matrix(train_norm[1:912, 1])
Y <- as.matrix(train_norm[2:913, 1])
X1 <- as.matrix(test_norm[1:391, 1])
Y1 <- as.matrix(test_norm[2:392, 1])
```

#### Kode 0.3 Proses mengubah dataset menjadi matriks untuk variabel *univariate*

```
X2 <- as.matrix(train_norm[1:912, c(1,2)])
Y2 <- as.matrix(train_norm[2:913, 1])
X3 <- as.matrix(test_norm[1:391, c(1,2)])
Y3 <- as.matrix(test_norm[2:392, 1])
```

#### Kode 0.4 Proses mengubah dataset menjadi matriks untuk variabel *multivariate*

Keterangan Kode 5.3 dan Kode 5.4 dijelaskan pada Tabel 5.7.

**Tabel 0.7 Penjelasan dari Kode 5.3 dan Kode 5.4**

Atribut	Penjelasan
X	Matriks dari normalisasi data <i>training</i> yang dijadikan <i>input</i> pada fungsi <code>trainr()</code> sesuai dengan periode susunan Tabel 4.1 pada kolom <i>univariate</i>
Y	Matriks dari normalisasi data <i>training</i> yang dijadikan <i>output</i> pada fungsi <code>trainr()</code>
X1	Matriks dari normalisasi data <i>testing</i> yang dijadikan <i>input</i> pada fungsi <code>predictr()</code> sesuai dengan susunan Tabel 4.1 pada kolom <i>univariate</i>
Y1	Matriks dari normalisasi data <i>testing</i> yang dijadikan <i>input</i> pada fungsi <code>denormalizeData()</code>
X2	Matriks dari normalisasi data <i>training</i> yang dijadikan <i>input</i> pada fungsi <code>trainr()</code> sesuai dengan periode susunan Tabel 4.1 pada kolom <i>multivariate</i>
Y2	Matriks dari normalisasi data <i>training</i> yang dijadikan <i>output</i> pada fungsi <code>trainr()</code>
X3	Matriks dari normalisasi data <i>testing</i> yang dijadikan <i>input</i> pada fungsi <code>predictr()</code> sesuai dengan susunan Tabel 4.1 pada kolom <i>multivariate</i>
Y3	Matriks dari normalisasi data <i>testing</i> yang dijadikan <i>input</i> pada fungsi <code>denormalizeData()</code>
<code>as.matrix()</code>	Fungsi untuk mengubah data menjadi bentuk matriks

### 5.4.3. Membentuk Model

Model peramalan RNN yang dibentuk pada Kode 5.5 menggunakan *library* yang sudah tersedia di R yaitu *library rnn*. *Library rnn* menyediakan `trainr()` berfungsi untuk melatih model dan `predictr()` untuk membuat prediksi. Fungsi `for()` untuk mengotomatiskan kode yang butuh diulang dalam suatu fungsi.

```

sigmoid <- c("logistic", "Gompertz")
rule <- c("sgd", "adagrad")
for (ii in 1:9) { i = ii/10
  for (jj in 1:9) { j = jj/10
    for (k in n:3n) {
      for (l in sigmoid) {
        for (m in rule) {
          start_time <- Sys.time()
          model <- trainr(Y, X, learningrate = i, momentum =
j, hidden_dim = k, numepochs = 100, network_type = "rnn",
sigmoid = l, use_bias = F, batch_size = 1, seq_to_seq_unsync =
T, update_rule = m, epoch_function = c(epoch_print,
epoch_annealing), loss_function = loss_L1)
          result <- predictr(model, X1, hidden = F,
real_output = T)
          end_time <- Sys.time()
          time_taken <- end_time - start_time }}}}}

```

#### Kode 0.5 Proses pembentukan model peramalan dengan parameter

Keterangan Kode 5.5 dijelaskan pada Tabel 5.8.

**Tabel 0.8 Penjelasan dari Kode 5.5**

Atribut	Penjelasan
sigmoid	Inisiasi <i>sigmoid</i>
rule	Inisiasi <i>optimizer</i>
for(ii in 1:9) {i = ii/10}	Perulangan untuk parameter <i>learning rate</i>
for(jj in 1:9) {j = jj/10}	Perulangan untuk parameter <i>momentum</i>
for(kk in n:3n)	Perulangan untuk parameter <i>hidden layer</i>
for (l in sigmoid)	Perulangan untuk parameter <i>sigmoid</i>
for (m in rule)	Perulangan untuk parameter <i>rule</i>
start_time	Menghitung awal waktu model untuk melakukan peramalan
end_time	Menghitung akhir waktu model untuk melakukan peramalan
Sys.time()	Fungsi mengembalikan nilai tanggal-waktu yang dapat dikonversi ke berbagai zona waktu
time_taken	Lama waktu yang diperlukan model melakukan peramalan dari awal hingga akhir
trainr()	Fungsi untuk melatih model yang berisi parameter-parameter

<code>numepochs = 100</code>	Jumlah iterasi yang digunakan sebanyak 100
<code>network_type = "rnn"</code>	Jenis <i>neural network</i> yang digunakan adalah RNN
<code>use_bias = F</code>	Penggunaan bias pada model RNN
<code>batch_size = 1</code>	Jumlah bobot yang digunakan pada setiap iterasi namun hanya 1 yang didukung oleh R
<code>seq_to_seq_unsync = T</code>	Jika diatur TRUE, maka <i>neural network</i> akan dilatih dengan <i>backpropagate</i>
<code>epoch_function = c(epoch_print, epoch_annealing)</code>	Digunakan sebagai interaksi dari objek dalam model
<code>predictr()</code>	Fungsi untuk memprediksi <i>output</i> dari model
<code>hidden = F</code>	Atribut untuk mengeluarkan <i>hidden units states</i>
<code>real_output = T</code>	Atribut dengan <i>default</i> TRUE yang berfungsi untuk menjaga data hasil prediksi

#### 5.4.4. Denormalisasi

Denormalisasi digunakan untuk mengembalikan data aktual dan data prediksi ke bentuk data sebelum dinormalisasi. Data-data yang telah didenormalisasi di Kode 5.6 akan mempermudah keakuratan perhitungan MAPE pada Kode 5.7.

```
denom_predict <- denormalizeData(result,
                                    getNormParameters(test_norm))
denom_actual <- denormalizeData(Y3,
                                   getNormParameters(test_norm))
```

**Kode 0.6** Proses denormalisasi data aktual dan data hasil prediksi

Keterangan Kode 5.6 dijelaskan pada Tabel 5.9.

**Tabel 0.9 Penjelasan dari Kode 5.6**

<b>Atribut</b>	<b>Penjelasan</b>
<code>denom_predict</code>	Data prediksi ( <code>result</code> ) yang telah didenormalisasi
<code>denom_actual</code>	Data aktual ( <code>Y3</code> ) yang telah didenormalisasi

denormalizeData()	Fungsi mengembalikan nilai data kedalam bentuk semula sebelum dinormalisasi
getNormParameters	Atribut yang menggunakan data <i>test_norm</i> <i>normalizeData()</i> sebelumnya untuk mengembalikan normalisasi

#### 5.4.5. Menghitung MAPE (*Mean Absolute Percentage rror*)

MAPE dilakukan setelah data aktual dan data hasil prediksi telah didenormalisasi. Namun data aktual dan data hasil prediksi diubah terlebih dahulu menjadi vektor menggunakan *as.vector()*. Hal ini untuk menyamakan definisi *input* dan *output* pada fungsi *mape()* pada Kode 5.7.

```
comparison_test <- as.vector(denom_actual)
output <- as.vector(denom_predict)
eror <- mape(comparison_test, output)
```

**Kode 0.7** Proses menghitung MAPE antara data aktual dengan data prediksi

Keterangan Kode 5.7 dijelaskan pada Tabel 5.10.

**Tabel 0.10** Penjelasan dari Kode 5.7

Atribut	Penjelasan
comparison_test	Data aktual yang terdenormalisasi ( <i>denom_actual</i> ) diubah dari matriks ke bentuk vektor
output	Data prediksi yang terdenormalisasi ( <i>denom_predict</i> ) diubah dari matriks ke bentuk vektor
<i>as.vector()</i>	Fungsi yang mengubah data matriks menjadi data vektor
eror	Data nilai MAPE yang dihasilkan dari data <i>comparison_test</i> dengan <i>output</i>
<i>mape()</i>	Fungsi perhitungan MAPE dari <i>library Metrics</i>

#### 5.4.6. Menyimpan hasil prediksi

Pada Kode 5.8 digunakan untuk menyimpan data aktual dan hasil prediksi yang telah didenormalisasi terpisah dengan *file*

nilai MAPE. Penamaan *file* sangat penting untuk mempermudah analisis dari model peramalan yang terbaik serta sebagai dokumentasi penelitian tugas akhir.

```
mape_uni <- cbind(i, j, k, l, m, eror, time_taken)
write.table(mape_uni, "mape-multi-1.csv", row.names = F,
col.names = F, append = T, sep = ",")
predict_uni <- cbind(denom_actual, denom_predict)
form = sprintf('output_%s-%s-%s-%s.csv', i, j, k, l, m)
write.csv(predict_uni, file = form, row.names = F)
```

**Kode 0.8 Proses menyimpan data aktual, data hasil prediksi dan data nilai MAPE**

Keterangan Kode 5.8 dijelaskan pada Tabel 5.11.

**Tabel 0.11 Penjelasan dari Kode 5.8**

Atribut	Penjelasan
mape_uni	Format bentuk <i>dataframe</i> MAPE yang berisi kolom nilai MAPE yang dihasilkan sesuai dengan parameter yang digunakan beserta estimasi waktunya
cbind()	Fungsi menggabungkan kolom atau baris sesuai dengan urutan argumen
write.table()	Fungsi membuat tabel dari <i>dataframe</i>
“mape-multi-1.csv”	Nama <i>file</i> MAPE yang tersimpan
row.names = F	Atribut yang menambahkan karakter setiap baris <i>dataframe</i> MAPE
col.names = F	Atribut yang menambahkan karakter setiap kolom <i>dataframe</i> MAPE
append = T	Atribut yang menambahkan <i>string</i> pada nama <i>file</i> yang sama
sep = “,”	Atribut yang memisahkan setiap <i>string</i>
predict_uni	Format bentuk <i>dataframe</i> yang berisi kolom data aktual dan data prediksi
sprintf()	Fungsi mengembalikan karakter yang berisi kombinasi teks yang diatur sedemikian rupa
write.csv()	Fungsi untuk menyimpan <i>predict_uni</i> dalam bentuk csv

file = form	Atribut yang mengatur nama <i>file</i> sesuai dengan argumen
-------------	--

**5.5. Uji Coba Proporsi Data dan Uji Coba Dataset Lain**  
Uji coba model dilakukan menggunakan proporsi data dan jenis *dataset* yang berbeda pada setiap model pembelajaran terbaik. Proporsi data yang diujikan antara data pelatihan dan data pengujian dimulai dari 50:50, 60:40 dan 80:20. *Dataset* lain yang digunakan merupakan data harga Pasar Induk Kramat Jati mencakup harga bawang merah, cabe merah keriting, cabe merah besar, cabe rawit merah, dan cabe rawit hijau. *Dataset* diambil mulai dari periode 1 September 2018 sampai dengan 31 Januari 2020. Model dengan hasil MAPE paling kecil dipilih pada setiap *timestep* baik itu menggunakan variabel *univariate* maupun *multivariate*. Kode 5.9 sampai dengan Kode 5.12 terdapat notasi A – N yang menjadi bagian-bagian yang perlu diganti sesuai dengan proporsi data dan model terbaik yang akan digunakan.

```
train_size <- nrow(dataset)*A
```

**Kode 0.9 Pembagian data training dan data testing sesuai dengan proporsi data yang akan digunakan**

```
X <- as.matrix(train_norm[B, 1])
Y <- as.matrix(train_norm[C, 1])
X1 <- as.matrix(test_norm[D, 1])
Y1 <- as.matrix(test_norm[E, 1])
```

**Kode 0.10 Matriks data training dan data testing univariate sesuai dengan proporsi data yang akan digunakan**

```
X2 <- as.matrix(train_norm[F, c(1,2)])
Y2 <- as.matrix(train_norm[G, 1])
X3 <- as.matrix(train_norm[H, c(1,2)])
Y3 <- as.matrix(test_norm[I, 1])
```

**Kode 0.11 Matriks data training dan data testing multivariate sesuai dengan proporsi data yang akan digunakan**

```
sigmoid <- c(J)
rule <- c(K)
for (ii in L:L) { i = ii/10
  for (jj in M:M) { j = jj/10
    for (k in N:N) {
      for (l in sigmoid) {
        for (m in rule) { start_time <- Sys.time()
          model <- trainr(Y, X, learningrate = i, momentum =
j, hidden_dim = k, numepochs = 100, network_type = "rnn",
sigmoid = l, use_bias = F, batch_size = 1, seq_to_seq_unsync =
T, update_rule = m, epoch_function = c(epoch_print,
epoch_annealing), loss_function = loss_L1)
          result <- predictr(model, X1, hidden = F,
real_output = T)
          denom_predict <- denormalizeData(result,
getNormParameters(test_norm))
          denom_actual <- denormalizeData(Y1,
getNormParameters(test_norm))
          end_time <- Sys.time()
          time_taken <- end_time - start_time
```

**Kode 0.12 Model sesuai dengan model terbaik yang akan digunakan**

## **BAB VI**

### **HASIL DAN PEMBAHASAN**

Pada bab ini akan dijelaskan mengenai hasil uji coba dan analisis terhadap hasil yang diperoleh dari proses pembelajaran model peramalan menggunakan *Recurrent Neural Network* (RNN).

#### **6.1. Hasil Pengambilan Data**

Hasil implementasi pengambilan data yaitu mengetahui karakteristik harga emas dunia dan data harga minyak dunia (*Crude Oil West Texas Intermediate* (WTI)). Tabel 6.1 dan Tabel 6.2 menunjukkan masing-masing harga yang berhasil didapat dari investing.com.

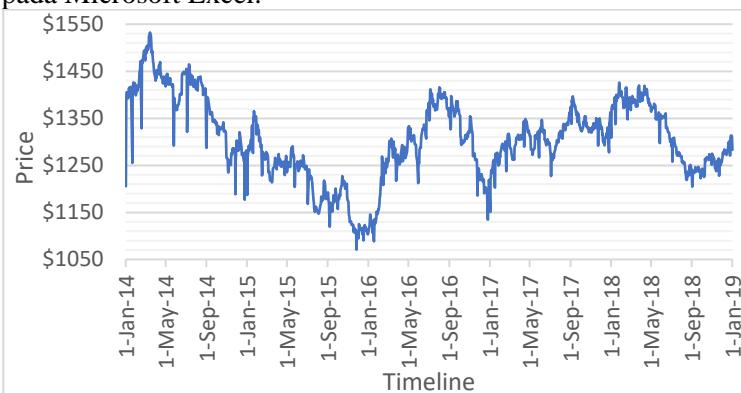
**Tabel 0.1 Contoh beberapa harga emas dunia yang berhasil disimpan**

Date	Price	Open	High	Low	Vol.	Change %
1-Jan-19	1,283.35	1,284.70	1,284.75	1,282.85	-	-2.22%
31-Dec-18	1,312.50	1,313.00	1,317.10	1,311.00	0.53K	-0.09%
28-Dec-18	1,313.70	1,311.00	1,313.90	1,309.20	0.62K	0.14%
27-Dec-18	1,311.90	1,304.00	1,312.30	1,300.30	0.21K	0.63%
26-Dec-18	1,303.70	1,299.00	1,312.80	1,298.70	0.26K	2.59%
25-Dec-18	1,270.75	1,272.50	1,274.55	1,270.65	-	-2.43%
24-Dec-18	1,302.40	1,292.50	1,303.80	1,292.50	0.16K	1.07%
21-Dec-18	1,288.60	1,295.50	1,295.50	1,287.90	0.43K	-0.77%
20-Dec-18	1,298.60	1,279.30	1,300.00	1,279.20	0.54K	0.92%
19-Dec-18	1,286.80	1,283.90	1,289.40	1,276.10	0.25K	0.22%
18-Dec-18	1,284.00	1,282.70	1,284.60	1,280.70	1.75K	0.11%
17-Dec-18	1,282.60	1,271.40	1,282.00	1,270.20	0.44K	0.82%
14-Dec-18	1,272.20	1,277.10	1,277.10	1,267.50	0.34K	-0.48%
13-Dec-18	1,278.40	1,281.20	1,281.90	1,276.90	0.16K	-0.20%
12-Dec-18	1,281.00	1,280.00	1,282.60	1,279.80	0.43K	0.23%
11-Dec-18	1,278.10	1,279.80	1,285.00	1,277.10	0.29K	-0.15%
10-Dec-18	1,280.00	1,283.80	1,283.80	1,279.60	0.68K	-0.28%
7-Dec-18	1,283.60	1,273.60	1,286.60	1,273.50	0.53K	0.73%
6-Dec-18	1,274.30	1,273.00	1,279.20	1,271.20	0.59K	0.07%
5-Dec-18	1,273.40	1,273.50	1,273.50	1,269.70	0.21K	-0.31%
4-Dec-18	1,277.40	1,271.00	1,277.50	1,271.00	0.27K	0.57%
3-Dec-18	1,270.20	1,260.60	1,271.00	1,260.30	0.18K	1.09%
30-Nov-18	1,256.50	1,257.40	1,257.70	1,255.30	0.26K	-0.34%
29-Nov-18	1,260.80	1,261.10	1,264.10	1,259.00	0.17K	0.05%

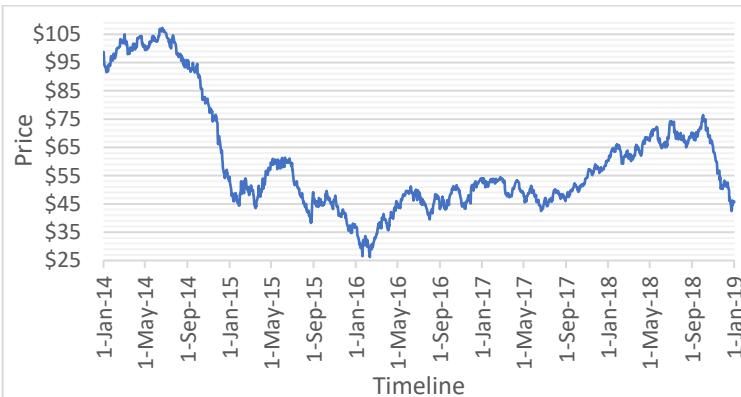
**Tabel 0.2 Contoh beberapa harga minyak dunia yang berhasil disimpan**

Date	Price	Open	High	Low	Vol.	Change %
1-Jan-19	45.89	45.77	45.95	45.73	-	1.06%
31-Dec-18	45.41	45.22	46.53	44.73	476.97K	0.18%
28-Dec-18	45.33	45.44	46.22	44.42	564.39K	1.61%
27-Dec-18	44.61	46.58	46.7	44.37	665.59K	-3.48%
26-Dec-18	46.22	42.85	47	42.52	698.41K	7.09%
25-Dec-18	43.16	43	43.25	42.88	-	1.48%
24-Dec-18	42.53	45.45	46.24	42.36	415.86K	-6.71%
21-Dec-18	45.59	46.25	46.77	45.13	694.00K	-0.63%
20-Dec-18	45.88	47.39	47.51	45.67	794.13K	-2.80%
19-Dec-18	47.2	45.93	48	45.93	37.16K	2.08%
18-Dec-18	46.24	49.16	49.59	45.79	120.10K	-7.30%
17-Dec-18	49.88	51.25	51.87	49.01	211.26K	-2.58%
14-Dec-18	51.2	52.83	52.95	50.84	526.84K	-2.62%
13-Dec-18	52.58	51.2	53.27	50.35	733.63K	2.80%
12-Dec-18	51.15	51.95	52.88	50.94	730.81K	-0.97%
11-Dec-18	51.65	50.89	52.43	50.7	665.26K	1.27%
10-Dec-18	51	52.03	52.81	50.53	733.23K	-3.06%
7-Dec-18	52.61	51.76	54.22	50.6	987.72K	2.18%
6-Dec-18	51.49	52.93	53.3	50.08	987.27K	-2.65%
5-Dec-18	52.89	52.59	54.44	52.16	624.91K	-0.68%
4-Dec-18	53.25	53.13	54.55	52.43	738.13K	0.57%
3-Dec-18	52.95	52.45	53.85	52.03	758.01K	3.97%

Visualisasi data harga emas dunia (Gambar 6.1) dan data harga minyak dunia (Gambar 6.2) menggunakan fungsi *chart line* pada Microsoft Excel.



**Gambar 0.1 Grafik fluktuasi harga emas dunia selama 5 tahun (Januari 2014 - Januari 2019)**



**Gambar 0.2 Grafik fluktuasi harga minyak dunia (WTI) selama 5 tahun (Januari 2014 - Januari 2019)**

## 6.2. Hasil Pra-Proses Data

Hasil implementasi pra-proses data menghasilkan penambahan dan pengurangan baris data pada data harga emas dan data harga minyak dunia. Pada Tabel 6.3 menampilkan perbandingan angka penambahan dan pengurangan baris di setiap data.

**Tabel 0.3 Perbandingan penambahan dan pengurangan baris data pada masing-masing data harga**

	Harga Emas	Harga Minyak
<b>Baris Data Awal</b>	1320	1316
<b>Penambahan Baris</b>	4	6
<b>Pengurangan Baris</b>	19	17
<b>Baris Data Akhir</b>	1305	1305
<b>Persentase (baris data awal : baris data akhir)</b>	98.86%	99.16%

## 6.3. Hasil Pemodelan Peramalan *Recurrent Neural Network* (RNN) dengan *Univariate*

Pemodelan RNN menggunakan proporsi data 70:30 menghasilkan model terbaik pada masing-masing periode dengan menggunakan satu variabel, *univariate*. Model terbaik yang dipilih berdasarkan nilai MAPE (*Mean Absolute Percentage Error*) terkecil.

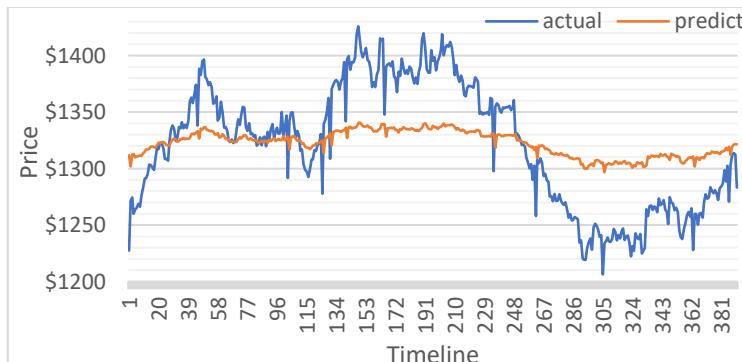
### 6.3.1. Hasil Pemodelan Peramalan RNN untuk Periode 1 dengan *Univariate*

Peramalan model menggunakan proporsi data 70:30 untuk periode 1 dengan variabel *univariate* menghasilkan data berupa nilai MAPE dan data prediksi. Pada Tabel 6.4 menunjukkan sebagian nilai MAPE yang telah diurutkan paling kecil hingga terbesar dari keseluruhan data nilai MAPE untuk periode 1 dengan variabel *univariate*.

**Tabel 0.4 Urutan 10 MAPE terkecil pada periode 1 variabel *univariate***

learning rate	momentum	hidden layer	sigmoid	rule	eror	time taken
0.5	0.9	3	Gompertz	sgd	283.643%	42.00883794
0.8	0.3	3	Gompertz	adagrad	312.916%	42.31083679
0.2	0.3	1	Gompertz	sgd	316.883%	40.71094704
0.2	0.5	2	Gompertz	adagrad	320.749%	41.49132395
0.5	0.7	1	Gompertz	adagrad	321.109%	42.08403921
0.3	0.9	2	Gompertz	adagrad	321.664%	38.72706103
0.5	0.1	1	Gompertz	adagrad	321.755%	41.37957001
0.7	0.4	2	Gompertz	adagrad	321.821%	41.85956097
0.8	0.8	3	Gompertz	sgd	322.534%	42.21237397
0.9	0.4	2	logistic	adagrad	323.801%	42.23574305

Dari tabel tersebut menunjukkan nilai MAPE terkecil sebesar 283,643%. Model yang memiliki nilai MAPE terkecil menggunakan parameter *learning rate* 0.5, *momentum* 0.9, *hidden layer* sebanyak 3 dimensi, *sigmoid* dengan *Gompertz*, dan *rule* dengan *sgd*. Gambar 6.3 menunjukkan grafik perbandingan antara data aktual dengan data hasil peramalan menggunakan model dari nilai MAPE terkecil.



**Gambar 0.3 Grafik antara data aktual dengan data hasil peramalan *univariate* periode 1**

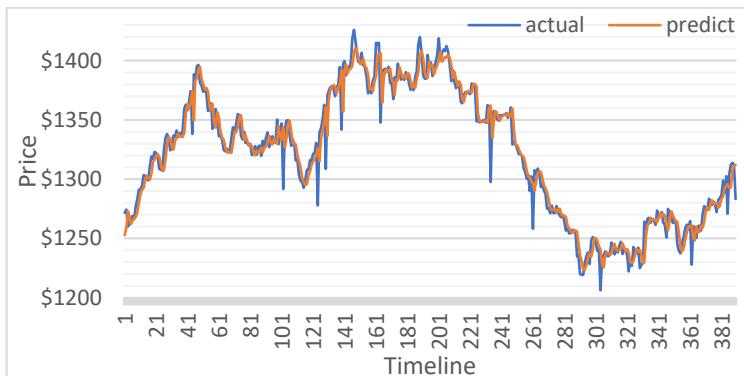
### 6.3.2. Hasil Pemodelan Peramalan RNN untuk Periode 2 dengan *Univariate*

Peramalan model menggunakan proporsi data 70:30 untuk periode 2 dengan variabel *univariate* menghasilkan data berupa nilai MAPE dan data prediksi. Pada Tabel 6.5 menunjukkan sebagian nilai MAPE yang telah diurutkan paling kecil hingga terbesar dari keseluruhan data nilai MAPE untuk periode 2 dengan variabel *univariate*.

**Tabel 0.5 Urutan 10 MAPE terkecil pada periode 2 variabel *univariate***

learning rate	momentum	hidden layer	sigmoid	rule	eror	time taken (secs)
0.9	0.9	3	Gompertz	sgd	62.447%	46.02754188
0.9	0.7	6	Gompertz	sgd	63.606%	51.30676889
0.9	0.9	5	Gompertz	sgd	64.380%	46.55644202
0.7	0.9	4	Gompertz	sgd	64.673%	48.89062119
0.8	0.7	5	Gompertz	sgd	64.867%	50.08033895
0.8	0.7	4	Gompertz	sgd	64.970%	49.27115417
0.7	0.9	6	Gompertz	sgd	64.975%	50.06353903
0.8	0.9	6	Gompertz	sgd	65.028%	50.8285079
0.7	0.8	5	Gompertz	sgd	65.114%	49.62034392
0.9	0.7	5	Gompertz	sgd	65.136%	49.30054879

Dari tabel tersebut menunjukkan nilai MAPE terkecil sebesar 62,447%. Model yang memiliki nilai MAPE terkecil menggunakan parameter *learning rate* 0.9, *momentum* 0.9, *hidden layer* sebanyak 3 dimensi, *sigmoid* dengan *Gompertz*, dan *rule* dengan *sgd*. Gambar 6.4 menunjukkan grafik perbandingan antara data aktual dengan data hasil peramalan menggunakan model dari nilai MAPE terkecil.



**Gambar 0.4 Grafik data aktual dengan data hasil peramalan *univariate* periode 2**

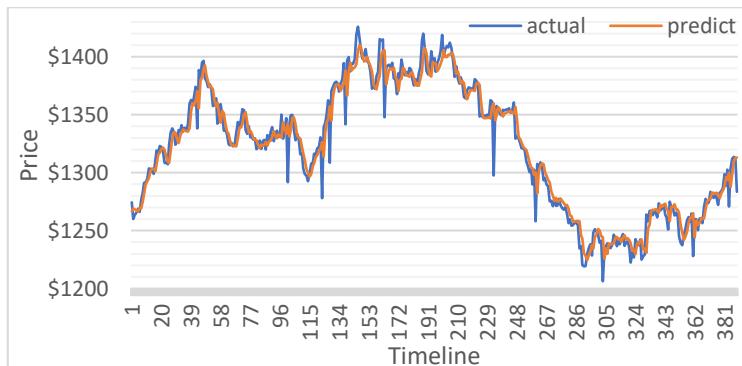
### 6.3.3. Hasil Pemodelan Peramalan RNN untuk Periode 3 dengan *Univariate*

Peramalan model menggunakan proporsi data 70:30 untuk periode 3 dengan variabel *univariate* menghasilkan data berupa nilai MAPE dan data prediksi. Pada Tabel 6.6 menunjukkan sebagian nilai MAPE yang telah diurutkan paling kecil hingga terbesar dari keseluruhan data nilai MAPE untuk periode 3 dengan variabel *univariate*.

**Tabel 0.6 Urutan 10 MAPE terkecil pada periode 3 variabel *univariate***

learning rate	momentum	hidden layer	sigmoid	rule	eror	time taken (secs)
0.9	0.8	8	Gompertz	sgd	62.771%	50.25427008
0.9	0.9	9	Gompertz	sgd	63.078%	51.82362103
0.9	0.9	3	Gompertz	sgd	64.274%	47.30247593
0.9	0.9	8	logistic	sgd	64.392%	50.85379004
0.8	0.9	5	Gompertz	sgd	64.460%	48.94350719
0.9	0.9	7	logistic	sgd	64.675%	49.58411813
0.9	0.7	8	Gompertz	sgd	64.968%	50.77438617
0.7	0.9	8	Gompertz	sgd	65.024%	49.92569017
0.9	0.9	9	logistic	sgd	65.670%	51.53555703
0.9	0.9	6	Gompertz	sgd	65.678%	48.96197891

Dari tabel tersebut menunjukkan nilai MAPE terkecil sebesar 62,771%. Model yang memiliki nilai MAPE terkecil menggunakan parameter *learning rate* 0.9, *momentum* 0.8, *hidden layer* sebanyak 8 dimensi, *sigmoid* dengan *Gompertz*, dan *rule* dengan *sgd*. Gambar 6.5 menunjukkan grafik perbandingan antara data aktual dengan data hasil peramalan menggunakan model dari nilai MAPE terkecil.



**Gambar 0.5 Grafik data aktual dengan data hasil peramalan *univariate* periode 3**

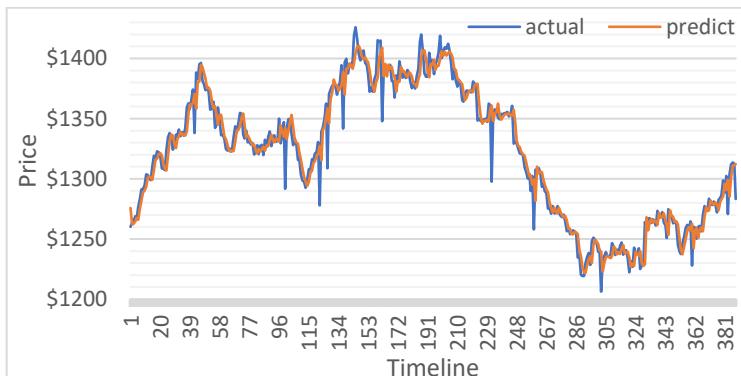
### 6.3.4. Hasil Pemodelan Peramalan RNN untuk Periode 4 dengan *Univariate*

Peramalan model menggunakan proporsi data 70:30 untuk periode 4 dengan variabel *univariate* menghasilkan data berupa nilai MAPE dan data prediksi. Pada Tabel 6.7 menunjukkan sebagian nilai MAPE yang telah diurutkan paling kecil hingga terbesar dari keseluruhan data nilai MAPE untuk periode 4 dengan variabel *univariate*.

**Tabel 0.7 Urutan 10 MAPE terkecil pada periode 4 variabel *univariate***

learning rate	momentum	hidden layer	sigmoid	rule	eror	time taken (secs)
0.9	0.8	9	Gompertz	sgd	61.351%	60.61573245
0.9	0.9	10	Gompertz	sgd	61.516%	60.60086242
0.9	0.9	5	Gompertz	sgd	62.246%	60.51929395
0.8	0.9	9	Gompertz	sgd	62.251%	52.7188859
0.9	0.9	9	Gompertz	sgd	62.453%	60.58367535
0.9	0.9	7	Gompertz	sgd	62.786%	60.55006755
0.9	0.9	12	Gompertz	sgd	63.311%	60.64959011
0.9	0.8	7	Gompertz	sgd	64.336%	60.57829062
0.9	0.8	8	Gompertz	sgd	64.643%	60.59336072
0.9	0.4	5	Gompertz	sgd	64.833%	50.68848395

Dari tabel tersebut menunjukkan nilai MAPE terkecil sebesar 61,351%. Model yang memiliki nilai MAPE terkecil menggunakan parameter *learning rate* 0.9, *momentum* 0.8, *hidden layer* sebanyak 9 dimensi, *sigmoid* dengan *Gompertz*, dan *rule* dengan *sgd*. Gambar 6.6 menunjukkan grafik perbandingan antara data aktual dengan data hasil peramalan menggunakan model dari nilai MAPE terkecil.



**Gambar 0.6 Grafik data aktual dengan data hasil peramalan *univariate* periode 4**

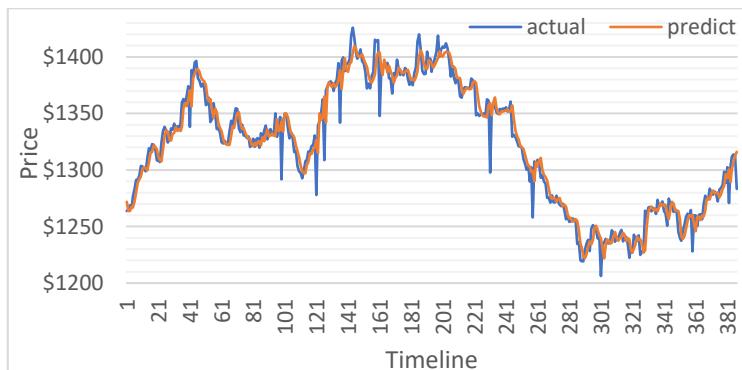
### 6.3.5. Hasil Pemodelan Peramalan RNN untuk Periode 5 dengan *Univariate*

Peramalan model menggunakan proporsi data 70:30 untuk periode 5 dengan variabel *univariate* menghasilkan data berupa nilai MAPE dan data prediksi. Pada Tabel 6.8 menunjukkan sebagian nilai MAPE yang telah diurutkan paling kecil hingga terbesar dari keseluruhan data nilai MAPE untuk periode 5 dengan variabel *univariate*.

**Tabel 0.8 Urutan 10 MAPE terkecil pada periode 5 variabel *univariate***

learning rate	momentum	hidden layer	sigmoid	rule	eror	time taken (secs)
0.9	0.9	10	Gompertz	sgd	0.621%	58.88810492
0.8	0.9	12	Gompertz	sgd	0.639%	59.24466801
0.8	0.9	14	Gompertz	sgd	0.645%	60.03167337
0.6	0.9	10	Gompertz	sgd	0.646%	56.53492689
0.9	0.9	13	Gompertz	sgd	0.654%	60.01092196
0.9	0.9	9	Gompertz	sgd	0.655%	57.51705813
0.9	0.9	14	Gompertz	sgd	0.663%	60.04954408
0.9	0.1	10	Gompertz	sgd	0.663%	57.55123997
0.8	0.3	5	Gompertz	sgd	0.664%	53.7058301
0.6	0.2	15	Gompertz	sgd	0.665%	60.0335479

Dari tabel tersebut menunjukkan nilai MAPE terkecil sebesar 0,621%. Model yang memiliki nilai MAPE terkecil menggunakan parameter *learning rate* 0.9, *momentum* 0.9, *hidden layer* sebanyak 10 dimensi, *sigmoid* dengan *Gompertz*, dan *rule* dengan *sgd*. Gambar 6.7 menunjukkan grafik perbandingan antara data aktual dengan data hasil peramalan menggunakan model dari nilai MAPE terkecil.



**Gambar 0.7 Grafik data aktual dengan data hasil peramalan *univariate* periode 5**

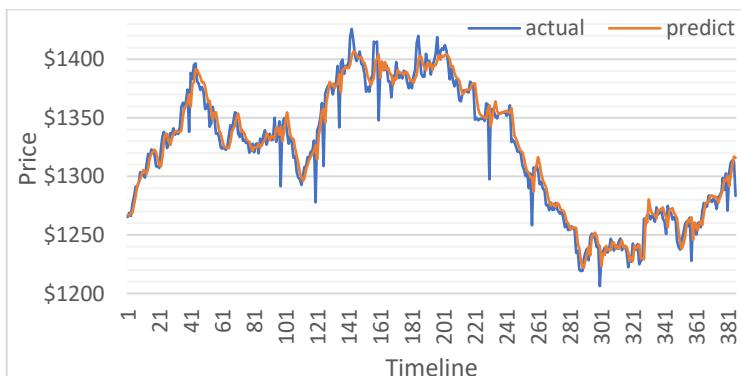
### 6.3.6. Hasil Pemodelan Peramalan RNN untuk Periode 6 dengan *Univariate*

Peramalan model menggunakan proporsi data 70:30 untuk periode 6 dengan variabel *univariate* menghasilkan data berupa nilai MAPE dan data prediksi. Pada Tabel 6.9 menunjukkan sebagian nilai MAPE yang telah diurutkan paling kecil hingga terbesar dari keseluruhan data nilai MAPE untuk periode 6 dengan variabel *univariate*.

**Tabel 0.9 Urutan 10 MAPE terkecil pada periode 6 variabel *univariate***

learning rate	momentum	hidden layer	sigmoid	rule	eror	time taken (secs)
0.9	0.9	12	Gompertz	sgd	0.640%	60.10396388
0.9	0.9	16	Gompertz	sgd	0.643%	60.15475023
0.8	0.9	14	Gompertz	sgd	0.647%	60.12212943
0.9	0.9	15	Gompertz	sgd	0.649%	60.1365988
0.9	0.9	13	Gompertz	sgd	0.649%	60.11362032
0.8	0.9	13	Gompertz	sgd	0.654%	60.11285465
0.9	0.8	13	Gompertz	sgd	0.656%	60.11538233
0.8	0.9	18	Gompertz	sgd	0.662%	60.18090757
0.9	0.9	12	logistic	sgd	0.662%	60.0982543
0.8	0.6	11	Gompertz	sgd	0.663%	60.08094203

Dari tabel tersebut menunjukkan nilai MAPE terkecil sebesar 0,64%. Model yang memiliki nilai MAPE terkecil menggunakan parameter *learning rate* 0.9, *momentum* 0.9, *hidden layer* sebanyak 12 dimensi, *sigmoid* dengan *Gompertz*, dan *rule* dengan *sgd*. Gambar 6.8 menunjukkan grafik perbandingan antara data aktual dengan data hasil peramalan menggunakan model dari nilai MAPE terkecil.



**Gambar 0.8 Grafik data aktual dengan data hasil peramalan *univariate* periode 6**

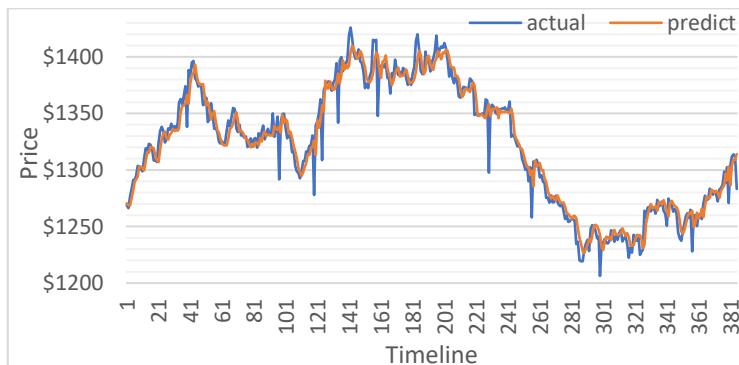
### 6.3.7. Hasil Pemodelan Peramalan RNN untuk Periode 7 dengan *Univariate*

Peramalan model menggunakan proporsi data 70:30 untuk periode 7 dengan variabel *univariate* menghasilkan data berupa nilai MAPE dan data prediksi. Pada Tabel 6.10 menunjukkan sebagian nilai MAPE yang telah diurutkan paling kecil hingga terbesar dari keseluruhan data nilai MAPE untuk periode 7 dengan variabel *univariate*.

**Tabel 0.10 Urutan 10 MAPE terkecil pada periode 7 variabel *univariate***

learning rate	momentum	hidden layer	sigmoid	rule	eror	time taken (secs)
0.9	0.9	16	Gompertz	sgd	0.634%	120.1623959
0.9	0.9	10	Gompertz	sgd	0.661%	107.9653912
0.6	0.9	11	Gompertz	sgd	0.663%	81.28142094
0.9	0.8	18	Gompertz	sgd	0.663%	134.4870319
0.7	0.7	19	Gompertz	sgd	0.665%	93.42917298
0.6	0.5	10	Gompertz	sgd	0.667%	78.69549702
0.2	0.1	14	Gompertz	sgd	0.667%	81.02194092
0.4	0.9	17	Gompertz	sgd	0.667%	87.12531804
0.6	0.8	10	Gompertz	sgd	0.667%	80.51268408
0.2	0.7	8	Gompertz	sgd	0.668%	73.575603

Dari tabel tersebut menunjukkan nilai MAPE terkecil sebesar 0,634%. Model yang memiliki nilai MAPE terkecil menggunakan parameter *learning rate* 0.9, *momentum* 0.9, *hidden layer* sebanyak 16 dimensi, *sigmoid* dengan *Gompertz*, dan *rule* dengan *sgd*. Gambar 6.9 menunjukkan grafik perbandingan antara data aktual dengan data hasil peramalan menggunakan model dari nilai MAPE terkecil.



**Gambar 0.9 Grafik data aktual dengan data hasil peramalan *univariate* periode 7**

## 6.4. Hasil Pemodelan Peramalan *Recurrent Neural Network (RNN)* dengan *Multivariate*

Pemodelan RNN menggunakan proporsi data 70:30 menghasilkan model terbaik pada masing-masing periode dengan menggunakan dua variabel, *multivariate*. Model terbaik yang dipilih berdasarkan nilai MAPE (*Mean Absolute Percentage Error*) terkecil.

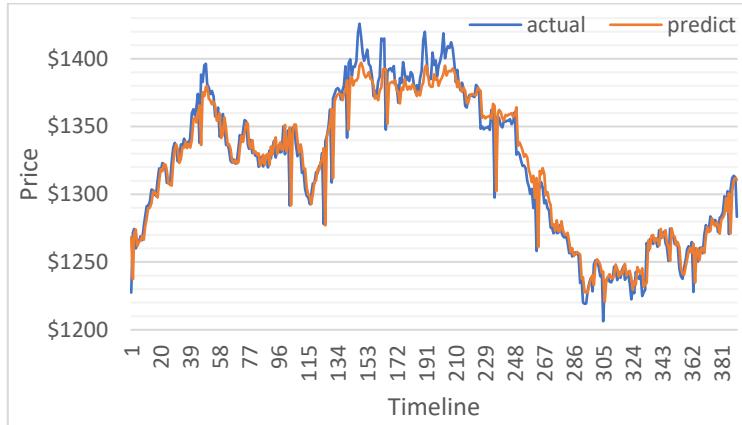
### 6.4.1. Hasil Pemodelan Peramalan RNN untuk Periode 1 dengan *Multivariate*

Peramalan model menggunakan proporsi data 70:30 untuk periode 1 dengan variabel *multivariate* menghasilkan data berupa nilai MAPE dan data prediksi. Pada Tabel 6.11 menunjukkan sebagian nilai MAPE yang telah diurutkan paling kecil hingga terbesar dari keseluruhan data nilai MAPE untuk periode 1 dengan variabel *multivariate*.

**Tabel 6.11 Urutan 10 MAPE terkecil pada periode 1 variabel *multivariate***

learning rate	momentum	hidden layer	sigmoid	rule	eror	time taken
0.4	0.1	5	Gompertz	sgd	74.944%	46.32831597
0.5	0.1	5	Gompertz	sgd	75.986%	46.35841584
0.5	0.4	4	Gompertz	sgd	76.367%	45.40091515
0.5	0.4	3	Gompertz	sgd	77.065%	45.73292279
0.4	0.4	6	Gompertz	sgd	77.114%	46.40732908
0.2	0.2	6	Gompertz	sgd	77.161%	46.28565884
0.7	0.4	3	Gompertz	sgd	77.323%	46.62543297
0.9	0.2	4	Gompertz	sgd	77.349%	45.52715111
0.5	0.1	3	Gompertz	sgd	77.383%	45.77597189
0.5	0.7	4	Gompertz	sgd	77.667%	45.48057604

Dari tabel tersebut menunjukkan nilai MAPE terkecil sebesar 74,944%. Model yang memiliki nilai MAPE terkecil menggunakan parameter *learning rate* 0.4, *momentum* 0.1, *hidden layer* sebanyak 5 dimensi, *sigmoid* dengan *Gompertz*, dan *rule* dengan *sgd*. Gambar 6.10 menunjukkan grafik perbandingan antara data aktual dengan data hasil peramalan menggunakan model dari nilai MAPE terkecil.



**Gambar 0.10 Grafik data aktual dengan data hasil peramalan multivariate periode 1**

#### 6.4.2. Hasil Pemodelan Peramalan RNN untuk Periode 2 dengan Multivariate

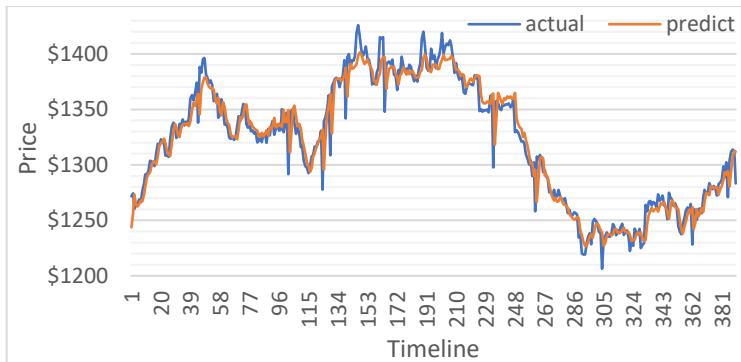
Peramalan model menggunakan proporsi data 70:30 untuk periode 2 dengan variabel *multivariate* menghasilkan data berupa nilai MAPE dan data prediksi. Pada Tabel 6.12 menunjukkan sebagian nilai MAPE yang telah diurutkan paling kecil hingga terbesar dari keseluruhan data nilai MAPE untuk periode 2 dengan variabel *multivariate*.

**Tabel 0.12 Urutan 10 MAPE terkecil pada periode 2 variabel *multivariate***

learning rate	momentum	hidden layer	sigmoid	rule	eror	time taken (secs)
0.5	0.8	7 Gompertz	sgd	0.695%	54.58292198	
0.7	0.7	6 Gompertz	sgd	0.699%	50.18565893	
0.4	0.8	4 logistic	sgd	0.699%	46.55642509	
0.2	0.7	10 Gompertz	sgd	0.699%	50.44959497	
0.8	0.3	9 Gompertz	sgd	0.700%	51.55564499	
0.3	0.4	8 Gompertz	sgd	0.701%	59.52492905	
0.5	0.7	11 Gompertz	sgd	0.706%	58.72867298	
0.9	0.5	5 Gompertz	sgd	0.707%	47.74685907	
0.9	0.7	4 logistic	sgd	0.708%	47.97601318	
0.3	0.8	9 logistic	sgd	0.709%	49.44919896	

Dari tabel tersebut menunjukkan nilai MAPE terkecil sebesar 0,695%. Model yang memiliki nilai MAPE terkecil menggunakan parameter *learning rate* 0.5, *momentum* 0.8, *hidden layer* sebanyak 7 dimensi, *sigmoid* dengan *Gompertz*, dan *rule* dengan *sgd*. Gambar 6.11 menunjukkan grafik

perbandingan antara data aktual dengan data hasil peramalan menggunakan model dari nilai MAPE terkecil.



**Gambar 0.11 Grafik data aktual dengan data hasil peramalan multivariate periode 2**

#### 6.4.3. Hasil Pemodelan Peramalan RNN untuk Periode 3 dengan Multivariate

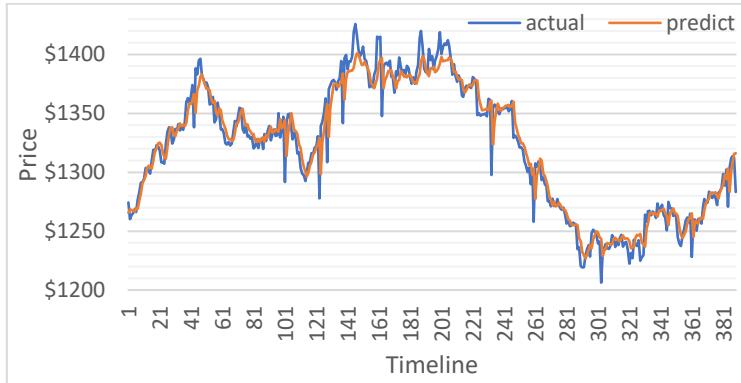
Peramalan model menggunakan proporsi data 70:30 untuk periode 3 dengan variabel *multivariate* menghasilkan data berupa nilai MAPE dan data prediksi. Pada Tabel 6.13 menunjukkan sebagian nilai MAPE yang telah diurutkan paling kecil hingga terbesar dari keseluruhan data nilai MAPE untuk periode 3 dengan variabel *multivariate*.

**Tabel 0.13 Urutan 10 MAPE terkecil pada periode 3 variabel multivariate**

learning rate	momentum	hidden layer	sigmoid	rule	eror	time taken (secs)
0.4	0.4	15	Gompertz	sgd	0.685%	60.12299393
0.1	0.4	18	Gompertz	sgd	0.688%	60.19610058
0.1	0.9	11	Gompertz	sgd	0.688%	60.06616836
0.9	0.2	16	logistic	sgd	0.702%	60.13633987
0.2	0.3	18	Gompertz	sgd	0.703%	60.20163623
0.2	0.3	16	Gompertz	sgd	0.704%	60.15917125
0.5	0.2	16	Gompertz	sgd	0.705%	60.1692001
0.8	0.3	11	Gompertz	sgd	0.707%	60.10719752
0.5	0.4	14	logistic	sgd	0.707%	60.14101192
0.3	0.4	12	Gompertz	sgd	0.707%	60.11808892

Dari tabel tersebut menunjukkan nilai MAPE terkecil sebesar 0,685%. Model yang memiliki nilai MAPE terkecil menggunakan parameter *learning rate* 0.4, *momentum* 0.4, *hidden layer* sebanyak 15 dimensi, *sigmoid* dengan *Gompertz*,

dan *rule* dengan *sgd*. Gambar 6.12 menunjukkan grafik perbandingan antara data aktual dengan data hasil peramalan menggunakan model dari nilai MAPE terkecil.



**Gambar 0.12** Grafik data aktual dengan data hasil peramalan *multivariate* periode 3

#### 6.4.4. Hasil Pemodelan Peramalan RNN untuk Periode 4 dengan *Multivariate*

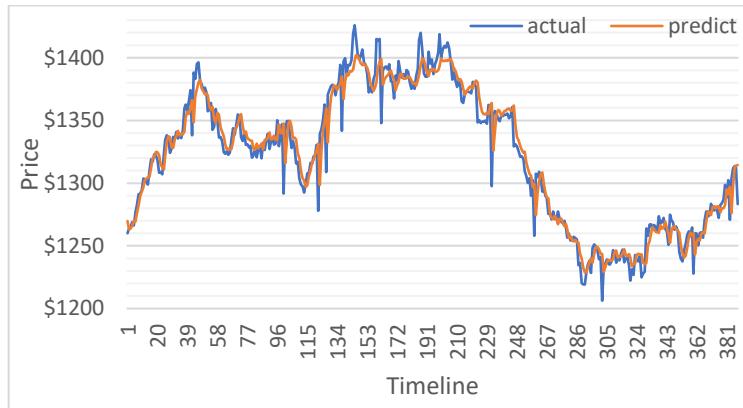
Peramalan model menggunakan proporsi data 70:30 untuk periode 4 dengan variabel *multivariate* menghasilkan data berupa nilai MAPE dan data prediksi. Pada Tabel 6.14 menunjukkan sebagian nilai MAPE yang telah diurutkan paling kecil hingga terbesar dari keseluruhan data nilai MAPE untuk periode 4 dengan variabel *multivariate*.

**Tabel 0.14 Urutan 10 MAPE terkecil pada periode 4 variabel *multivariate***

learning rate	momentum	hidden layer	sigmoid	rule	eror	time taken (secs)
0.4	0.2	19	Gompertz	sgd	0.677%	60.77079672
0.1	0.1	14	Gompertz	sgd	0.681%	60.65650478
0.1	0.9	11	Gompertz	sgd	0.691%	60.5200175
0.8	0.6	18	logistic	sgd	0.695%	60.66744048
0.5	0.5	19	Gompertz	sgd	0.696%	60.75259317
0.4	0.3	17	Gompertz	sgd	0.699%	60.74745867
0.9	0.8	22	logistic	sgd	0.700%	60.5317849
0.1	0.3	15	logistic	sgd	0.700%	60.67605908
0.1	0.5	16	Gompertz	sgd	0.700%	60.6931465
0.5	0.3	13	Gompertz	sgd	0.701%	60.60984442

Dari tabel tersebut menunjukkan nilai MAPE terkecil sebesar 0,677%. Model yang memiliki nilai MAPE terkecil menggunakan parameter *learning rate* 0.4, *momentum* 0.2,

*hidden layer* sebanyak 19 dimensi, *sigmoid* dengan *Gompertz*, dan *rule* dengan *sgd*. Gambar 6.13 menunjukkan grafik perbandingan antara data aktual dengan data hasil peramalan menggunakan model dari nilai MAPE terkecil.



**Gambar 0.13 Grafik data aktual dengan data hasil peramalan multivariate periode 4**

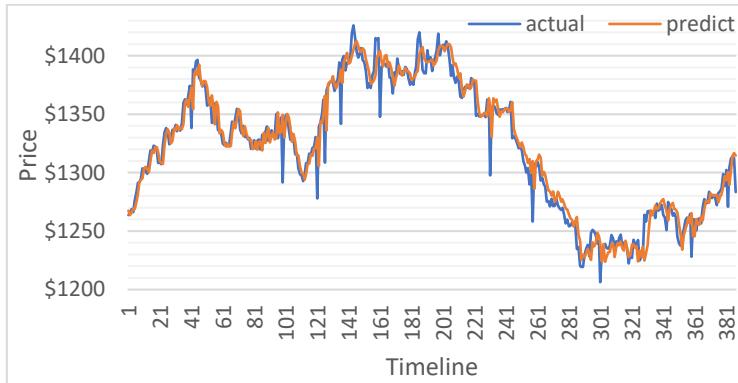
#### 6.4.5. Hasil Pemodelan Peramalan RNN untuk Periode 5 dengan *Multivariate*

Peramalan model menggunakan proporsi data 70:30 untuk periode 5 dengan variabel *multivariate* menghasilkan data berupa nilai MAPE dan data prediksi. Pada Tabel 6.15 menunjukkan sebagian nilai MAPE yang telah diurutkan paling kecil hingga terbesar dari keseluruhan data nilai MAPE untuk periode 5 dengan variabel *multivariate*.

**Tabel 0.15 Urutan 10 MAPE terkecil pada periode 5 variabel *multivariate***

learning rate	momentum	hidden layer	sigmoid	rule	error	time taken (secs)
0.9	0.9	30	Gompertz	sgd	0.682%	172.607044
0.6	0.7	12	logistic	sgd	0.691%	91.58674598
0.4	0.5	23	Gompertz	sgd	0.696%	122.052223
0.3	0.5	30	logistic	sgd	0.699%	132.6082511
0.6	0.1	26	Gompertz	sgd	0.700%	116.8613799
0.3	0.7	23	logistic	sgd	0.702%	120.2197309
0.9	0.9	30	logistic	sgd	0.702%	173.2104869
0.4	0.3	30	logistic	sgd	0.705%	131.3226449
0.9	0.3	17	logistic	sgd	0.709%	161.483011
0.6	0.6	21	logistic	sgd	0.710%	107.95699

Dari tabel tersebut menunjukkan nilai MAPE terkecil sebesar 0,682%. Model yang memiliki nilai MAPE terkecil menggunakan parameter *learning rate* 0.9, *momentum* 0.9, *hidden layer* sebanyak 30 dimensi, *sigmoid* dengan *Gompertz*, dan *rule* dengan *sgd*. Gambar 6.14 menunjukkan grafik perbandingan antara data aktual dengan data hasil peramalan menggunakan model dari nilai MAPE terkecil.



**Gambar 0.14** Grafik data aktual dengan data hasil peramalan multivariate periode 5

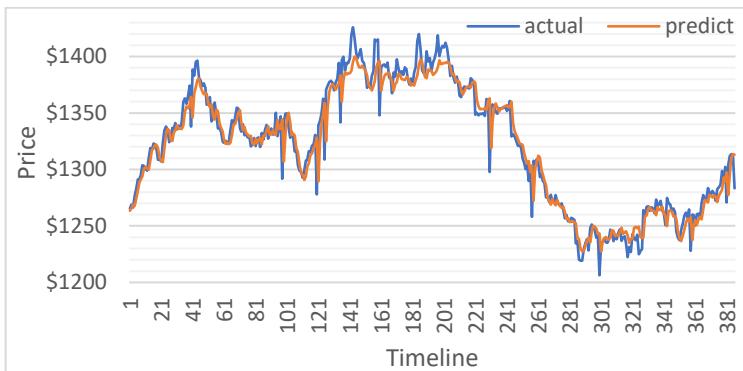
#### 6.4.6. Hasil Pemodelan Peramalan RNN untuk Periode 6 dengan Multivariate

Peramalan model menggunakan proporsi data 70:30 untuk periode 6 dengan variabel *multivariate* menghasilkan data berupa nilai MAPE dan data prediksi. Pada Tabel 6.16 menunjukkan sebagian nilai MAPE yang telah diurutkan paling kecil hingga terbesar dari keseluruhan data nilai MAPE untuk periode 6 dengan variabel *multivariate*.

**Tabel 0.16 Urutan 10 MAPE terkecil pada periode 6 variabel multivariate**

learning rate	momentum	hidden layer	sigmoid	rule	eror	time taken (secs)
0.1	0.6	15	Gompertz	sgd	0.6989%	129.0607409
0.3	0.2	31	logistic	sgd	0.6993%	183.3196099
0.1	0.4	28	Gompertz	sgd	0.6999%	167.9670059
0.1	0.3	27	Gompertz	sgd	0.7023%	173.2573862
0.6	0.7	34	logistic	sgd	0.7026%	210.6740611
0.6	0.2	16	Gompertz	sgd	0.7031%	143.358171
0.1	0.2	22	Gompertz	sgd	0.7042%	143.536381
0.1	0.6	30	Gompertz	sgd	0.7048%	169.5892072
0.8	0.9	33	logistic	sgd	0.7052%	180.330934
0.1	0.5	21	Gompertz	sgd	0.7057%	157.8469329

Dari tabel tersebut menunjukkan nilai MAPE terkecil sebesar 0,6989%. Model yang memiliki nilai MAPE terkecil menggunakan parameter *learning rate* 0.1, *momentum* 0.6, *hidden layer* sebanyak 15 dimensi, *sigmoid* dengan *Gompertz*, dan *rule* dengan *sgd*. Gambar 6.15 menunjukkan grafik perbandingan antara data aktual dengan data hasil peramalan menggunakan model dari nilai MAPE terkecil.



**Gambar 0.15** Grafik data aktual dengan data hasil peramalan *multivariate* periode 6

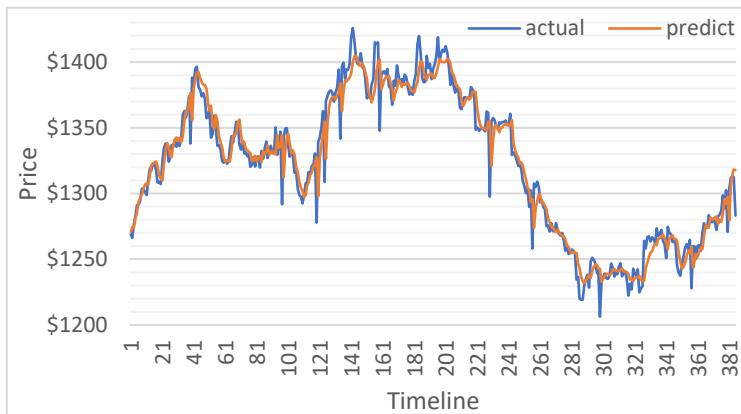
#### 6.4.7. Hasil Pemodelan Peramalan RNN untuk Periode 7 dengan *Multivariate*

Peramalan model menggunakan proporsi data 70:30 untuk periode 7 dengan variabel *multivariate* menghasilkan data berupa nilai MAPE dan data prediksi. Pada Tabel 6.17 menunjukkan sebagian nilai MAPE yang telah diurutkan paling kecil hingga terbesar dari keseluruhan data nilai MAPE untuk periode 7 dengan variabel *multivariate*.

**Tabel 0.17 Urutan 10 MAPE terkecil pada periode 7 variabel *multivariate***

learning rate	momentum	hidden layer	sigmoid	rule	eror	time taken (secs)
0.9	0.7	26	logistic	sgd	0.676%	313.595175
0.9	0.8	37	logistic	sgd	0.690%	243.086514
0.4	0.8	37	logistic	sgd	0.691%	235.9995031
0.6	0.3	39	Gompertz	sgd	0.695%	282.7118819
0.1	0.4	26	Gompertz	sgd	0.701%	226.7637348
0.1	0.6	21	Gompertz	sgd	0.702%	281.817646
0.2	0.9	17	Gompertz	sgd	0.702%	115.687974
0.2	0.1	30	Gompertz	sgd	0.707%	156.2918119
0.5	0.7	21	Gompertz	sgd	0.708%	169.5138109
0.1	0.2	18	Gompertz	sgd	0.709%	146.431958

Dari tabel tersebut menunjukkan nilai MAPE terkecil sebesar 0,676%. Model yang memiliki nilai MAPE terkecil menggunakan parameter *learning rate* 0.9, *momentum* 0.7, *hidden layer* sebanyak 26 dimensi, *sigmoid* dengan *logistic*, dan *rule* dengan *s gd*. Gambar 6.16 menunjukkan grafik perbandingan antara data aktual dengan data hasil peramalan menggunakan model dari nilai MAPE terkecil.



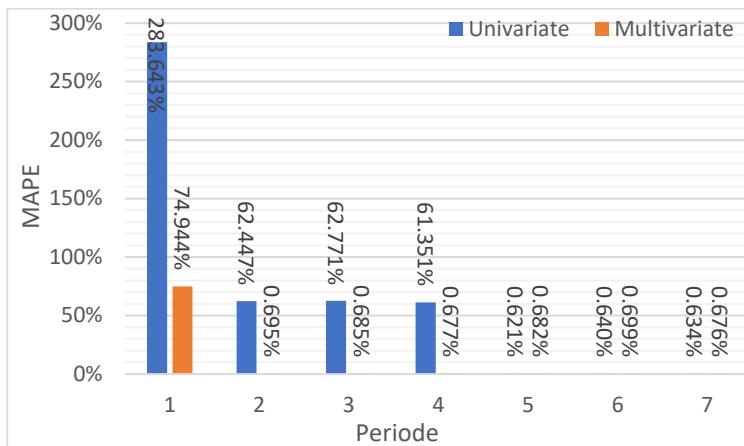
**Gambar 0.16 Grafik data aktual dengan data hasil peramalan multivariate periode 7**

### 6.5. Perbandingan Hasil Pemodelan Peramalan RNN antara *Univariate* dengan *Multivariate*

Tabel 6.18 menampilkan parameter mana saja yang menghasilkan nilai MAPE terkecil pada setiap periodenya. Parameter ini yang akan digunakan sebagai dalam menguji model peramalan dengan menggunakan proporsi data yang berbeda, yakni 50:50, 60:40, dan 80:20. Tabel ini juga menampilkan nilai MAPE peramalan dengan proporsi data 70:30 dan dibandingkan melalui Gambar 6.17.

Tabel 0.18 Model pada proporsi data 70:30 disetiap periode yang memiliki nilai MAPE terkecil

Model	Periode	Learning rate	Moment um	Hidden layer	Sigmoid	Rule	MAPE	Time (secs)
UNIVARIATE	1	0.5	0.9	3	Gompertz	sgd	283,643%	42.00883794
	2	0.9	0.9	3	Gompertz	sgd	62,447%	46.02754188
	3	0.9	0.8	8	Gompertz	sgd	62,771%	50.25427008
	4	0.9	0.8	9	Gompertz	sgd	61,351%	60.61573245
	<b>5</b>	<b>0.9</b>	<b>0.9</b>	<b>10</b>	<b>Gompertz</b>	<b>sgd</b>	<b>0,621%</b>	<b>58.88810492</b>
	6	0.9	0.9	12	Gompertz	sgd	0,64%	60.10396388
	7	0.9	0.9	16	Gompertz	sgd	0,634%	120.1623959
MULTIVARIATE	1	0.4	0.1	5	Gompertz	sgd	74,944%	46.32831597
	2	0.5	0.8	7	Gompertz	sgd	0,695%	54.58292198
	3	0.4	0.4	15	Gompertz	sgd	0,685%	60.12299393
	4	0.4	0.2	19	Gompertz	sgd	0,677%	60.77079672
	5	0.9	0.9	30	Gompertz	sgd	0,682%	172.607044
	6	0.1	0.6	15	Gompertz	sgd	0,6989%	129.0607409
	<b>7</b>	<b>0.9</b>	<b>0.7</b>	<b>26</b>	<b>logistic</b>	<b>sgd</b>	<b>0,676%</b>	<b>313.595175</b>



Gambar 0.17 Grafik perbandingan nilai MAPE terkecil di setiap periode pada proporsi data 70:30

## 6.6. Hasil Uji Coba Proporsi Data

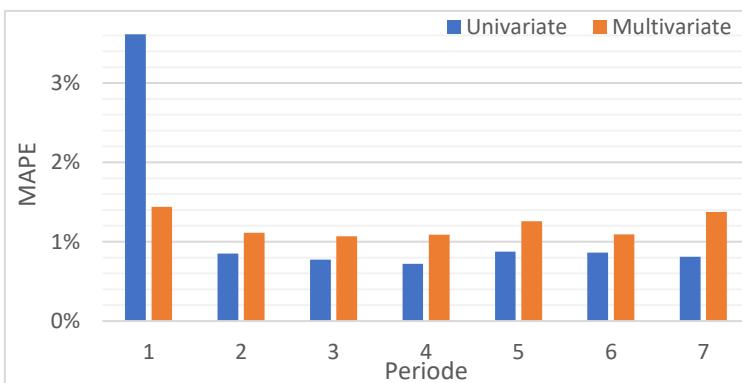
### 6.6.1. Uji Coba Proporsi Data 50:50

Tabel 6.19 menampilkan hasil peramalan menggunakan model pada Tabel 6.18 dengan proporsi data 50:50. Nilai MAPE terkecil untuk variabel *univariate* berada pada periode ke-4 sebesar 0.72% dengan menggunakan parameter *learning rate* 0.9, *momentum* 0.8, *hidden layer* sebanyak 9 dimensi, *sigmoid* dengan *Gompertz*, dan *rule* dengan *sgd*. *Multivariate* di periode ke-3 dengan nilai MAPE terkecil 1.06% dengan menggunakan parameter *learning rate* 0.4, *momentum* 0.4, *hidden layer* sebanyak 15 dimensi, *sigmoid* dengan *Gompertz*, dan *rule* dengan *sgd*. Gambar 6.18 menampilkan perbandingan nilai MAPE dari Tabel 6.19.

Tabel 0.19 Nilai MAPE terkecil pada proporsi data 50:50

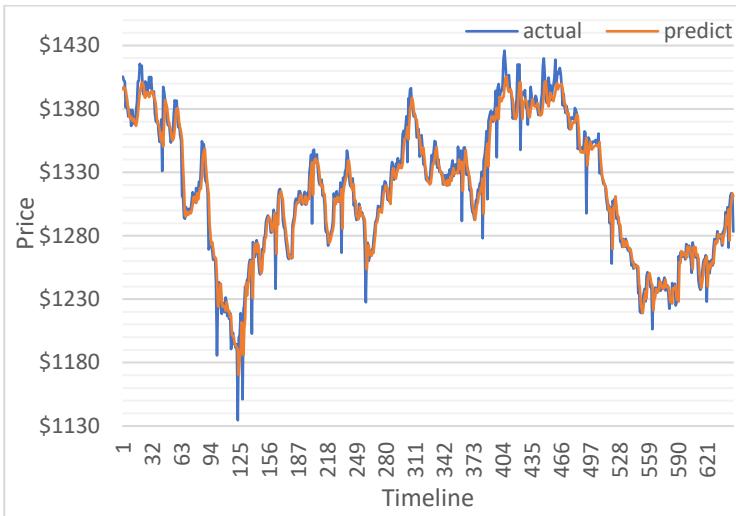
Data Propotion 50:50	Periode	MAPE	Time (secs)
UNIVARIATE	1	3.612%	32.69465
	2	0.852%	49.34904385
	3	0.773%	51.79914308
	4	0.722%	62.83814502
	5	0.874%	73.20338106

	6	0.861%	77.51213193
	7	0.810%	105.2583771
MULTIVARIATE	1	1.439%	50.20432711
	2	1.112%	58.87649179
	3	<b>1.067%</b>	<b>80.97839999</b>
	4	1.089%	103.808836
	5	1.259%	147.2995958
	6	1.093%	130.0769601
	7	1.374%	183.6626549

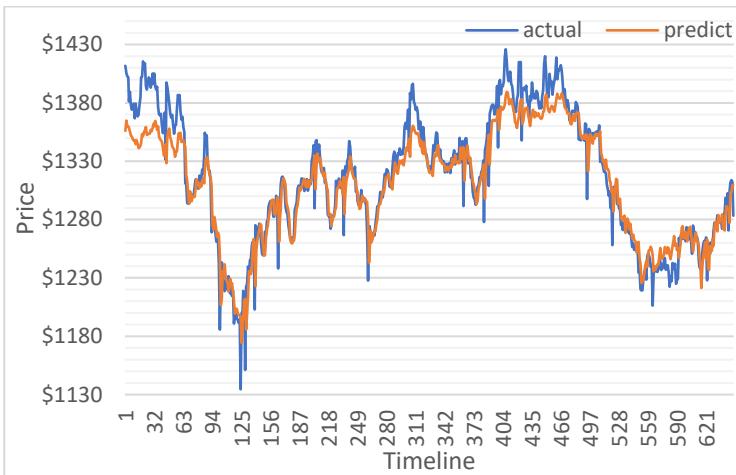


Gambar 0.18 Grafik perbandingan nilai MAPE terkecil di setiap periode pada proporsi data 50:50

Pada Gambar 6.19 menunjukkan grafik antara data aktual dengan data hasil peramalan menggunakan model *univariate* periode ke-4 dengan proporsi data 50:50. Pada Gambar 6.20 menunjukkan grafik antara data aktual dengan data hasil peramalan menggunakan model *multivariate* periode ke-3 dengan proporsi data 50:50.



**Gambar 0.19** Grafik antara data aktual dengan data hasil peramalan menggunakan model univariate periode ke-4 dengan proporsi data 50:50



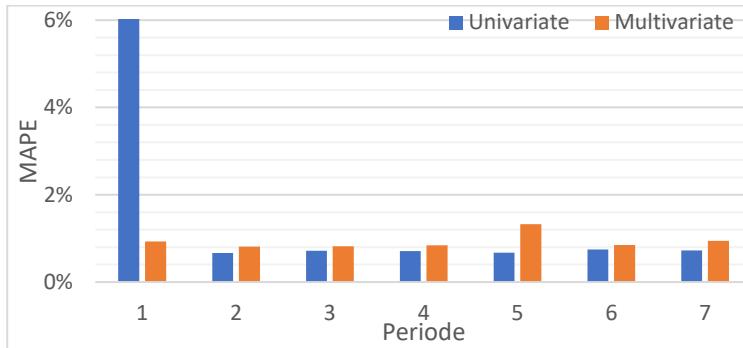
**Gambar 0.20** Grafik antara data aktual dengan data hasil peramalan menggunakan model multivariate periode ke-3 dengan proporsi data 50:50

### 6.6.2. Uji Coba Proporsi Data 60:40

Tabel 6.20 menampilkan hasil peramalan menggunakan model pada Tabel 6.18 dengan proporsi data 60:40. Nilai MAPE terkecil untuk variabel *univariate* sebesar 0.66% pada periode ke-2 dengan parameter *learning rate* 0.9, *momentum* 0.9, *hidden layer* sebanyak 3 dimensi, *sigmoid* dengan *Gompertz*, dan *rule* dengan *sgd*. *Multivariate* pada periode ke-2 yang memiliki nilai MAPE terkecil 0.81% menggunakan parameter *learning rate* 0.5, *momentum* 0.8, *hidden layer* sebanyak 7 dimensi, *sigmoid* dengan *Gompertz*, dan *rule* dengan *sgd*. Gambar 6.21 menampilkan perbandingan nilai MAPE dari Tabel 6.20.

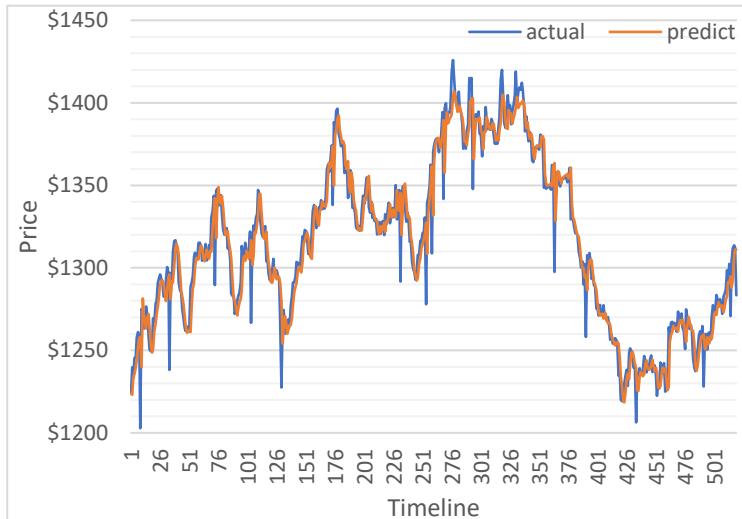
**Tabel 0.20 Nilai MAPE terkecil pada proporsi data 60:40**

Data Propotion 60:40	Periode	MAPE	Time (secs)
UNIVARIATE	1	6.029%	41.78853
	2	<b>0.669%</b>	<b>52.48401904</b>
	3	0.721%	61.90779781
	4	0.712%	103.3089619
	5	0.676%	100.4512489
	6	0.750%	139.3064609
	7	0.728%	126.809587
MULTIVARIATE	1	0.930%	73.36917496
	2	<b>0.815%</b>	<b>71.170506</b>
	3	0.819%	202.912199
	4	0.839%	180.6799881
	5	1.324%	259.169287
	6	0.850%	226.9026601
	7	0.943%	264.116008

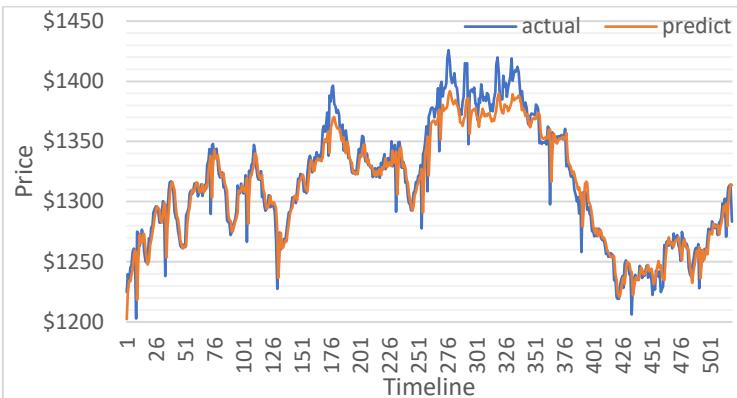


Gambar 0.21 Grafik perbandingan nilai MAPE terkecil di setiap periode pada proporsi data 60:40

Pada Gambar 6.22 menunjukkan grafik antara data aktual dengan data hasil peramalan menggunakan model *univariate* periode ke-2 dengan proporsi data 60:40. Pada Gambar 6.23 menunjukkan grafik antara data aktual dengan data hasil peramalan menggunakan model *multivariate* periode ke-2 dengan proporsi data 60:40.



Gambar 0.22 Grafik antara data aktual dengan data hasil peramalan menggunakan model univariate periode ke-2 dengan proporsi data 60:40



**Gambar 0.23** Grafik antara data aktual dengan data hasil peramalan menggunakan model multivariate periode ke-2 dengan proporsi data 60:40

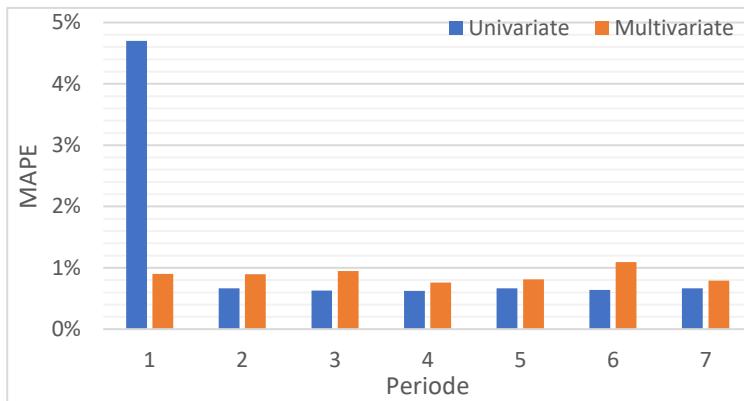
### 6.6.3. Uji Coba Proporsi Data 80:20

Tabel 6.21 menampilkan hasil peramalan menggunakan model pada Tabel 6.18 dengan proporsi data 80:20. Nilai MAPE terkecil untuk variabel *univariate* dan *multivariate* sama-sama berada pada periode ke-4 dengan nilai MAPE masing-masing sebesar 0.62% dan 0.76%. Parameter yang digunakan masing-masing variabel adalah *learning rate* 0.9, *momentum* 0.8, *hidden layer* sebanyak 9 dimensi, *sigmoid* dengan *Gompertz*, dan *rule* dengan *sgd* serta *learning rate* 0.4, *momentum* 0.2, *hidden layer* sebanyak 19 dimensi, *sigmoid* dengan *Gompertz*, dan *rule* dengan *sgd*. Gambar 6.24 menampilkan perbandingan nilai MAPE dari Tabel 6.21.

**Tabel 0.21** Nilai MAPE terkecil pada proporsi data 80:20

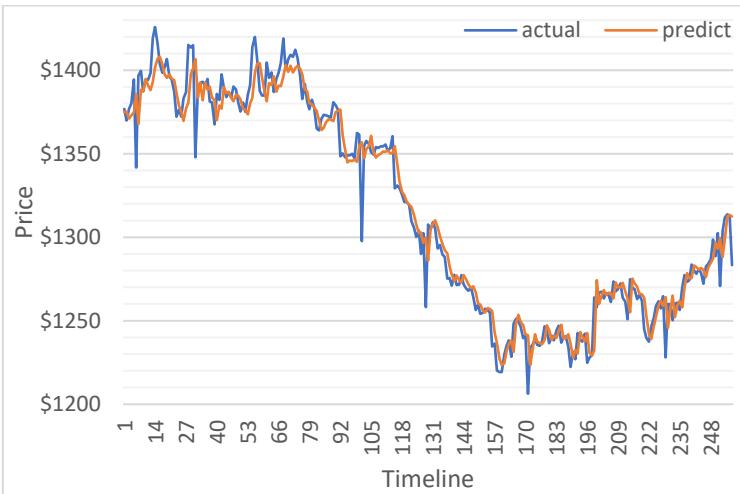
Data Propotion 80:20	Periode	MAPE	Time (secs)
UNIVARIATE	1	4.699%	1.262308
	2	0.667%	102.240658
	3	0.630%	177.2078381
	4	<b>0.623%</b>	<b>140.0968931</b>
	5	0.667%	135.7239091
	6	0.638%	168.0002959
	7	0.664%	191.8915522

MULTIVARIATE	1	0.902%	100.5108662
	2	0.898%	151.537003
	3	0.946%	292.074415
	4	<b>0.761%</b>	<b>252.0311961</b>
	5	0.813%	345.178762
	6	1.095%	570.4638679
	7	0.792%	475.6772609

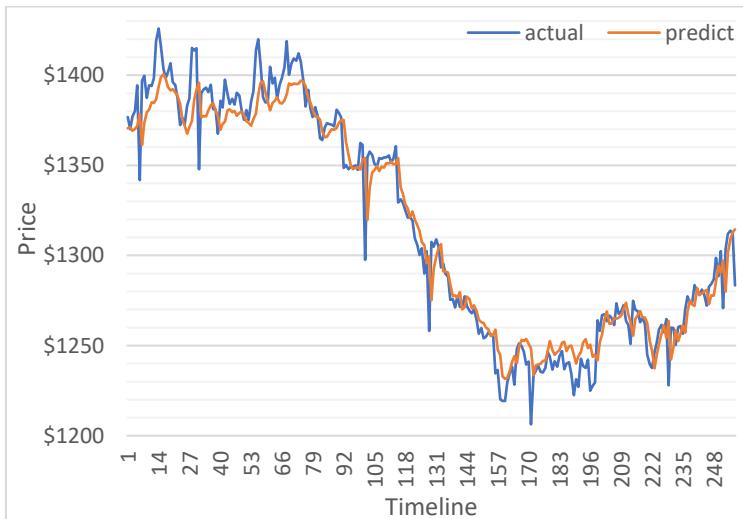


**Gambar 0.24** Grafik perbandingan nilai MAPE terkecil di setiap periode pada proporsi data 80:20

Pada Gambar 6.25 menunjukkan grafik antara data aktual dengan data hasil peramalan menggunakan model *univariate* periode ke-4 dengan proporsi data 80:20. Pada Gambar 6.26 menunjukkan grafik antara data aktual dengan data hasil peramalan menggunakan model *multivariate* periode ke-4 dengan proporsi data 80:20.



**Gambar 0.25** Grafik antara data aktual dengan data hasil peramalan menggunakan model univariate periode ke-4 dengan proporsi data 80:20



**Gambar 0.26** Grafik antara data aktual dengan data hasil peramalan menggunakan model multivariate periode ke-4 dengan proporsi data 80:20

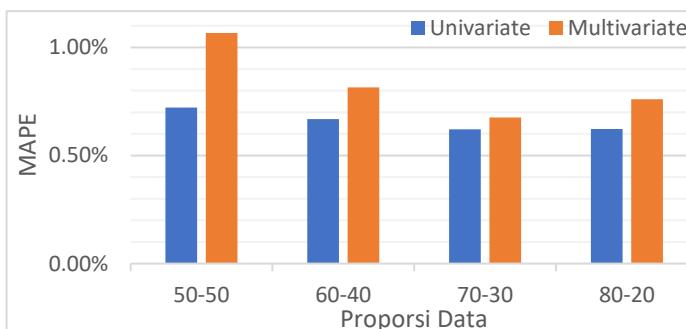
### 6.7. Perbandingan Nilai MAPE antar Proporsi Data

Perbandingan MAPE antara variabel *univariate* dan *multivariate* pada peralaman harga emas di setiap proporsi data yang berbeda dapat dilihat pada Tabel 6.22.

**Tabel 0.22** Nilai MAPE terkecil pada setiap proporsi data

Proporsi Data	MAPE	
	Univariate	Multivariate
50:50	0.722%	1.067%
60:40	0.669%	0.815%
<b>70:30</b>	<b>0.621%</b>	<b>0.676%</b>
80:20	0.623%	0.761%

Grafik perbandingan MAPE dari setiap proporsi data ditunjukkan pada Gambar 6.27. Nilai MAPE terkecil diketahui berada di proporsi data 70:30 dengan nilai variabel *univariate* pada periode ke-5 sebesar 0,621% sedangkan variabel *multivariate* periode ke-7 sebesar 0,676%.



**Gambar 0.27** Grafik perbandingan nilai MAPE terkecil di setiap proporsi data

### 6.8. Hasil Uji Coba Menggunakan Dataset Lain

Skenario pengujian ini dilakukan untuk menguji model terbaik dengan menggunakan dataset harga bawang merah, cabe merah keriting, cabe merah besar, cabe rawit merah, dan cabe rawit hijau dari Pasar Induk Kramat Jati. Model yang digunakan hanya model terbaik pada variabel tunggal (*univariate*) karena antara harga satu dengan harga lainnya tidak berkaitan satu sama lain. Proporsi data yang digunakan sama dengan proporsi

data yang sudah diujikan sebelumnya, yaitu menggunakan 50:50, 60:40, 70:30, dan 80:20. Hasil MAPE dari setiap proporsi data pada dataset harga Pasar Induk Kramat Jati menggunakan model terbaik *univariate* dapat dilihat pada Tabel 6.23 sampai dengan Tabel 6.26.

Tabel 0.23 Nilai MAPE terkecil pada proporsi data 50:50

Periode	Bawang Merah	Cabai Merah Keriting	Cabai Merah Besar	Cabai Rawit Merah	Cabai Rawit Hijau
1	27.648%	35.399%	46.538%	29.898%	50.116%
2	7.506%	<b>6.522%</b>	<b>5.936%</b>	<b>4.547%</b>	7.957%
3	9.851%	6.667%	6.642%	5.162%	<b>7.498%</b>
4	7.825%	6.750%	5.949%	5.220%	9.316%
5	<b>6.669%</b>	6.807%	6.105%	5.159%	8.510%
6	6.785%	6.764%	6.193%	4.704%	41.313%
7	7.451%	53.016%	6.118%	6.261%	41.373%

Tabel 0.24 Nilai MAPE terkecil pada proporsi data 60:40

Periode	Bawang Merah	Cabai Merah Keriting	Cabai Merah Besar	Cabai Rawit Merah	Cabai Rawit Hijau
1	57.030%	30.341%	46.256%	42.094%	26.768%
2	8.203%	<b>5.647%</b>	5.845%	<b>4.982%</b>	<b>6.346%</b>
3	<b>7.270%</b>	5.880%	<b>5.681%</b>	7.344%	6.864%
4	7.554%	5.864%	5.778%	5.873%	6.820%
5	7.427%	5.776%	5.979%	6.493%	36.008%
6	7.756%	6.356%	5.879%	5.682%	7.356%
7	7.273%	47.251%	5.890%	6.713%	7.140%

Tabel 0.25 Nilai MAPE terkecil pada proporsi data 70:30

Periode	Bawang Merah	Cabai Merah Keriting	Cabai Merah Besar	Cabai Rawit Merah	Cabai Rawit Hijau
1	37.368%	25.620%	78.611%	29.969%	32.339%
2	7.382%	7.774%	6.307%	<b>5.437%</b>	<b>11.727%</b>
3	7.460%	<b>7.144%</b>	6.408%	5.468%	11.958%

4	7.309%	7.383%	<b>6.200%</b>	5.568%	12.206%
5	7.057%	7.574%	6.388%	5.489%	11.833%
6	48.245%	7.558%	6.306%	5.578%	11.890%
7	<b>6.151%</b>	7.283%	39.032%	6.099%	44.862%

Tabel 0.26 Nilai MAPE terkecil pada proporsi data 80:20

Periode	Bawang Merah	Cabai Merah Keriting	Cabai Merah Besar	Cabai Rawit Merah	Cabai Rawit Hijau
1	34.578%	22.178%	26.575%	32.502%	19.071%
2	4.956%	4.589%	4.113%	<b>3.553%</b>	<b>6.659%</b>
3	5.192%	4.646%	<b>3.967%</b>	3.565%	7.139%
4	<b>4.830%</b>	<b>4.573%</b>	4.072%	3.649%	7.111%
5	4.839%	4.754%	4.116%	3.754%	6.720%
6	5.056%	4.643%	4.278%	3.623%	6.972%
7	29.506%	4.908%	25.718%	24.937%	6.913%

## 6.9. Perbandingan Nilai MAPE Pada Dataset Lain

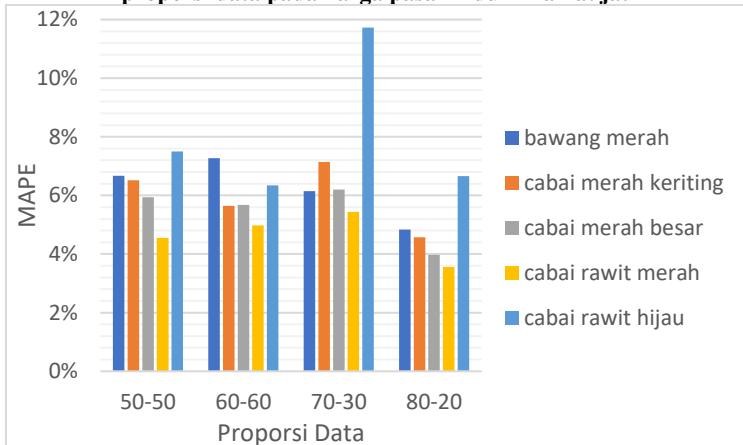
Perbandingan MAPE pada *dataset* yaitu data harga komoditi Pasar Induk Kramat Jati; bawang merah, cabe merah keriting, cabe merah besar, cabe rawit merah, dan cabe rawit hijau. Harga komoditi tersebut diujikan pada proporsi data berbeda yang dapat dilihat pada Tabel 6.27.

Tabel 0.27 Nilai MAPE setiap komoditi pada proporsi data berbeda

Komoditi	Proporsi Data			
	50:50	60:40	70:30	80:20
Bawang Merah	6.669%	7.270%	6.151%	<b>4.830%</b>
Cabai Merah Keriting	6.522%	5.647%	7.144%	<b>4.573%</b>
Cabai Merah Besar	5.936%	5.681%	6.200%	<b>3.967%</b>
Cabai Rawit Merah	4.547%	4.982%	5.437%	<b>3.553%</b>
Cabai Rawit Hijau	7.498%	<b>6.346%</b>	11.727%	6.659%

Gambar 6.28 menampilkan grafik perbandingan MAPE dari setiap komoditi yang diuji pada. Nilai MAPE terkecil diketahui berada di proporsi data 80:20 untuk komoditi bawang merah di periode ke-4, cabai merah keriting di periode ke-4, cabai merah besar di periode ke-3, dan caba rawit merah di periode ke-2. Cabai rawit hijau memiliki nilai MAPE terkecil di proporsi data 60:40 di periode ke-2.

**Gambar 0.28 Grafik perbandingan nilai MAPE terkecil di setiap proporsi data pada harga pasar induk kramat jati**



## 6.10. Kesimpulan Hasil Peramalan

Hasil peramalan harga emas dunia menggunakan maupun tidak menggunakan faktor ekonomi makro, harga minyak dunia. Hasil peramalan menggunakan metode *Recurrent Neural Network* (RNN) dapat disimpulkan sebagai berikut :

1. Pada peramalan harga emas dunia tanpa menggunakan variabel harga minyak dunia memiliki nilai MAPE terbaik sebesar 0.621% pada periode ke-5 dengan proporsi data 70:30 dan parameter *learning rate* sebesar 0.9, *momentum* 0.9, *hidden layer* 10, *sigmoid* dengan ‘*Gompertz*’, dan *rule* dengan ‘*sgd*’.
2. Pada peramalan harga emas dunia dengan menggunakan variabel harga minyak dunia memiliki nilai MAPE terbaik sebesar 0.676% pada periode ke-7 dengan proporsi data

70:30 dan parameter *learning rate* sebesar 0.9, *momentum* 0.7, *hidden layer* 26, *sigmoid* dengan ‘*Gompertz*’, dan *rule* dengan ‘*sgd*’.

3. Pada peramalan harga emas dunia baik itu menggunakan variabel tunggal maupun variabel ganda memiliki kesamaan parameter *rule* bertipe ‘*sgd*’ karena menghasilkan luaran lebih optimal untuk membangun model peramalan.
4. Peramalan harga emas dunia dengan menggunakan harga minyak dunia lebih bisa diandalkan jika terjadi perubahan harga yang terlalu tajam namun keakuratannya lebih rendah dibandingkan peramalan tanpa dengan menggunakan harga minyak dunia.
5. Pada peramalan harga emas dunia tanpa menggunakan variabel harga minyak dunia memiliki nilai MAPE paling baik dibandingkan dengan peramalan yang menggunakan variabel harga minyak dunia. Dengan kata lain, walaupun ada korelasi yang tinggi antara harga emas dan harga minyak tetapi harga minyak tidak mampu meningkatkan akurasi peramalan harga emas dunia.
6. Secara keseluruhan semakin banyak periode pada model peramalan tidak mempengaruhi penurunan nilai MAPE. Hal ini bertolak belakang dengan karakteristik RNN yang semakin banyak periode/*lag* yang digunakan maka menghasilkan performa yang semakin baik.
7. Model yang dibangun cukup handal karena model tetap menghasilkan performa yang tidak terlalu jauh berbeda walaupun menggunakan berbagai macam jenis proporsi data.
8. Selain itu, model yang dibangun dapat digunakan pada *dataset* yang berbeda. Hal ini dibuktikan dengan pengujian pada data harga komoditi Pasar Induk Kramat Jati mulai 1 September 2018 sampai dengan 31 Januari 2020. Hasilnya model dapat meningkatkan performa peramalan harga komoditi dibandingkan menggunakan metode *Radial Basis Function Neural Network* (RBFNN).

## **BAB VII**

### **KESIMPULAN DAN SARAN**

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

#### **7.1. Kesimpulan**

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

1. Model terbaik untuk peramalan harga emas tanpa faktor ekonomi makro menggunakan parameter *learning rate* sebesar 0.9, *momentum* 0.9, *hidden layer* 10, *sigmoid* dengan ‘*Gompertz*’, dan *rule* dengan ‘*sgd (stochastic gradient descent)*’. Model ini menghasilkan nilai MAPE sebesar 0.621% pada periode ke-5 dengan proporsi data 70:30.
2. Model terbaik untuk peramalan harga emas dengan faktor ekonomi makro menggunakan parameter *learning rate* sebesar 0.9, *momentum* 0.7, *hidden layer* 26, *sigmoid* dengan ‘*Gompertz*’, dan *rule* dengan ‘*sgd*’. Model ini menghasilkan nilai MAPE sebesar 0.676% pada periode ke-7 dengan proporsi data 70:30.
3. Dari grafik peramalan harga emas dunia tanpa menggunakan harga minyak dunia memiliki keakuratan yang lebih tinggi namun tidak bisa mengantisipasi adanya perubahan harga yang terlalu tajam. Sebaliknya, peramalan harga emas dunia dengan menggunakan harga minyak dunia dapat mengantisipasi adanya perubahan harga yang terlalu tajam namun keakuratannya lebih rendah dibandingkan variabel tunggal.
4. Penambahan salah satu faktor ekonomi makro yaitu harga minyak dunia tidak memberikan perbedaan yang terlalu signifikan sehingga dapat menjadi informasi tambahan bagi investor apabila ingin mempertimbangkan faktor tersebut dalam melakukan investasi untuk masa yang akan datang.

## 7.2. Saran

Dari penggerjaan tugas akhir ini, adapun beberapa saran untuk pengembangan penelitian di masa yang akan datang.

1. Pada penelitian selanjutnya, peramalan harga emas dunia dapat menggunakan arsitektur *Recurrent Neural Network* (RNN) lain seperti RNN dengan tipe model Hopfield, *Long Short-Term Memory* (LSTM), *Gate Recurrent Unit* (GRU), atau metode *Deep Learning* lainnya.
2. Melakukan optimasi nilai parameter dalam metode peramalan RNN serta mempertimbangkan dalam menggunakan parameter lain di dalam arsitektur model.
3. Melanjutkan percobaan pembelajaran model peramalan dan mengakhirinya jika nilai MAPE tidak semakin membaik pada dua periode berturut-turut.
4. Jika memungkinkan dapat menggunakan faktor ekonomi makro yang lain seperti nilai tukar mata uang, tingkat suku bunga bank, inflasi, atau *Gross Domestic Product* (GDP).

## DAFTAR PUSTAKA

- [1] B. M. L. Dirk G. Baur, “Is Gold a Hedge or a Safe Haven? An Analysis of Stocks, Bonds and Gold,” *Financial Review*, vol. 45, no. 2, pp. 217-229, 2010.
- [2] J. Y. H. J. Jianwei E., “A Novel Hybrid Model on the Prediction of Time Series and Its Application for the Gold Price Analysis and Forecasting,” *Physica A*, no. 527, pp. 0378-4371, 2019.
- [3] F. A. M. L. A. R. Sri Herawati, “Implementing Method of Ensemble Empirical Mode Decomposition and Recurrent Neural Network for Gold Price Forecasting,” *International Journal of Engineering Research and Application*, vol. VII, no. 11, pp. 39-43, 2017.
- [4] W. Kristjanpoller dan M. C. Minutolo, “Gold Price Volatility: A Forecasting Approach Using The Artificial Neural,” *Expert Systems with Applications*, no. 42, pp. 7245-7251, 2015.
- [5] “Gold Contract,” Fusion Media, [Online]. Available: <https://www.investing.com/commodities/gold>. [Diakses 1 Oktober 2019].
- [6] B. M. L. Edel Tully, “A Power GARCH Examination of The Gold Market,” *Research in International Business and Finance*, p. 316 – 325, 2007.
- [7] “Crude Oil WTI Futures,” Fusion Media, [Online]. Available: <https://www.investing.com/commodities/crude-oil-historical-data>. [Diakses 1 Oktober 2019].
- [8] M. R. S. R. Christian Pierdzioch, “A Boosting Approach to Forecasting the Volatility of Gold-Price Fluctuations Under Flexible Loss,” *Resources Policy*, no. 47, pp. 95-107, 2016.
- [9] R. V. Kawengian, “Analisis Pengaruh Investasi dan Tenaga Kerja dalam Sektor Pertanian dan Sektor Industri Guna Menentukan Strategi Pembangunan Irian Jaya,” Institut Pertanian Bogor, Bogor, 2002.

- [10] S. S. Husnan, Studi Kelayakan Proyek, Yogyakarta: UPP AMP YKPN, 2000.
- [11] S. Dipraja, Siapa Bilang Investasi Emas Butuh Modal Gede?, Jakarta: Tangga Pustaka, 2011.
- [12] Inas, Analisis Pengaruh Harga Emas Dunia, Harga Minyak Dunia, Jumlah Uang Beredar, Inflasi, Kurs Rupiah terhadap Jakarta Islamic Index (JII) Periode 2011-2015, Jakarta: UIN Syarif Hidayatullah, 2016.
- [13] M. Samsul, Pasar Modal dan Manajemen Portofolio, Surabaya: Erlangga, 2006.
- [14] S. Handiani, “Pengaruh Harga Emas Dunia, Harga Minyak Dunia dan Nilai Tukar Dolar Amerika/Rupiah terhadap Indeks Harga Saham Gabungan pada Periode 2008-2013,” *e-Journal Graduate UNPAR*, vol. 1, no. 1, pp. 85-93, 2014.
- [15] L. Stepvhanie, Peramalan Penjualan Produk Susu Bayi dengan Metode Grey System Theory dan Neural Network, Depok: Universitas Indonesia, 2012.
- [16] J. E. W. D. W. Hanke, Business Forecasting 9th edition, Harlow: Prentice Hall, 2009.
- [17] P. L. P. Supriyanto, Peramalan Jumlah Penumpang Penerbangan di Terminal 1 Bandara Internasional Juanda Menggunakan Metode ARIMA BOX-JENKINS dan Hybrid Autoregressive Integrated Moving Averageartificial Neural Network (ARIMA-ANN), Surabaya: Institut Teknologi Sepuluh Nopember, 2017.
- [18] S. Sumathi dan S. Panneerselvam, Computational Intelligence Paradigms : Theory and Applications using MATLAB, LLC: Taylor and Francis Group, 2010.
- [19] A. J. S. C. M. M. & M. R. Tomas Mikolov, “Learning Longer Memory in Recurrent Neural Network,” dalam *International Conference on Learning Representations (ICLR)*, New York, 2015.
- [20] J. L. Elman, “Finding Structure in Time,” *Cognitive Science*, pp. 179-211, 1990.

- [21] J. B. Ahire, “Artificial Neural Networks: Some Misconceptions (Part 2),” DZone, 22 April 2018. [Online]. Available: <https://dzone.com/articles/artificial-neural-networks-some-misconceptions-par>. [Diakses 7 November 2019].
- [22] K. K. T. Zhang Yi, Convergence Analysis of Recurrent Neural Networks, Minnesota: Kluwer Academic Publishers, 2014.
- [23] W. U. S. Nurul Chamidah, “Pengaruh Normalisasi Data pada Jaringan Syaraf Tiruan Backpropagation Gradient Descent Adaptive Gain (BPGDAG) untuk Klasifikasi,” *ITSMART*, vol. I, no. 1, pp. 28-33, 2012.
- [24] H. K. Sungil Kim, “A New Metric of Absolute Percentage Error for Intermittent Demand Forecasts,” *International Journal of Forecasting*, vol. 32, no. 3, pp. 669-679, 2016.
- [25] C. H. Aprilianto, S. Kumalaningsih dan I. Santoso, “Penerapan Jaringan Syaraf Tiruan Untuk Peramalan Penjualan Dalam Mendukung Pengembangan Agroindustri Coklat di Kabupaten Blitar,” *HABITAT*, vol. 29, no. 3, pp. 129-137, 2018.
- [26] S. M. Nikolay Kyurkchiev, “The Gompertz Sigmoid Function,” dalam *Sigmoid Functions: Some Approximation, and Modelling Aspects*, 2015, pp. 57-72.
- [27] J. H. M. Daniel Jurafsky, “Neural Networks and Neural,” dalam *Speech and Language Processing*, New Jersey, Pearson Prentice Hall, 2019, p. 2.
- [28] J. Brownlee, “Difference Between a Batch and an Epoch in a Neural Network,” Machine Learning Mastery Pty. Ltd., 20 July 2018. [Online]. Available: <https://machinelearningmastery.com/difference-between-a-batch-and-an-epoch/>. [Diakses 30 June 2020].
- [29] J. W. G. Putra, “Pengenalan Konsep Pembelajaran Mesin dan Deep Learning,” 25 Juli 2019. [Online]. Available: <https://wiragotama.github.io/resources/ebook/part3/JWGP-intro-to-ml-part3-secured.pdf>. [Diakses 24 Juni 2020].

- [30] “7 Jenis Investasi dengan Keuntungan dan Kerugiannya (Lengkap),” [Online]. Available: <https://www.seputarpengetahuan.co.id/2016/01/7-jenis-investasi-lengkap-dengan-keuntungan-dan-kerugiannya.html>. [Diakses 2019 September 22].

## BIODATA PENULIS



Penulis, bernama Ludia Rosema Dewi lahir di Serang, Banten pada tanggal 14 Juli 1998. Anak kedua dari pasangan Hadi Santoso dan Luluk Hariyati. Penulis menyelesaikan pendidikan formal di SDIT Raudhatul Jannah, SMP Negeri 1 Kota Cilegon, dan SMA Negeri 1 Kota Serang.

Pada Tahun 2016 pasca kelulusan SMA, penulis melanjutkan pendidikan sebagai mahasiswa di Jurusan Sistem Informasi Fakultas Teknologi Elektro dan Informatika Cerdas – Institut Teknologi Sepuluh Nopember (FTEIC ITS) Surabaya melalui jalur Seleksi Nasional Masuk Perguruan Tinggi Negeri (SNMPTN) terdaftar sebagai mahasiswa dengan NRP 05211640000025. Selama menjadi mahasiswa, penulis mengikuti berbagai kegiatan kemahasiswaan seperti beberapa kepanitian serta pernah menjabat sebagai Staff Departemen Media Informasi BEM FTIK – ITS (Badan Eksekutif Mahasiswa Fakultas Teknologi Informasi dan Komunikasi – Institut Teknologi Sepuluh Nopember) dan pada tahun ketiga menjabat sebagai Sekretaris Departemen Media Informasi BEM FTIK – ITS dan bendahara umum KISI – ITS (Kajian Islam Sistem Informasi – Institut Teknologi Sepuluh Nopember). Di bidang akademik, penulis aktif menjadi asisten laboratorium Rekayasa Data dan Intelegensi Bisnis.

Pada tahun keempat, karena penulis memiliki ketertarikan di bidang pengolahan data, maka penulis mengambil bidang minat Rekayasa Data dan Intelegensi Bisnis (RDIB) dengan topik tugas akhir peramalan data. Penulis dapat dihubungi melalui *email* di [25ludiarosemadewi@gmail.com](mailto:25ludiarosemadewi@gmail.com).

*Halaman ini sengaja dikosongkan*

## LAMPIRAN A

Data harga emas dunia dan data harga minyak dunia yang digunakan sebagai *input* model peramalan RNN (*Recurrent Neural Network*) dari tanggal 1 Januari 2014 sampai dengan 1 Januari 2019.

Tanggal	Emas	Minyak
1-Jan-19	1,283.35	45.89
31-Dec-18	1,312.50	45.41
28-Dec-18	1,313.70	45.33
27-Dec-18	1,311.90	44.61
26-Dec-18	1,303.70	46.22
25-Dec-18	1,270.75	43.16
24-Dec-18	1,302.40	42.53
21-Dec-18	1,288.60	45.59
20-Dec-18	1,298.60	45.88
19-Dec-18	1,286.80	47.2
18-Dec-18	1,284.00	46.24
17-Dec-18	1,282.60	49.88
14-Dec-18	1,272.20	51.2
13-Dec-18	1,278.40	52.58
12-Dec-18	1,281.00	51.15
11-Dec-18	1,278.10	51.65
10-Dec-18	1,280.00	51
7-Dec-18	1,283.60	52.61
6-Dec-18	1,274.30	51.49
5-Dec-18	1,273.40	52.89
4-Dec-18	1,277.40	53.25
3-Dec-18	1,270.20	52.95
30-Nov-18	1,256.50	50.93
29-Nov-18	1,260.80	51.45
28-Nov-18	1,260.20	50.29

27-Nov-18	1,250.40	51.56
26-Nov-18	1,259.70	51.63
23-Nov-18	1,260.00	50.42
22-Nov-18	1,228.00	54.02
21-Nov-18	1,264.70	54.63
20-Nov-18	1,257.50	53.43
19-Nov-18	1,261.60	56.76
16-Nov-18	1,259.00	56.46
15-Nov-18	1,251.70	56.46
14-Nov-18	1,246.20	56.25
13-Nov-18	1,237.50	55.69
12-Nov-18	1,239.60	59.93
9-Nov-18	1,245.00	60.19
8-Nov-18	1,262.00	60.67
7-Nov-18	1,265.40	61.67
6-Nov-18	1,263.00	62.21
5-Nov-18	1,269.00	63.1
2-Nov-18	1,269.90	63.14
1-Nov-18	1,274.80	63.69
31-Oct-18	1,250.80	65.31
30-Oct-18	1,261.50	66.18
29-Oct-18	1,263.70	67.04
26-Oct-18	1,272.30	67.59
25-Oct-18	1,269.00	67.33
24-Oct-18	1,267.60	66.82
23-Oct-18	1,273.50	66.43
22-Oct-18	1,261.30	69.17
19-Oct-18	1,265.30	69.12
18-Oct-18	1,266.60	68.65
17-Oct-18	1,263.40	69.75
16-Oct-18	1,267.30	71.92

15-Oct-18	1,266.90	71.78
12-Oct-18	1,258.10	71.34
11-Oct-18	1,264.00	70.97
10-Oct-18	1,229.40	73.17
9-Oct-18	1,227.80	74.96
8-Oct-18	1,224.90	74.29
5-Oct-18	1,242.20	74.34
4-Oct-18	1,237.50	74.33
3-Oct-18	1,238.70	76.41
2-Oct-18	1,242.70	75.23
1-Oct-18	1,227.00	75.3
28-Sep-18	1,231.30	73.25
27-Sep-18	1,222.40	72.12
26-Sep-18	1,234.40	71.57
25-Sep-18	1,240.80	72.28
24-Sep-18	1,240.00	72.08
21-Sep-18	1,236.90	70.78
20-Sep-18	1,247.00	70.8
19-Sep-18	1,244.10	71.12
18-Sep-18	1,238.30	69.85
17-Sep-18	1,241.20	68.91
14-Sep-18	1,236.60	68.99
13-Sep-18	1,243.80	68.59
12-Sep-18	1,246.60	70.37
11-Sep-18	1,237.60	69.25
10-Sep-18	1,235.00	67.54
7-Sep-18	1,235.50	67.75
6-Sep-18	1,239.10	67.77
5-Sep-18	1,236.00	68.72
4-Sep-18	1,233.60	69.87
3-Sep-18	1,206.30	70.12

31-Aug-18	1,241.10	69.8
30-Aug-18	1,239.50	70.25
29-Aug-18	1,246.50	69.51
28-Aug-18	1,249.60	68.53
27-Aug-18	1,251.20	68.87
24-Aug-18	1,248.20	68.72
23-Aug-18	1,228.40	67.83
22-Aug-18	1,238.20	67.86
21-Aug-18	1,234.90	67.35
20-Aug-18	1,229.60	66.43
17-Aug-18	1,219.30	65.91
16-Aug-18	1,219.20	65.46
15-Aug-18	1,220.20	65.01
14-Aug-18	1,236.40	67.04
13-Aug-18	1,234.60	67.2
10-Aug-18	1,255.10	67.63
9-Aug-18	1,256.30	66.81
8-Aug-18	1,257.30	66.94
7-Aug-18	1,254.70	69.17
6-Aug-18	1,254.10	69.01
3-Aug-18	1,259.70	68.49
2-Aug-18	1,256.50	68.96
1-Aug-18	1,264.30	67.66
31-Jul-18	1,270.10	68.76
30-Jul-18	1,268.00	70.13
27-Jul-18	1,269.30	68.69
26-Jul-18	1,271.80	69.61
25-Jul-18	1,277.40	69.3
24-Jul-18	1,271.50	68.52
23-Jul-18	1,271.40	67.89
20-Jul-18	1,277.50	70.46

19-Jul-18	1,271.10	69.46
18-Jul-18	1,275.70	68.76
17-Jul-18	1,275.30	68.08
16-Jul-18	1,288.20	68.06
13-Jul-18	1,289.70	71.01
12-Jul-18	1,295.40	70.33
11-Jul-18	1,293.30	70.38
10-Jul-18	1,305.10	74.11
9-Jul-18	1,309.00	73.85
6-Jul-18	1,304.80	73.8
5-Jul-18	1,307.60	72.94
4-Jul-18	1,258.10	74.13
3-Jul-18	1,302.40	74.14
2-Jul-18	1,289.90	73.94
29-Jun-18	1,303.90	74.15
28-Jun-18	1,300.20	73.45
27-Jun-18	1,305.70	72.76
26-Jun-18	1,309.60	70.53
25-Jun-18	1,319.20	68.08
22-Jun-18	1,321.30	68.58
21-Jun-18	1,321.00	65.54
20-Jun-18	1,325.30	66.22
19-Jun-18	1,329.20	65.07
18-Jun-18	1,331.10	65.85
15-Jun-18	1,329.30	65.06
14-Jun-18	1,360.60	66.89
13-Jun-18	1,353.50	66.64
12-Jun-18	1,351.80	66.36
11-Jun-18	1,355.50	66.1
8-Jun-18	1,354.40	65.74
7-Jun-18	1,354.40	65.95

6-Jun-18	1,353.50	64.73
5-Jun-18	1,354.10	65.52
4-Jun-18	1,349.40	64.75
1-Jun-18	1,350.90	65.81
31-May-18	1,355.90	67.04
30-May-18	1,357.60	68.21
29-May-18	1,354.60	66.73
28-May-18	1,297.60	67.05
25-May-18	1,361.40	67.88
24-May-18	1,362.40	70.71
23-May-18	1,347.40	71.84
22-May-18	1,350.00	72.13
21-May-18	1,349.00	72.24
18-May-18	1,349.20	71.28
17-May-18	1,347.90	71.49
16-May-18	1,350.10	71.49
15-May-18	1,348.50	71.31
14-May-18	1,376.60	70.96
11-May-18	1,379.10	70.7
10-May-18	1,380.80	71.36
9-May-18	1,371.70	71.14
8-May-18	1,372.50	69.06
7-May-18	1,372.90	70.73
4-May-18	1,373.40	69.72
3-May-18	1,371.10	68.43
2-May-18	1,364.00	67.93
1-May-18	1,365.10	67.25
30-Apr-18	1,377.80	68.57
27-Apr-18	1,382.30	68.1
26-Apr-18	1,376.70	68.19
25-Apr-18	1,381.60	68.05

24-Apr-18	1,391.80	67.7
23-Apr-18	1,382.70	68.64
20-Apr-18	1,396.90	68.38
19-Apr-18	1,407.50	68.29
18-Apr-18	1,412.20	68.47
17-Apr-18	1,408.00	66.52
16-Apr-18	1,409.30	66.22
13-Apr-18	1,406.60	67.39
12-Apr-18	1,400.30	67.07
11-Apr-18	1,418.90	66.82
10-Apr-18	1,404.40	65.51
9-Apr-18	1,398.50	63.42
6-Apr-18	1,394.80	62.06
5-Apr-18	1,387.00	63.54
4-Apr-18	1,398.60	63.37
3-Apr-18	1,395.40	63.51
2-Apr-18	1,404.70	63.01
30-Mar-18	1,384.90	64.94
29-Mar-18	1,384.90	64.94
28-Mar-18	1,387.80	64.38
27-Mar-18	1,406.70	65.25
26-Mar-18	1,419.90	65.55
23-Mar-18	1,413.90	65.88
22-Mar-18	1,391.10	64.3
21-Mar-18	1,385.50	65.17
20-Mar-18	1,375.10	63.4
19-Mar-18	1,380.60	62.06
16-Mar-18	1,375.20	62.34
15-Mar-18	1,380.60	61.19
14-Mar-18	1,388.60	60.96
13-Mar-18	1,390.30	60.71

12-Mar-18	1,383.70	61.36
9-Mar-18	1,386.90	62.04
8-Mar-18	1,384.00	60.12
7-Mar-18	1,389.50	61.15
6-Mar-18	1,397.50	62.6
5-Mar-18	1,382.10	62.57
2-Mar-18	1,385.80	61.25
1-Mar-18	1,367.60	60.99
28-Feb-18	1,380.80	61.64
27-Feb-18	1,381.30	63.01
26-Feb-18	1,394.80	63.91
23-Feb-18	1,390.70	63.55
22-Feb-18	1,393.10	62.77
21-Feb-18	1,392.30	61.68
20-Feb-18	1,390.10	61.9
19-Feb-18	1,347.80	62.38
16-Feb-18	1,415.00	61.68
15-Feb-18	1,413.70	61.34
14-Feb-18	1,415.10	60.6
13-Feb-18	1,387.00	59.19
12-Feb-18	1,383.10	59.29
9-Feb-18	1,372.30	59.2
8-Feb-18	1,376.40	61.15
7-Feb-18	1,372.30	61.79
6-Feb-18	1,387.00	63.39
5-Feb-18	1,394.50	64.15
2-Feb-18	1,396.20	65.45
1-Feb-18	1,406.70	65.8
31-Jan-18	1,401.70	64.73
30-Jan-18	1,398.50	64.5
29-Jan-18	1,403.60	65.56

26-Jan-18	1,416.00	66.14
25-Jan-18	1,425.90	65.51
24-Jan-18	1,419.10	65.61
23-Jan-18	1,398.20	64.47
22-Jan-18	1,394.00	63.49
19-Jan-18	1,394.30	63.37
18-Jan-18	1,387.40	63.95
17-Jan-18	1,399.70	63.97
16-Jan-18	1,396.80	63.73
15-Jan-18	1,341.80	64.73
12-Jan-18	1,394.40	64.3
11-Jan-18	1,380.10	63.8
10-Jan-18	1,377.00	63.57
9-Jan-18	1,370.00	62.96
8-Jan-18	1,376.80	61.73
5-Jan-18	1,378.40	61.44
4-Jan-18	1,377.40	62.01
3-Jan-18	1,374.20	61.63
2-Jan-18	1,370.50	60.37
1-Jan-18	1,308.70	60.24
29-Dec-17	1,362.60	60.42
28-Dec-17	1,350.10	59.84
27-Dec-17	1,343.00	59.64
26-Dec-17	1,339.20	59.97
25-Dec-17	1,277.90	58.59
22-Dec-17	1,330.50	58.47
21-Dec-17	1,322.00	58.36
20-Dec-17	1,321.10	58.09
19-Dec-17	1,315.50	57.46
18-Dec-17	1,316.30	57.16
15-Dec-17	1,308.10	57.3

14-Dec-17	1,307.90	57.04
13-Dec-17	1,299.40	56.6
12-Dec-17	1,292.60	57.14
11-Dec-17	1,297.50	57.99
8-Dec-17	1,298.80	57.36
7-Dec-17	1,303.70	56.69
6-Dec-17	1,316.90	55.96
5-Dec-17	1,315.80	57.62
4-Dec-17	1,328.70	57.47
1-Dec-17	1,333.50	58.36
30-Nov-17	1,328.00	57.4
29-Nov-17	1,337.10	57.3
28-Nov-17	1,349.70	57.99
27-Nov-17	1,349.40	58.11
24-Nov-17	1,342.30	58.95
23-Nov-17	1,291.66	58.38
22-Nov-17	1,347.10	58.02
21-Nov-17	1,336.50	56.83
20-Nov-17	1,329.40	56.09
17-Nov-17	1,350.10	56.55
16-Nov-17	1,331.50	55.14
15-Nov-17	1,330.80	55.33
14-Nov-17	1,336.30	55.7
13-Nov-17	1,332.50	56.76
10-Nov-17	1,327.10	56.74
9-Nov-17	1,339.40	57.17
8-Nov-17	1,334.90	56.81
7-Nov-17	1,326.50	57.2
6-Nov-17	1,332.40	57.35
3-Nov-17	1,319.80	55.64
2-Nov-17	1,328.30	54.54

1-Nov-17	1,327.50	54.3
31-Oct-17	1,320.60	54.38
30-Oct-17	1,327.80	54.15
27-Oct-17	1,322.00	53.9
26-Oct-17	1,320.30	52.64
25-Oct-17	1,329.70	52.18
24-Oct-17	1,328.40	52.47
23-Oct-17	1,331.10	51.9
20-Oct-17	1,330.40	51.47
19-Oct-17	1,340.10	51.29
18-Oct-17	1,333.50	52.04
17-Oct-17	1,336.70	51.88
16-Oct-17	1,353.90	51.87
13-Oct-17	1,354.70	51.45
12-Oct-17	1,346.60	50.6
11-Oct-17	1,338.80	51.3
10-Oct-17	1,343.70	50.92
9-Oct-17	1,334.70	49.58
6-Oct-17	1,324.30	49.29
5-Oct-17	1,322.60	50.79
4-Oct-17	1,325.60	49.98
3-Oct-17	1,323.40	50.42
2-Oct-17	1,324.70	50.58
29-Sep-17	1,333.20	51.67
28-Sep-17	1,336.90	51.56
27-Sep-17	1,336.30	52.14
26-Sep-17	1,349.70	51.88
25-Sep-17	1,359.20	52.22
22-Sep-17	1,345.10	50.66
21-Sep-17	1,342.40	50.55
20-Sep-17	1,364.00	50.41

19-Sep-17	1,358.30	49.48
18-Sep-17	1,357.40	49.91
15-Sep-17	1,372.20	49.89
14-Sep-17	1,376.30	49.89
13-Sep-17	1,373.80	49.3
12-Sep-17	1,378.90	48.23
11-Sep-17	1,381.20	48.07
8-Sep-17	1,396.40	47.48
7-Sep-17	1,395.10	49.09
6-Sep-17	1,383.00	49.16
5-Sep-17	1,388.30	48.66
4-Sep-17	1,338.08	47.41
1-Sep-17	1,374.20	47.29
31-Aug-17	1,365.60	47.23
30-Aug-17	1,358.00	45.96
29-Aug-17	1,362.80	46.44
28-Aug-17	1,359.70	46.57
25-Aug-17	1,341.90	47.87
24-Aug-17	1,336.00	47.43
23-Aug-17	1,338.80	48.41
22-Aug-17	1,335.50	47.64
21-Aug-17	1,341.00	47.37
18-Aug-17	1,335.70	48.51
17-Aug-17	1,336.80	47.09
16-Aug-17	1,327.50	46.78
15-Aug-17	1,324.20	47.55
14-Aug-17	1,334.80	47.59
11-Aug-17	1,338.10	48.82
10-Aug-17	1,334.50	48.59
9-Aug-17	1,323.70	49.56
8-Aug-17	1,307.10	49.17

7-Aug-17	1,308.70	49.39
4-Aug-17	1,308.40	49.58
3-Aug-17	1,318.30	49.03
2-Aug-17	1,322.20	49.59
1-Aug-17	1,323.00	49.16
31-Jul-17	1,317.20	50.17
28-Jul-17	1,319.10	49.71
27-Jul-17	1,310.20	49.04
26-Jul-17	1,298.90	48.75
25-Jul-17	1,300.90	47.89
24-Jul-17	1,303.10	46.34
21-Jul-17	1,303.60	45.77
20-Jul-17	1,294.80	46.79
19-Jul-17	1,291.40	47.12
18-Jul-17	1,291.20	46.4
17-Jul-17	1,283.10	46.02
14-Jul-17	1,276.50	46.54
13-Jul-17	1,266.20	46.08
12-Jul-17	1,268.90	45.49
11-Jul-17	1,265.40	45.04
10-Jul-17	1,263.70	44.4
7-Jul-17	1,260.10	44.23
6-Jul-17	1,274.40	45.52
5-Jul-17	1,271.60	45.13
4-Jul-17	1,227.55	47.13
3-Jul-17	1,268.60	47.07
30-Jun-17	1,291.70	46.04
29-Jun-17	1,295.40	44.93
28-Jun-17	1,298.50	44.74
27-Jun-17	1,296.10	44.24
26-Jun-17	1,295.40	43.38

23-Jun-17	1,305.40	43.01
22-Jun-17	1,298.10	42.74
21-Jun-17	1,294.60	42.53
20-Jun-17	1,292.50	43.23
19-Jun-17	1,296.10	44.2
16-Jun-17	1,305.80	44.74
15-Jun-17	1,303.90	44.46
14-Jun-17	1,325.30	44.73
13-Jun-17	1,318.30	46.46
12-Jun-17	1,318.60	46.08
9-Jun-17	1,321.00	45.83
8-Jun-17	1,329.00	45.64
7-Jun-17	1,342.70	45.72
6-Jun-17	1,347.10	48.19
5-Jun-17	1,332.70	47.4
2-Jun-17	1,330.20	47.66
1-Jun-17	1,320.30	48.36
31-May-17	1,325.60	48.32
30-May-17	1,316.20	49.66
29-May-17	1,266.69	49.97
26-May-17	1,321.90	49.8
25-May-17	1,310.40	48.9
24-May-17	1,306.80	51.36
23-May-17	1,309.20	51.47
22-May-17	1,315.10	50.73
19-May-17	1,307.00	50.33
18-May-17	1,306.30	49.35
17-May-17	1,313.30	49.07
16-May-17	1,291.50	48.66
15-May-17	1,285.10	48.85
12-May-17	1,282.80	47.84

11-May-17	1,280.00	47.83
10-May-17	1,274.70	47.33
9-May-17	1,272.20	45.88
8-May-17	1,283.20	46.43
5-May-17	1,282.90	46.22
4-May-17	1,284.50	45.52
3-May-17	1,304.70	47.82
2-May-17	1,313.20	47.66
1-May-17	1,311.70	48.84
28-Apr-17	1,324.20	49.33
27-Apr-17	1,321.80	48.97
26-Apr-17	1,320.10	49.62
25-Apr-17	1,323.10	49.56
24-Apr-17	1,332.90	49.23
21-Apr-17	1,344.10	49.62
20-Apr-17	1,338.80	50.27
19-Apr-17	1,337.60	50.44
18-Apr-17	1,348.00	52.41
17-Apr-17	1,346.90	52.65
14-Apr-17	1,289.65	53.18
13-Apr-17	1,343.80	53.18
12-Apr-17	1,334.40	53.11
11-Apr-17	1,330.50	53.4
10-Apr-17	1,310.40	53.08
7-Apr-17	1,313.90	52.24
6-Apr-17	1,309.50	51.7
5-Apr-17	1,304.60	51.15
4-Apr-17	1,314.50	51.03
3-Apr-17	1,310.40	50.24
31-Mar-17	1,307.50	50.6
30-Mar-17	1,304.40	50.35

29-Mar-17	1,313.20	49.51
28-Mar-17	1,315.20	48.37
27-Mar-17	1,315.10	47.73
24-Mar-17	1,308.10	47.97
23-Mar-17	1,306.20	47.7
22-Mar-17	1,309.20	48.04
21-Mar-17	1,306.70	47.34
20-Mar-17	1,294.90	48.22
17-Mar-17	1,291.30	48.78
16-Mar-17	1,288.40	48.75
15-Mar-17	1,262.00	48.86
14-Mar-17	1,264.00	47.72
13-Mar-17	1,264.30	48.4
10-Mar-17	1,261.70	48.49
9-Mar-17	1,263.40	49.28
8-Mar-17	1,269.60	50.28
7-Mar-17	1,275.40	53.14
6-Mar-17	1,285.00	53.2
3-Mar-17	1,286.50	53.33
2-Mar-17	1,291.60	52.61
1-Mar-17	1,308.80	53.83
28-Feb-17	1,312.00	54.01
27-Feb-17	1,316.80	54.05
24-Feb-17	1,316.10	53.99
23-Feb-17	1,309.40	54.45
22-Feb-17	1,291.00	53.59
21-Feb-17	1,296.90	54.06
20-Feb-17	1,238.20	53.97
17-Feb-17	1,297.10	53.4
16-Feb-17	1,300.40	53.36
15-Feb-17	1,291.90	53.11

14-Feb-17	1,282.60	53.2
13-Feb-17	1,282.60	52.93
10-Feb-17	1,292.20	53.86
9-Feb-17	1,293.10	53
8-Feb-17	1,296.00	52.34
7-Feb-17	1,294.10	52.17
6-Feb-17	1,291.00	53.01
3-Feb-17	1,279.90	53.83
2-Feb-17	1,278.30	53.54
1-Feb-17	1,267.20	53.88
31-Jan-17	1,269.50	52.81
30-Jan-17	1,254.10	52.63
27-Jan-17	1,249.40	53.17
26-Jan-17	1,250.60	53.78
25-Jan-17	1,258.80	52.75
24-Jan-17	1,271.80	53.18
23-Jan-17	1,276.60	52.75
20-Jan-17	1,266.90	52.42
19-Jan-17	1,263.20	51.37
18-Jan-17	1,273.40	51.08
17-Jan-17	1,275.10	52.48
16-Jan-17	1,202.85	52.52
13-Jan-17	1,259.00	52.37
12-Jan-17	1,261.00	53.01
11-Jan-17	1,257.70	52.25
10-Jan-17	1,246.20	50.82
9-Jan-17	1,245.30	51.96
6-Jan-17	1,233.40	53.99
5-Jan-17	1,239.80	53.76
4-Jan-17	1,224.80	53.26
3-Jan-17	1,222.40	52.33

2-Jan-17	1,151.05	54.03
30-Dec-16	1,212.20	53.72
29-Dec-16	1,218.90	53.77
28-Dec-16	1,201.70	54.06
27-Dec-16	1,199.60	53.9
26-Dec-16	1,134.55	53.19
23-Dec-16	1,194.50	53.02
22-Dec-16	1,191.50	52.95
21-Dec-16	1,194.20	52.49
20-Dec-16	1,194.70	52.23
19-Dec-16	1,203.60	52.12
16-Dec-16	1,198.60	51.9
15-Dec-16	1,190.80	50.9
14-Dec-16	1,219.10	51.04
13-Dec-16	1,214.40	52.98
12-Dec-16	1,221.10	52.83
9-Dec-16	1,216.80	51.5
8-Dec-16	1,227.20	50.84
7-Dec-16	1,231.40	49.77
6-Dec-16	1,219.80	50.93
5-Dec-16	1,226.50	51.79
2-Dec-16	1,227.20	51.68
1-Dec-16	1,218.50	51.06
30-Nov-16	1,223.20	49.44
29-Nov-16	1,240.30	45.23
28-Nov-16	1,243.40	47.08
25-Nov-16	1,230.30	46.06
24-Nov-16	1,185.55	47.98
23-Nov-16	1,241.70	47.96
22-Nov-16	1,262.80	48.03
21-Nov-16	1,261.60	47.49

18-Nov-16	1,261.20	45.69
17-Nov-16	1,268.60	45.42
16-Nov-16	1,275.10	45.57
15-Nov-16	1,275.70	45.81
14-Nov-16	1,271.70	43.32
11-Nov-16	1,269.10	43.41
10-Nov-16	1,313.00	44.66
9-Nov-16	1,322.10	45.27
8-Nov-16	1,322.60	44.98
7-Nov-16	1,326.80	44.89
4-Nov-16	1,352.10	44.07
3-Nov-16	1,350.20	44.66
2-Nov-16	1,354.40	45.34
1-Nov-16	1,334.40	46.67
31-Oct-16	1,319.30	46.86
28-Oct-16	1,322.70	48.7
27-Oct-16	1,315.60	49.72
26-Oct-16	1,310.70	49.18
25-Oct-16	1,317.70	49.96
24-Oct-16	1,306.30	50.52
21-Oct-16	1,312.10	50.85
20-Oct-16	1,312.60	50.43
19-Oct-16	1,314.30	51.6
18-Oct-16	1,307.50	50.29
17-Oct-16	1,300.70	49.94
14-Oct-16	1,299.30	50.35
13-Oct-16	1,301.20	50.44
12-Oct-16	1,296.60	50.18
11-Oct-16	1,298.40	50.79
10-Oct-16	1,302.80	51.35
7-Oct-16	1,293.40	49.81

6-Oct-16	1,294.40	50.44
5-Oct-16	1,310.20	49.83
4-Oct-16	1,311.00	48.69
3-Oct-16	1,354.80	48.81
30-Sep-16	1,359.30	48.24
29-Sep-16	1,368.00	47.83
28-Sep-16	1,365.60	47.05
27-Sep-16	1,372.70	44.67
26-Sep-16	1,386.60	45.93
23-Sep-16	1,383.70	44.48
22-Sep-16	1,386.70	46.32
21-Sep-16	1,374.90	45.34
20-Sep-16	1,361.30	43.44
19-Sep-16	1,360.80	43.3
16-Sep-16	1,353.50	43.03
15-Sep-16	1,361.30	43.91
14-Sep-16	1,369.70	43.58
13-Sep-16	1,367.20	44.9
12-Sep-16	1,370.80	46.29
9-Sep-16	1,379.50	45.88
8-Sep-16	1,386.60	47.62
7-Sep-16	1,393.50	45.5
6-Sep-16	1,397.50	44.83
5-Sep-16	1,331.10	45.07
2-Sep-16	1,371.70	44.44
1-Sep-16	1,359.00	43.16
31-Aug-16	1,354.00	44.7
30-Aug-16	1,360.60	46.35
29-Aug-16	1,370.50	46.98
26-Aug-16	1,369.30	47.64
25-Aug-16	1,370.10	47.33

24-Aug-16	1,376.50	46.77
23-Aug-16	1,393.90	48.1
22-Aug-16	1,391.30	47.05
19-Aug-16	1,394.10	48.52
18-Aug-16	1,405.20	48.22
17-Aug-16	1,396.70	46.79
16-Aug-16	1,405.10	46.58
15-Aug-16	1,396.70	45.74
12-Aug-16	1,392.90	44.49
11-Aug-16	1,400.10	43.49
10-Aug-16	1,401.70	41.71
9-Aug-16	1,396.70	42.77
8-Aug-16	1,391.40	43.02
5-Aug-16	1,394.00	41.8
4-Aug-16	1,414.00	41.93
3-Aug-16	1,410.00	40.83
2-Aug-16	1,415.50	39.51
1-Aug-16	1,402.30	40.06
29-Jul-16	1,401.80	41.6
28-Jul-16	1,384.90	41.14
27-Jul-16	1,378.10	41.92
26-Jul-16	1,369.60	42.92
25-Jul-16	1,368.30	43.13
22-Jul-16	1,372.50	44.19
21-Jul-16	1,379.20	44.75
20-Jul-16	1,366.70	44.94
19-Jul-16	1,379.30	44.65
18-Jul-16	1,375.90	45.24
15-Jul-16	1,374.00	45.95
14-Jul-16	1,378.20	45.68
13-Jul-16	1,389.50	44.75

12-Jul-16	1,381.20	46.8
11-Jul-16	1,401.80	44.76
8-Jul-16	1,402.50	45.41
7-Jul-16	1,405.50	45.14
6-Jul-16	1,411.70	47.43
5-Jul-16	1,403.30	46.6
4-Jul-16	1,352.00	48.65
1-Jul-16	1,383.20	48.99
30-Jun-16	1,363.90	48.33
29-Jun-16	1,370.30	49.88
28-Jun-16	1,361.10	47.85
27-Jun-16	1,367.70	46.33
24-Jun-16	1,365.70	47.64
23-Jun-16	1,306.60	50.11
22-Jun-16	1,311.70	49.13
21-Jun-16	1,314.20	48.85
20-Jun-16	1,333.80	49.37
17-Jun-16	1,333.90	47.98
16-Jun-16	1,336.60	46.21
15-Jun-16	1,326.00	48.01
14-Jun-16	1,325.60	48.49
13-Jun-16	1,328.10	48.88
10-Jun-16	1,317.00	49.07
9-Jun-16	1,313.70	50.56
8-Jun-16	1,303.30	51.23
7-Jun-16	1,288.10	50.36
6-Jun-16	1,288.70	49.69
3-Jun-16	1,283.90	48.62
2-Jun-16	1,254.20	49.17
1-Jun-16	1,256.50	49.01
31-May-16	1,258.60	49.1

30-May-16	1,212.15	49.51
27-May-16	1,256.90	49.33
26-May-16	1,262.90	49.48
25-May-16	1,266.70	49.56
24-May-16	1,272.00	48.62
23-May-16	1,294.20	48.08
20-May-16	1,295.20	47.75
19-May-16	1,295.20	48.16
18-May-16	1,313.60	48.19
17-May-16	1,314.20	48.31
16-May-16	1,311.10	47.72
13-May-16	1,308.80	46.21
12-May-16	1,307.00	46.7
11-May-16	1,311.90	46.23
10-May-16	1,300.60	44.66
9-May-16	1,302.20	43.44
6-May-16	1,329.40	44.66
5-May-16	1,307.10	44.32
4-May-16	1,310.60	43.78
3-May-16	1,329.10	43.65
2-May-16	1,333.60	44.78
29-Apr-16	1,327.70	45.92
28-Apr-16	1,303.10	46.03
27-Apr-16	1,286.50	45.33
26-Apr-16	1,279.10	44.04
25-Apr-16	1,275.80	42.64
22-Apr-16	1,265.50	43.73
21-Apr-16	1,286.20	43.18
20-Apr-16	1,289.00	42.63
19-Apr-16	1,287.50	41.08
18-Apr-16	1,267.00	39.78

15-Apr-16	1,266.40	40.36
14-Apr-16	1,258.80	41.5
13-Apr-16	1,280.60	41.76
12-Apr-16	1,293.10	42.17
11-Apr-16	1,289.10	40.36
8-Apr-16	1,274.00	39.72
7-Apr-16	1,269.00	37.26
6-Apr-16	1,255.50	37.75
5-Apr-16	1,261.20	35.89
4-Apr-16	1,251.40	35.7
1-Apr-16	1,255.60	36.79
31-Mar-16	1,267.60	38.34
30-Mar-16	1,263.60	38.32
29-Mar-16	1,273.00	38.28
28-Mar-16	1,257.40	39.39
25-Mar-16	1,216.70	39.46
24-Mar-16	1,259.10	39.46
23-Mar-16	1,260.70	39.79
22-Mar-16	1,285.50	41.45
21-Mar-16	1,279.40	39.91
18-Mar-16	1,288.70	39.44
17-Mar-16	1,300.80	40.2
16-Mar-16	1,267.60	38.46
15-Mar-16	1,266.90	36.34
14-Mar-16	1,281.10	37.18
11-Mar-16	1,295.30	38.5
10-Mar-16	1,306.80	37.84
9-Mar-16	1,290.10	38.29
8-Mar-16	1,295.70	36.5
7-Mar-16	1,297.00	37.9
4-Mar-16	1,302.30	35.92

3-Mar-16	1,287.40	34.57
2-Mar-16	1,269.70	34.66
1-Mar-16	1,257.90	34.4
29-Feb-16	1,260.00	33.75
26-Feb-16	1,245.50	32.78
25-Feb-16	1,263.70	33.07
24-Feb-16	1,263.80	32.15
23-Feb-16	1,248.10	31.87
22-Feb-16	1,233.40	31.48
19-Feb-16	1,254.10	29.64
18-Feb-16	1,249.20	30.77
17-Feb-16	1,233.90	30.66
16-Feb-16	1,227.80	29.04
15-Feb-16	1,208.10	30.6
12-Feb-16	1,257.90	29.44
11-Feb-16	1,268.80	26.21
10-Feb-16	1,219.30	27.45
9-Feb-16	1,223.40	27.94
8-Feb-16	1,224.50	29.69
5-Feb-16	1,184.30	30.89
4-Feb-16	1,184.00	31.72
3-Feb-16	1,169.60	32.28
2-Feb-16	1,156.40	29.88
1-Feb-16	1,157.80	31.62
29-Jan-16	1,146.20	33.62
28-Jan-16	1,147.80	33.22
27-Jan-16	1,148.00	32.3
26-Jan-16	1,151.40	31.45
25-Jan-16	1,136.50	30.34
22-Jan-16	1,126.70	32.19
21-Jan-16	1,127.70	29.53

20-Jan-16	1,135.80	26.55
19-Jan-16	1,119.90	28.46
18-Jan-16	1,088.50	30.02
15-Jan-16	1,121.60	29.42
14-Jan-16	1,106.40	31.2
13-Jan-16	1,120.60	30.48
12-Jan-16	1,120.30	30.44
11-Jan-16	1,131.70	31.41
8-Jan-16	1,134.90	33.16
7-Jan-16	1,145.30	33.27
6-Jan-16	1,134.50	33.97
5-Jan-16	1,121.00	35.97
4-Jan-16	1,118.10	36.76
1-Jan-16	1,103.40	37.04
31-Dec-15	1,103.40	37.04
30-Dec-15	1,103.20	36.6
29-Dec-15	1,111.00	37.87
28-Dec-15	1,110.50	36.81
25-Dec-15	1,118.30	38.1
24-Dec-15	1,118.30	38.1
23-Dec-15	1,110.60	37.5
22-Dec-15	1,116.40	36.14
21-Dec-15	1,122.90	34.74
18-Dec-15	1,105.70	34.73
17-Dec-15	1,090.50	34.95
16-Dec-15	1,117.70	35.52
15-Dec-15	1,102.20	37.35
14-Dec-15	1,103.80	36.31
11-Dec-15	1,116.20	35.62
10-Dec-15	1,112.70	36.76
9-Dec-15	1,117.30	37.16

8-Dec-15	1,116.40	37.51
7-Dec-15	1,116.30	37.65
4-Dec-15	1,125.20	39.97
3-Dec-15	1,102.60	41.08
2-Dec-15	1,094.40	39.94
1-Dec-15	1,104.00	41.85
30-Nov-15	1,105.90	41.65
27-Nov-15	1,096.50	41.71
26-Nov-15	1,070.80	42.59
25-Nov-15	1,110.00	43.04
24-Nov-15	1,113.20	42.87
23-Nov-15	1,106.30	41.75
20-Nov-15	1,115.40	40.39
19-Nov-15	1,117.20	40.54
18-Nov-15	1,108.50	40.75
17-Nov-15	1,108.50	40.67
16-Nov-15	1,124.10	41.74
13-Nov-15	1,122.90	40.74
12-Nov-15	1,122.90	41.75
11-Nov-15	1,127.00	42.93
10-Nov-15	1,131.00	44.21
9-Nov-15	1,130.80	43.87
6-Nov-15	1,129.50	44.29
5-Nov-15	1,141.70	45.2
4-Nov-15	1,142.80	46.32
3-Nov-15	1,150.20	47.9
2-Nov-15	1,172.00	46.14
30-Oct-15	1,176.80	46.59
29-Oct-15	1,183.40	46.06
28-Oct-15	1,210.90	45.94
27-Oct-15	1,199.80	43.2

26-Oct-15	1,201.70	43.98
23-Oct-15	1,200.10	44.6
22-Oct-15	1,204.10	45.38
21-Oct-15	1,205.40	45.2
20-Oct-15	1,216.60	45.55
19-Oct-15	1,212.00	45.89
16-Oct-15	1,222.30	47.26
15-Oct-15	1,227.10	46.38
14-Oct-15	1,219.30	46.64
13-Oct-15	1,206.90	46.66
12-Oct-15	1,206.20	47.1
9-Oct-15	1,197.50	49.63
8-Oct-15	1,185.00	49.43
7-Oct-15	1,189.10	47.81
6-Oct-15	1,186.40	48.53
5-Oct-15	1,178.30	46.26
2-Oct-15	1,179.00	45.54
1-Oct-15	1,156.90	44.74
30-Sep-15	1,158.40	45.09
29-Sep-15	1,172.90	45.23
28-Sep-15	1,178.20	44.43
25-Sep-15	1,192.60	45.7
24-Sep-15	1,200.70	44.91
23-Sep-15	1,179.40	44.48
22-Sep-15	1,172.70	45.83
21-Sep-15	1,181.80	46.68
18-Sep-15	1,186.50	44.68
17-Sep-15	1,167.20	46.9
16-Sep-15	1,168.60	47.15
15-Sep-15	1,151.50	44.59
14-Sep-15	1,156.70	44

11-Sep-15	1,152.90	44.63
10-Sep-15	1,158.90	45.92
9-Sep-15	1,151.70	44.15
8-Sep-15	1,170.90	45.94
7-Sep-15	1,119.90	44.7
4-Sep-15	1,171.50	46.05
3-Sep-15	1,174.50	46.75
2-Sep-15	1,185.40	46.25
1-Sep-15	1,192.30	45.41
31-Aug-15	1,187.90	49.2
28-Aug-15	1,189.40	45.22
27-Aug-15	1,178.20	42.56
26-Aug-15	1,180.00	38.6
25-Aug-15	1,194.70	39.31
24-Aug-15	1,209.90	38.24
21-Aug-15	1,217.80	40.45
20-Aug-15	1,213.20	41.14
19-Aug-15	1,188.10	40.8
18-Aug-15	1,177.30	42.62
17-Aug-15	1,178.90	41.87
14-Aug-15	1,173.30	42.5
13-Aug-15	1,176.10	42.23
12-Aug-15	1,184.00	43.3
11-Aug-15	1,168.70	43.08
10-Aug-15	1,166.80	44.96
7-Aug-15	1,156.80	43.87
6-Aug-15	1,152.60	44.66
5-Aug-15	1,148.10	45.15
4-Aug-15	1,149.70	45.74
3-Aug-15	1,147.80	45.17
31-Jul-15	1,154.10	47.12

30-Jul-15	1,154.40	48.52
29-Jul-15	1,158.50	48.79
28-Jul-15	1,161.60	47.98
27-Jul-15	1,161.60	47.39
24-Jul-15	1,151.00	48.14
23-Jul-15	1,161.10	48.45
22-Jul-15	1,158.60	49.19
21-Jul-15	1,170.50	50.36
20-Jul-15	1,176.50	50.15
17-Jul-15	1,201.70	50.89
16-Jul-15	1,214.20	50.91
15-Jul-15	1,217.30	51.41
14-Jul-15	1,223.40	53.04
13-Jul-15	1,226.00	52.2
10-Jul-15	1,227.60	52.74
9-Jul-15	1,226.10	52.78
8-Jul-15	1,229.60	51.65
7-Jul-15	1,220.50	52.33
6-Jul-15	1,241.60	52.53
3-Jul-15	1,167.80	55.52
2-Jul-15	1,232.50	56.93
1-Jul-15	1,239.50	56.96
30-Jun-15	1,241.80	59.47
29-Jun-15	1,249.00	58.33
26-Jun-15	1,244.10	59.63
25-Jun-15	1,241.30	59.7
24-Jun-15	1,242.00	60.27
23-Jun-15	1,245.80	61.01
22-Jun-15	1,253.10	59.68
19-Jun-15	1,270.40	59.61
18-Jun-15	1,271.80	60.45

17-Jun-15	1,247.90	59.92
16-Jun-15	1,250.40	59.97
15-Jun-15	1,256.80	59.52
12-Jun-15	1,252.00	59.96
11-Jun-15	1,253.60	60.77
10-Jun-15	1,259.60	61.43
9-Jun-15	1,247.80	60.14
8-Jun-15	1,243.00	58.14
5-Jun-15	1,237.60	59.13
4-Jun-15	1,241.10	58
3-Jun-15	1,250.90	59.64
2-Jun-15	1,258.80	61.26
1-Jun-15	1,251.40	60.2
29-May-15	1,251.70	60.3
28-May-15	1,251.50	57.68
27-May-15	1,249.60	57.51
26-May-15	1,251.20	58.03
25-May-15	1,207.40	59.85
22-May-15	1,268.70	59.72
21-May-15	1,267.10	60.72
20-May-15	1,272.50	58.98
19-May-15	1,270.40	57.26
18-May-15	1,290.20	59.43
15-May-15	1,287.90	59.69
14-May-15	1,288.00	59.88
13-May-15	1,281.20	60.5
12-May-15	1,256.00	60.75
11-May-15	1,246.30	59.25
8-May-15	1,251.50	59.39
7-May-15	1,247.50	58.94
6-May-15	1,255.70	60.93

5-May-15	1,257.20	60.4
4-May-15	1,248.00	58.93
1-May-15	1,235.10	59.15
30-Apr-15	1,242.00	59.63
29-Apr-15	1,269.00	58.58
28-Apr-15	1,270.40	57.06
27-Apr-15	1,258.20	56.99
24-Apr-15	1,229.40	57.15
23-Apr-15	1,251.00	57.74
22-Apr-15	1,243.70	56.16
21-Apr-15	1,258.10	55.26
20-Apr-15	1,248.30	56.38
17-Apr-15	1,257.10	55.74
16-Apr-15	1,252.00	56.71
15-Apr-15	1,255.50	56.39
14-Apr-15	1,247.10	53.29
13-Apr-15	1,256.80	51.91
10-Apr-15	1,262.30	51.64
9-Apr-15	1,250.60	50.79
8-Apr-15	1,260.10	50.42
7-Apr-15	1,267.40	53.98
6-Apr-15	1,274.40	52.14
3-Apr-15	1,257.20	49.14
2-Apr-15	1,257.20	49.14
1-Apr-15	1,263.20	50.09
31-Mar-15	1,241.20	47.6
30-Mar-15	1,245.40	48.68
27-Mar-15	1,260.90	48.87
26-Mar-15	1,266.00	51.43
25-Mar-15	1,256.30	49.21
24-Mar-15	1,250.20	47.51

23-Mar-15	1,246.50	47.45
20-Mar-15	1,243.70	45.72
19-Mar-15	1,228.50	43.96
18-Mar-15	1,216.50	44.66
17-Mar-15	1,213.50	43.46
16-Mar-15	1,218.30	43.88
13-Mar-15	1,217.90	44.84
12-Mar-15	1,218.00	47.05
11-Mar-15	1,217.40	48.17
10-Mar-15	1,227.10	48.29
9-Mar-15	1,237.00	50
6-Mar-15	1,234.60	49.61
5-Mar-15	1,265.10	50.76
4-Mar-15	1,269.60	51.53
3-Mar-15	1,273.20	50.52
2-Mar-15	1,274.80	49.59
27-Feb-15	1,278.40	49.76
26-Feb-15	1,275.10	48.17
25-Feb-15	1,265.00	50.99
24-Feb-15	1,262.10	49.28
23-Feb-15	1,267.70	49.45
20-Feb-15	1,272.20	50.34
19-Feb-15	1,275.90	51.16
18-Feb-15	1,270.50	52.14
17-Feb-15	1,278.90	53.53
16-Feb-15	1,231.70	53.61
13-Feb-15	1,294.20	52.78
12-Feb-15	1,287.70	51.21
11-Feb-15	1,288.20	48.84
10-Feb-15	1,300.20	50.02
9-Feb-15	1,308.90	52.86

6-Feb-15	1,301.60	51.69
5-Feb-15	1,323.90	50.48
4-Feb-15	1,325.40	48.45
3-Feb-15	1,319.30	53.05
2-Feb-15	1,334.40	49.57
30-Jan-15	1,336.60	48.24
29-Jan-15	1,315.80	44.53
28-Jan-15	1,346.90	44.45
27-Jan-15	1,354.70	46.23
26-Jan-15	1,345.60	45.15
23-Jan-15	1,357.60	45.59
22-Jan-15	1,365.20	46.31
21-Jan-15	1,353.40	47.78
20-Jan-15	1,352.40	46.39
19-Jan-15	1,275.90	47.78
16-Jan-15	1,334.90	48.69
15-Jan-15	1,322.80	46.25
14-Jan-15	1,294.50	48.48
13-Jan-15	1,304.50	45.89
12-Jan-15	1,303.20	46.07
9-Jan-15	1,287.40	48.36
8-Jan-15	1,281.60	48.79
7-Jan-15	1,283.60	48.65
6-Jan-15	1,292.20	47.93
5-Jan-15	1,283.50	50.04
2-Jan-15	1,267.70	52.69
1-Jan-15	1,186.80	54.56
31-Dec-14	1,265.40	53.27
30-Dec-14	1,281.90	54.12
29-Dec-14	1,262.90	53.61
26-Dec-14	1,277.70	54.73

25-Dec-14	1,177.00	55.92
24-Dec-14	1,255.60	55.84
23-Dec-14	1,259.70	57.12
22-Dec-14	1,259.70	55.26
19-Dec-14	1,275.60	56.52
18-Dec-14	1,273.90	54.11
17-Dec-14	1,272.30	56.47
16-Dec-14	1,272.00	55.93
15-Dec-14	1,287.70	55.91
12-Dec-14	1,303.50	57.81
11-Dec-14	1,312.30	59.95
10-Dec-14	1,315.50	60.94
9-Dec-14	1,320.20	63.82
8-Dec-14	1,284.40	63.05
5-Dec-14	1,280.80	65.84
4-Dec-14	1,294.20	66.81
3-Dec-14	1,295.80	67.38
2-Dec-14	1,284.70	66.88
1-Dec-14	1,302.50	69
28-Nov-14	1,261.20	66.15
27-Nov-14	1,188.80	68.55
26-Nov-14	1,284.50	73.69
25-Nov-14	1,285.20	74.09
24-Nov-14	1,284.20	75.78
21-Nov-14	1,285.90	76.51
20-Nov-14	1,278.90	75.58
19-Nov-14	1,283.40	74.58
18-Nov-14	1,285.50	74.61
17-Nov-14	1,273.70	75.64
14-Nov-14	1,275.60	75.82
13-Nov-14	1,251.40	74.21

12-Nov-14	1,250.40	77.18
11-Nov-14	1,255.10	77.94
10-Nov-14	1,251.30	77.4
7-Nov-14	1,261.00	78.65
6-Nov-14	1,234.40	77.91
5-Nov-14	1,238.10	78.68
4-Nov-14	1,260.30	77.19
3-Nov-14	1,264.40	78.78
31-Oct-14	1,265.90	80.54
30-Oct-14	1,292.90	81.12
29-Oct-14	1,319.20	82.2
28-Oct-14	1,322.60	81.42
27-Oct-14	1,322.40	81
24-Oct-14	1,325.00	81.01
23-Oct-14	1,322.10	82.09
22-Oct-14	1,336.60	80.52
21-Oct-14	1,341.80	82.81
20-Oct-14	1,334.30	82.71
17-Oct-14	1,328.50	82.75
16-Oct-14	1,327.50	82.7
15-Oct-14	1,331.30	81.78
14-Oct-14	1,329.30	81.84
13-Oct-14	1,329.30	85.74
10-Oct-14	1,323.70	85.82
9-Oct-14	1,328.80	85.77
8-Oct-14	1,314.20	87.31
7-Oct-14	1,333.60	88.85
6-Oct-14	1,330.70	90.34
3-Oct-14	1,316.90	89.74
2-Oct-14	1,338.10	91.01
1-Oct-14	1,340.20	90.73

30-Sep-14	1,336.70	91.16
29-Sep-14	1,343.70	94.57
26-Sep-14	1,340.40	93.54
25-Sep-14	1,346.40	92.53
24-Sep-14	1,344.90	92.8
23-Sep-14	1,347.20	91.56
22-Sep-14	1,344.20	91.52
19-Sep-14	1,343.10	92.41
18-Sep-14	1,353.40	93.07
17-Sep-14	1,362.00	94.42
16-Sep-14	1,363.00	94.88
15-Sep-14	1,361.30	92.92
12-Sep-14	1,357.80	92.27
11-Sep-14	1,365.40	92.83
10-Sep-14	1,372.00	91.67
9-Sep-14	1,374.60	92.75
8-Sep-14	1,380.20	92.66
5-Sep-14	1,393.20	93.29
4-Sep-14	1,392.30	94.45
3-Sep-14	1,395.50	95.54
2-Sep-14	1,389.00	92.88
1-Sep-14	1,287.40	95.83
29-Aug-14	1,410.60	95.96
28-Aug-14	1,413.80	94.55
27-Aug-14	1,406.90	93.88
26-Aug-14	1,409.30	93.86
25-Aug-14	1,403.10	93.35
22-Aug-14	1,404.10	93.65
21-Aug-14	1,399.20	93.96
20-Aug-14	1,419.00	96.07
19-Aug-14	1,419.00	94.48

18-Aug-14	1,422.80	96.41
15-Aug-14	1,429.40	97.35
14-Aug-14	1,439.10	95.58
13-Aug-14	1,437.90	97.59
12-Aug-14	1,435.30	97.37
11-Aug-14	1,435.50	98.08
8-Aug-14	1,435.90	97.65
7-Aug-14	1,437.30	97.34
6-Aug-14	1,432.70	96.92
5-Aug-14	1,409.00	97.38
4-Aug-14	1,411.90	98.29
1-Aug-14	1,421.10	97.88
31-Jul-14	1,411.50	98.17
30-Jul-14	1,426.10	100.27
29-Jul-14	1,426.70	100.97
28-Jul-14	1,432.00	101.67
25-Jul-14	1,430.30	102.09
24-Jul-14	1,417.30	102.07
23-Jul-14	1,430.30	103.12
22-Jul-14	1,431.60	104.42
21-Jul-14	1,439.60	104.59
18-Jul-14	1,434.70	103.13
17-Jul-14	1,442.10	103.19
16-Jul-14	1,424.90	101.2
15-Jul-14	1,421.30	99.96
14-Jul-14	1,430.70	100.91
11-Jul-14	1,462.90	100.83
10-Jul-14	1,464.70	102.93
9-Jul-14	1,449.70	102.29
8-Jul-14	1,441.40	103.4
7-Jul-14	1,442.00	103.53

4-Jul-14	1,321.30	103.76
3-Jul-14	1,445.60	104.06
2-Jul-14	1,454.80	104.48
1-Jul-14	1,450.20	105.34
30-Jun-14	1,445.10	105.37
27-Jun-14	1,444.70	105.74
26-Jun-14	1,443.40	105.84
25-Jun-14	1,449.20	106.5
24-Jun-14	1,448.60	106.03
23-Jun-14	1,447.00	106.17
20-Jun-14	1,445.20	107.26
19-Jun-14	1,442.50	106.43
18-Jun-14	1,400.60	105.97
17-Jun-14	1,399.90	106.36
16-Jun-14	1,403.00	106.9
13-Jun-14	1,401.60	106.91
12-Jun-14	1,399.90	106.53
11-Jun-14	1,387.00	104.4
10-Jun-14	1,386.50	104.35
9-Jun-14	1,380.20	104.41
6-Jun-14	1,377.60	102.66
5-Jun-14	1,377.30	102.48
4-Jun-14	1,368.40	102.64
3-Jun-14	1,368.20	102.66
2-Jun-14	1,367.70	102.47
30-May-14	1,368.90	102.71
29-May-14	1,379.50	103.58
28-May-14	1,385.40	102.72
27-May-14	1,392.90	104.11
26-May-14	1,292.50	104.28
23-May-14	1,419.10	104.35

22-May-14	1,422.70	103.74
21-May-14	1,416.10	104.07
20-May-14	1,422.50	102.44
19-May-14	1,421.90	102.61
16-May-14	1,422.30	102.02
15-May-14	1,422.00	101.5
14-May-14	1,435.30	102.37
13-May-14	1,427.50	101.7
12-May-14	1,430.60	100.59
9-May-14	1,421.80	99.99
8-May-14	1,421.70	100.26
7-May-14	1,423.30	100.77
6-May-14	1,444.00	99.5
5-May-14	1,444.40	99.48
2-May-14	1,437.50	99.76
1-May-14	1,417.50	99.42
30-Apr-14	1,431.80	99.74
29-Apr-14	1,432.50	101.28
28-Apr-14	1,435.70	100.84
25-Apr-14	1,438.90	100.6
24-Apr-14	1,429.70	101.94
23-Apr-14	1,424.00	101.44
22-Apr-14	1,425.40	102.13
21-Apr-14	1,432.40	104.37
18-Apr-14	1,437.50	104.3
17-Apr-14	1,437.50	104.3
16-Apr-14	1,446.00	103.76
15-Apr-14	1,442.00	103.75
14-Apr-14	1,469.30	104.05
11-Apr-14	1,459.70	103.74
10-Apr-14	1,461.70	103.4

9-Apr-14	1,451.10	103.6
8-Apr-14	1,452.30	102.56
7-Apr-14	1,442.70	100.44
4-Apr-14	1,452.70	101.14
3-Apr-14	1,435.10	100.29
2-Apr-14	1,442.50	99.62
1-Apr-14	1,430.00	99.74
31-Mar-14	1,433.80	101.58
28-Mar-14	1,445.30	101.67
27-Mar-14	1,447.80	101.28
26-Mar-14	1,456.10	100.26
25-Mar-14	1,466.40	99.19
24-Mar-14	1,468.50	99.6
21-Mar-14	1,493.50	99.46
20-Mar-14	1,488.70	99.43
19-Mar-14	1,493.00	100.37
18-Mar-14	1,511.60	99.7
17-Mar-14	1,525.60	98.08
14-Mar-14	1,532.40	98.89
13-Mar-14	1,526.00	98.2
12-Mar-14	1,525.20	97.99
11-Mar-14	1,502.20	100.03
10-Mar-14	1,497.20	101.12
7-Mar-14	1,494.60	102.58
6-Mar-14	1,504.30	101.56
5-Mar-14	1,491.10	101.45
4-Mar-14	1,488.70	103.33
3-Mar-14	1,500.00	104.92
28-Feb-14	1,473.00	102.59
27-Feb-14	1,481.30	102.4
26-Feb-14	1,478.40	102.59

25-Feb-14	1,493.80	101.83
24-Feb-14	1,491.00	102.82
21-Feb-14	1,474.40	102.2
20-Feb-14	1,467.80	102.92
19-Feb-14	1,467.70	103.31
18-Feb-14	1,473.20	102.43
17-Feb-14	1,328.50	100.58
14-Feb-14	1,470.80	100.3
13-Feb-14	1,451.40	100.35
12-Feb-14	1,451.10	100.37
11-Feb-14	1,443.60	99.94
10-Feb-14	1,427.50	100.06
7-Feb-14	1,415.70	99.88
6-Feb-14	1,413.30	97.84
5-Feb-14	1,413.00	97.38
4-Feb-14	1,407.30	97.19
3-Feb-14	1,417.10	96.43
31-Jan-14	1,398.90	97.49
30-Jan-14	1,402.80	98.23
29-Jan-14	1,422.20	97.36
28-Jan-14	1,412.00	97.41
27-Jan-14	1,425.10	95.72
24-Jan-14	1,426.00	96.64
23-Jan-14	1,426.10	97.32
22-Jan-14	1,403.60	96.73
21-Jan-14	1,405.10	94.99
20-Jan-14	1,255.10	93.93
17-Jan-14	1,417.10	94.37
16-Jan-14	1,405.70	93.96
15-Jan-14	1,405.90	94.17
14-Jan-14	1,411.80	92.59

13-Jan-14	1,416.00	91.8
10-Jan-14	1,413.40	92.72
9-Jan-14	1,397.90	91.66
8-Jan-14	1,392.60	92.33
7-Jan-14	1,395.50	93.67
6-Jan-14	1,405.00	93.43
3-Jan-14	1,405.50	93.96
2-Jan-14	1,391.70	95.44
1-Jan-14	1,205.40	98.7

*Halaman ini sengaja dikosongkan*

## **LAMPIRAN B**

Data harga komoditi Pasar Induk Kramat Jati; bawang merah, cabe merah keriting, cabe merah besar, cabe rawit merah, dan cabe rawit hijau. Data harga komoditi yang digunakan pada tanggal 1 September 2018 sampai dengan 31 Januari 2020.

<b>Tanggal</b>	<b>Bawang Merah</b>	<b>Cabai Merah Keriting</b>	<b>Cabai Merah Besar</b>	<b>Cabai Rawit Merah</b>	<b>Cabai Rawit Hijau</b>
9/1/2018	11000	13000	24000	11000	12000
9/2/2018	11000	13000	24000	11000	12000
9/3/2018	11000	12000	23000	11000	10000
9/4/2018	11000	14000	21000	12000	11000
9/5/2018	11000	13000	20000	11000	10000
9/6/2018	12000	15000	20000	12000	11000
9/7/2018	13000	15000	22000	13000	10000
9/8/2018	14000	17000	18000	14000	9000
9/9/2018	14000	18000	19000	16000	9000
9/10/2018	15000	19000	20000	16000	10000
9/11/2018	13000	17000	19000	15000	9000
9/12/2018	12000	16000	20000	13000	10000
9/13/2018	11000	15000	18000	13000	12000
9/14/2018	11000	18000	22000	14000	11000
9/15/2018	10500	16000	24000	14000	13000
9/16/2018	11000	17000	25000	15000	11000
9/17/2018	10000	16000	22000	13000	10000
9/18/2018	10000	17000	21000	12500	12000
9/19/2018	11000	18000	20000	14000	10000
9/20/2018	11000	20000	19000	15000	9000
9/21/2018	10000	21000	18000	13000	9000
9/22/2018	11000	22000	18000	14000	10000
9/23/2018	10000	20000	20000	13000	9000
9/24/2018	11000	21000	19000	13000	11000

9/25/2018	11000	23500	21000	15500	13000
9/26/2018	9500	22000	19000	16000	15000
9/27/2018	10000	23000	18000	15000	14000
9/28/2018	9000	25000	17000	15000	13700
9/29/2018	9000	24000	16000	15500	15000
9/30/2018	9000	25000	17000	16000	16000
10/1/2018	9500	24000	19000	18000	14000
10/2/2018	9500	23000	20000	23000	14000
10/3/2018	10000	25000	22000	21000	16000
10/4/2018	10000	25000	25000	17000	13000
10/5/2018	10000	24000	27000	15000	12000
10/6/2018	10500	25000	29000	16000	15000
10/7/2018	11000	26000	30000	17000	14000
10/8/2018	10000	25000	26000	18000	15000
10/9/2018	11000	25000	25000	18000	17000
10/10/2018	15000	25000	27000	18000	17000
10/11/2018	14000	27000	28000	17000	16000
10/12/2018	13000	28000	27000	16000	17000
10/13/2018	13000	27000	27000	17000	18000
10/14/2018	14000	28000	27000	19000	17000
10/15/2018	14000	26000	28000	21000	18000
10/16/2018	15000	28000	26000	22000	19000
10/17/2018	14000	27000	27000	20000	17000
10/18/2018	14000	30000	25000	18000	17000
10/19/2018	15000	29000	26000	20000	18000
10/20/2018	13500	27000	24000	20000	17000
10/21/2018	14000	28000	23500	20000	16000
10/22/2018	15500	31000	24000	21000	18000
10/23/2018	15000	30000	25000	20000	16000
10/24/2018	14000	29000	23000	19000	17500
10/25/2018	15000	30000	22500	18000	18000

10/26/2018	16000	28000	22000	17000	17000
10/27/2018	15000	29000	23000	18000	15000
10/28/2018	17000	28000	24000	20000	16000
10/29/2018	17000	28000	24000	20000	16000
10/30/2018	17000	26000	22000	17000	14000
10/31/2018	17000	25000	24000	16000	12000
11/1/2018	16000	24000	25000	17000	13000
11/2/2018	17000	25000	24000	18000	15000
11/3/2018	18000	23500	25000	19000	16000
11/4/2018	17000	21000	22000	20000	13000
11/5/2018	16000	20000	24000	21000	12000
11/6/2018	18000	21000	21000	22000	14000
11/7/2018	18000	20000	22000	21000	11000
11/8/2018	20000	19000	20000	19000	12000
11/9/2018	18000	18000	18000	16000	11000
11/10/2018	19000	19000	19000	15000	10000
11/11/2018	19000	20000	20000	16000	9000
11/12/2018	20000	21000	21000	15000	10000
11/13/2018	19000	19000	20000	14000	9000
11/14/2018	18000	20000	20000	13000	9000
11/15/2018	19000	20000	20000	14000	10000
11/16/2018	18000	18000	19000	13000	10000
11/17/2018	19000	18000	19000	14000	11000
11/18/2018	19000	17000	18000	15000	12000
11/19/2018	18000	17000	19000	13000	11000
11/20/2018	18000	17000	18000	12000	10000
11/21/2018	20000	14000	18000	14000	10000
11/22/2018	18500	13000	18000	13000	9500
11/23/2018	18000	12000	18000	14000	10000
11/24/2018	19000	13000	18000	15000	11000
11/25/2018	20000	12000	19000	12000	10000

11/26/2018	20000	12000	20000	13000	10000
11/27/2018	20000	13000	20000	14000	12000
11/28/2018	18500	12000	19000	14500	11000
11/29/2018	19000	13000	20000	15000	12000
11/30/2018	18000	14000	21000	14000	11000
12/1/2018	18000	18000	21000	16000	10000
12/2/2018	18000	18000	20000	13000	11000
12/3/2018	19000	19000	21000	15000	12000
12/4/2018	18500	17000	20000	17000	11000
12/5/2018	17000	18000	19000	17000	10000
12/6/2018	19000	18000	20000	18000	11000
12/7/2018	19000	17000	21000	19000	10000
12/8/2018	19000	14000	20000	20000	9000
12/9/2018	20000	15000	23000	20000	10000
12/10/2018	18000	16000	25000	18000	10000
12/11/2018	19000	18000	24000	19000	9000
12/12/2018	18000	17000	23000	18000	8000
12/13/2018	19000	16000	26000	17500	8000
12/14/2018	19000	15000	28000	19000	9000
12/15/2018	19000	17000	30000	20000	10000
12/16/2018	20000	16000	29000	22000	9000
12/17/2018	21000	15000	26000	23000	10000
12/18/2018	20000	17000	23000	25000	10000
12/19/2018	17000	16000	25000	25000	9000
12/20/2018	18000	15000	26000	26500	8000
12/21/2018	19000	16000	27000	28000	8000
12/22/2018	18000	16000	28000	30000	7000
12/23/2018	19000	17000	26000	33000	8000
12/24/2018	19000	16000	27000	35000	10000
12/25/2018	20000	15000	24000	33000	11000
12/26/2018	22000	20000	25000	34000	13000

12/27/2018	23000	19000	25000	33000	12000
12/28/2018	22000	20000	26000	32000	11000
12/29/2018	21000	21000	25000	35000	11000
12/30/2018	20000	20000	24000	33000	10000
12/31/2018	21000	20000	22000	28000	11000
1/1/2019	23000	23000	23000	33000	13000
1/2/2019	24000	20000	23000	41000	14000
1/3/2019	22000	18000	21000	36000	11000
1/4/2019	22000	17000	21000	34000	12000
1/5/2019	21000	16000	20000	30000	10000
1/6/2019	20000	15000	22000	25000	8000
1/7/2019	20000	16000	25000	21000	8000
1/8/2019	19000	13000	25000	27000	9000
1/9/2019	19000	14000	27000	28000	7500
1/10/2019	18000	12000	26000	26000	7000
1/11/2019	17000	11000	27000	24000	8000
1/12/2019	17000	11000	24000	23000	7000
1/13/2019	16000	12000	23000	24000	7000
1/14/2019	17000	11000	22000	21000	8000
1/15/2019	17500	10000	20000	27000	9000
1/16/2019	18000	9500	19000	25000	10000
1/17/2019	18000	9000	18000	22000	9000
1/18/2019	18000	8000	19000	20000	8000
1/19/2019	16000	8000	20000	17000	7000
1/20/2019	14000	8000	21000	14000	7500
1/21/2019	12000	7700	20000	16000	7000
1/22/2019	13000	8000	20000	19000	8000
1/23/2019	14000	8500	19000	16000	7000
1/24/2019	13000	8000	20000	13000	7500
1/25/2019	13000	7000	21000	13000	8000
1/26/2019	12000	8500	22000	15000	8000

1/27/2019	12000	8000	21000	13000	7000
1/28/2019	11000	7000	21000	12000	6500
1/29/2019	10000	7000	20000	13000	7000
1/30/2019	11000	7000	19000	13000	6000
1/31/2019	12000	7000	21000	11000	6000
2/1/2019	13000	7000	20000	11000	6000
2/2/2019	11000	7000	19000	11000	6500
2/3/2019	10000	8000	20000	11000	8000
2/4/2019	10000	6000	18000	12000	8000
2/5/2019	12000	7000	20000	14000	9000
2/6/2019	11000	6000	17000	11000	8000
2/7/2019	12000	6500	18000	10000	8500
2/8/2019	12000	6000	16000	11000	7000
2/9/2019	13000	7500	17000	12500	8500
2/10/2019	13000	6500	18000	13000	9000
2/11/2019	12000	6000	16000	11000	8000
2/12/2019	12000	6000	15000	11000	10000
2/13/2019	13000	7000	16000	11000	10000
2/14/2019	12000	7000	15000	11000	9000
2/15/2019	13000	8000	14000	12000	10000
2/16/2019	12000	8500	15000	13000	11000
2/17/2019	13000	8000	13000	16000	10000
2/18/2019	14000	7000	12000	15000	10000
2/19/2019	14000	8000	12000	17000	9000
2/20/2019	14000	8500	14000	16000	10000
2/21/2019	16000	8000	13000	17000	11000
2/22/2019	16000	7500	11000	15000	11000
2/23/2019	16000	7500	12000	16000	10000
2/24/2019	18000	11000	12000	16000	10000
2/25/2019	18000	8000	11000	17000	9000
2/26/2019	19000	8000	12000	15000	9000

2/27/2019	19000	9000	13000	17000	10000
2/28/2019	20000	11000	11000	17000	9000
3/1/2019	20000	8000	10000	16000	10000
3/2/2019	20000	9000	11000	15000	10000
3/3/2019	21000	10000	10000	20000	9000
3/4/2019	21000	9000	10000	17000	8000
3/5/2019	21000	8000	9000	17000	9000
3/6/2019	20000	11000	11000	18000	10000
3/7/2019	22000	12000	13000	19000	11000
3/8/2019	22000	10000	12000	18000	10000
3/9/2019	22000	12000	13000	20000	12000
3/10/2019	23000	11000	12000	18000	11000
3/11/2019	21000	10000	11000	17000	10000
3/12/2019	21000	10000	11000	17000	10000
3/13/2019	20000	10000	14000	17000	10000
3/14/2019	20000	11000	16000	14000	9000
3/15/2019	21000	11000	17000	16000	11000
3/16/2019	20000	10000	20000	16000	10000
3/17/2019	21000	12000	22000	15000	10000
3/18/2019	23000	13000	24000	13000	11000
3/19/2019	26000	11000	20000	14000	12000
3/20/2019	28000	11000	17000	14000	11000
3/21/2019	28000	12000	18000	15000	12000
3/22/2019	29000	12000	20000	15000	10000
3/23/2019	29000	13000	21000	17000	11000
3/24/2019	31000	12000	20000	15000	11000
3/25/2019	34000	12000	22000	16000	10000
3/26/2019	31000	11000	20000	14000	9000
3/27/2019	29000	13000	21000	15000	10000
3/28/2019	27000	12000	18000	15000	10000
3/29/2019	28000	12000	19000	13000	11000

3/30/2019	28000	12000	20000	14000	10000
3/31/2019	28000	11000	18000	12000	11000
4/1/2019	28000	12000	20000	12000	10000
4/2/2019	29000	13000	20000	13000	11000
4/3/2019	29000	12000	19000	14000	11000
4/4/2019	28000	10000	22000	11000	9000
4/5/2019	29000	9000	22000	10000	10000
4/6/2019	28000	10000	21000	11000	11000
4/7/2019	29000	10000	23000	10000	10000
4/8/2019	28000	10000	25000	11000	10000
4/9/2019	29000	9000	25000	10000	9000
4/10/2019	28000	11000	26000	11000	10000
4/11/2019	29000	11000	28000	12000	10000
4/12/2019	29000	10000	30000	11000	9000
4/13/2019	26000	11000	30000	12000	9000
4/14/2019	25000	12000	30000	13000	10000
4/15/2019	26000	11000	30000	11000	11000
4/16/2019	24000	10000	29000	11000	9000
4/17/2019	24000	11000	28000	12000	10000
4/18/2019	25000	15000	30000	17000	18000
4/19/2019	25000	15000	30000	17000	18000
4/20/2019	24000	14000	29000	15000	15000
4/21/2019	27000	12000	31000	17000	11000
4/22/2019	27000	13000	35000	20000	11000
4/23/2019	23000	12000	35000	21000	10000
4/24/2019	20000	15000	36000	20000	9000
4/25/2019	19000	14000	33000	21000	11000
4/26/2019	20000	13000	34000	23000	12000
4/27/2019	19000	11000	30000	17000	10000
4/28/2019	19000	12000	29000	16000	10000
4/29/2019	22000	16000	28000	19000	11000

4/30/2019	22000	18000	26000	20000	12000
5/1/2019	20000	17000	28000	20000	13000
5/2/2019	18000	18000	27000	17000	11000
5/3/2019	20000	21000	30000	21000	12000
5/4/2019	21000	24000	32000	22000	12000
5/5/2019	20000	20000	30000	19000	12000
5/6/2019	18000	21000	30000	20000	13000
5/7/2019	20000	23000	33000	22000	15000
5/8/2019	21000	21000	32000	17000	15000
5/9/2019	20000	22000	38000	14000	13000
5/10/2019	18000	23000	35000	11000	14000
5/11/2019	19000	21000	34000	10000	12000
5/12/2019	18000	22000	33000	12000	10000
5/13/2019	20000	18000	31000	12000	12000
5/14/2019	20000	17000	34000	14000	13000
5/15/2019	18000	13000	28000	10000	12000
5/16/2019	18000	14000	27000	9000	13000
5/17/2019	19000	15000	30000	8000	12000
5/18/2019	19000	15000	31000	7000	13000
5/19/2019	20000	16000	28000	9000	15000
5/20/2019	17000	17000	29000	11000	14000
5/21/2019	18000	16000	28000	8000	12000
5/22/2019	19000	20000	25000	9000	13000
5/23/2019	19000	19000	26000	10000	14000
5/24/2019	20000	20000	28000	12000	15000
5/25/2019	22000	21000	29000	11000	16000
5/26/2019	25000	22000	30000	10000	14000
5/27/2019	24000	23000	30000	11000	14000
5/28/2019	24000	25000	35000	14000	16000
5/29/2019	22000	24000	40000	12000	14000
5/30/2019	23000	30000	44000	13000	18000

5/31/2019	24000	30000	45000	11000	16000
6/1/2019	24000	35000	47000	14000	18000
6/2/2019	26000	40000	51000	15000	20000
6/3/2019	27000	45000	53000	16000	22000
6/4/2019	25000	40000	50000	15000	20000
6/5/2019	25000	40000	50000	15000	20000
6/6/2019	25000	40000	50000	15000	20000
6/7/2019	38000	57000	77000	26000	27000
6/8/2019	40000	58000	75000	27000	26000
6/9/2019	39000	55000	75000	25000	24000
6/10/2019	35000	35000	50000	20000	18000
6/11/2019	32000	32000	48000	18000	17000
6/12/2019	30000	28000	45000	18000	16000
6/13/2019	26000	31000	38000	16000	18000
6/14/2019	27000	35000	36000	11000	17000
6/15/2019	25000	33000	40000	13000	20000
6/16/2019	26000	31000	39000	14000	21000
6/17/2019	26000	32000	40000	14000	17000
6/18/2019	23000	34000	41000	16000	18000
6/19/2019	21000	37000	40000	18000	19000
6/20/2019	24000	39000	39000	20000	21000
6/21/2019	23000	40000	40000	21000	23000
6/22/2019	22000	39000	40000	22000	24000
6/23/2019	22000	41000	40000	23000	24000
6/24/2019	23000	42000	44000	23000	27000
6/25/2019	21000	40000	50000	23000	25000
6/26/2019	21000	39000	55000	22000	29000
6/27/2019	22000	42000	53000	25000	33000
6/28/2019	20000	45000	52000	31000	35000
6/29/2019	19000	43000	50000	32000	38000
6/30/2019	20000	42000	51000	30000	38000

7/1/2019	19000	43000	54000	29000	39000
7/2/2019	18000	44000	53000	35000	40000
7/3/2019	17000	47000	55000	40000	46000
7/4/2019	19000	52000	54000	42000	50000
7/5/2019	18000	49000	55000	43000	52000
7/6/2019	18000	48000	55000	42000	49000
7/7/2019	19000	49000	56000	41000	45000
7/8/2019	20000	47000	55000	43000	46000
7/9/2019	19000	49000	56000	46000	48000
7/10/2019	20000	50000	53000	49000	52000
7/11/2019	19000	51000	54000	50000	50000
7/12/2019	17000	52000	52000	51000	53000
7/13/2019	18000	53000	55000	53000	54000
7/14/2019	17000	52000	55000	54000	53000
7/15/2019	18000	54000	56000	60000	57000
7/16/2019	19000	55000	55000	63000	58000
7/17/2019	17000	53000	52000	60000	57000
7/18/2019	18000	54000	55000	61000	58000
7/19/2019	17000	52000	53000	59000	55000
7/20/2019	17000	50000	56000	62000	58000
7/21/2019	17000	48000	55000	63000	59000
7/22/2019	18000	48000	56000	64000	57000
7/23/2019	17000	47000	55000	62000	56000
7/24/2019	17000	49000	53000	63000	58000
7/25/2019	18000	48000	55000	62000	56000
7/26/2019	17000	47000	52000	65000	55000
7/27/2019	17000	47000	52000	63000	55000
7/28/2019	17000	48000	50000	65000	52000
7/29/2019	17000	46000	53000	70000	51000
7/30/2019	17000	48000	48000	69000	50000
7/31/2019	18000	46000	45000	71000	46000

8/1/2019	16000	45000	41000	67000	43000
8/2/2019	18000	48000	44000	69000	39000
8/3/2019	18000	50000	48000	72000	43000
8/4/2019	17000	56000	50000	73000	44000
8/5/2019	16000	54000	52000	72000	42000
8/6/2019	16000	57000	50000	70000	45000
8/7/2019	16000	58000	52000	69000	47000
8/8/2019	16000	66000	54000	73000	48000
8/9/2019	16000	65000	52000	72000	46000
8/10/2019	17000	64000	52000	70000	45000
8/11/2019	17000	66000	55000	72000	47000
8/12/2019	18000	67000	57000	74000	49000
8/13/2019	15000	65000	58000	70000	45000
8/14/2019	12000	63000	60000	71000	40000
8/15/2019	12000	60000	58000	69000	37000
8/16/2019	12000	56000	53000	68000	33000
8/17/2019	13000	53000	50000	65000	34000
8/18/2019	13000	55000	51000	67000	36000
8/19/2019	11000	52000	49000	66000	31000
8/20/2019	10000	53000	45000	65000	28000
8/21/2019	9000	47000	42000	69000	30000
8/22/2019	9000	46000	40000	67000	27000
8/23/2019	9000	45000	36000	63000	24000
8/24/2019	10000	43000	37000	64000	21000
8/25/2019	10000	45000	34000	60000	20000
8/26/2019	9000	43000	31000	55000	19000
8/27/2019	9000	44000	30000	54000	21000
8/28/2019	9000	47000	26000	50000	20000
8/29/2019	9000	46000	25000	48000	18000
8/30/2019	11000	48000	23000	49000	19000
8/31/2019	11000	49000	25000	51000	20000

9/1/2019	11000	47000	24000	52000	21000
9/2/2019	21000	46000	28000	56000	18000
9/3/2019	10000	49000	30000	59000	23000
9/4/2019	10000	48000	31000	58000	22000
9/5/2019	11000	45000	27000	61000	25000
9/6/2019	22000	42000	26000	60000	23000
9/7/2019	11000	41000	25000	57000	21000
9/8/2019	11000	40000	26000	58000	20000
9/9/2019	10000	38000	24000	55000	22000
9/10/2019	10000	37000	25000	53000	24000
9/11/2019	11000	35000	23000	54000	21000
9/12/2019	10000	33000	25000	52000	20000
9/13/2019	10000	35000	26000	49000	23000
9/14/2019	10000	33000	24000	45000	26000
9/15/2019	12000	32000	24000	46000	25000
9/16/2019	12000	33000	25000	44000	22000
9/17/2019	12000	32000	26000	43000	22000
9/18/2019	11000	31000	25000	44000	23000
9/19/2019	10000	29000	24000	40000	21000
9/20/2019	11000	28000	25000	37000	19000
9/21/2019	11000	26000	26000	35000	22000
9/22/2019	10000	25000	26000	34000	21000
9/23/2019	11000	27000	28000	35000	22000
9/24/2019	11000	26000	25000	34000	21000
9/25/2019	12000	28000	26000	36000	23000
9/26/2019	11000	27000	24000	35000	22000
9/27/2019	11000	25000	23000	34000	19000
9/28/2019	11000	27000	25000	35000	22000
9/29/2019	12000	26000	24000	33000	23000
9/30/2019	11000	25000	25000	35000	19000
10/1/2019	10000	27000	26000	38000	18000

10/2/2019	11000	28000	27000	37000	19000
10/3/2019	11000	26000	25000	37000	18000
10/4/2019	11000	29000	26000	39000	17000
10/5/2019	12000	30000	27000	40000	19000
10/6/2019	12000	31000	26000	39000	18000
10/7/2019	14000	32000	25000	40000	19000
10/8/2019	15000	34000	26000	39000	17000
10/9/2019	16000	31000	25000	37000	16000
10/10/2019	16000	30000	29000	34000	18000
10/11/2019	16000	29000	31000	32000	19000
10/12/2019	16500	28000	32000	30000	21000
10/13/2019	17000	26000	35000	31000	20000
10/14/2019	16000	24000	37000	29000	18000
10/15/2019	17000	23000	38000	29000	17000
10/16/2019	18000	25000	41000	29000	18000
10/17/2019	16000	26000	40000	29000	17000
10/18/2019	16000	23000	38000	28000	16000
10/19/2019	16000	23000	36000	26000	15000
10/20/2019	18000	21000	35000	25000	14000
10/21/2019	16000	19000	36000	27000	16000
10/22/2019	17000	20000	35000	29000	17000
10/23/2019	17000	21000	37000	28000	16000
10/24/2019	16000	21000	33000	27000	15000
10/25/2019	17000	22000	32000	29000	17000
10/26/2019	15500	18000	31000	29000	15000
10/27/2019	16000	19000	31000	28000	15000
10/28/2019	16000	17000	28000	27000	14000
10/29/2019	17000	15000	29000	29000	13000
10/30/2019	18000	16000	30000	30000	14000
10/31/2019	18000	15000	28000	30000	13000
11/1/2019	18000	16000	29000	29000	12000

11/2/2019	19000	14000	29000	29000	10000
11/3/2019	19000	15000	30000	28000	11000
11/4/2019	19000	18000	27000	29000	12000
11/5/2019	19000	19000	25000	31000	11000
11/6/2019	21000	21000	25000	30000	12000
11/7/2019	22000	23000	26000	29000	13000
11/8/2019	23000	24000	25000	30000	11000
11/9/2019	23000	24000	23000	32000	10000
11/10/2019	23000	23000	25000	30000	10000
11/11/2019	24000	24000	27000	29000	13000
11/12/2019	23000	23000	24000	28000	12000
11/13/2019	22000	22000	23000	25000	11000
11/14/2019	21000	23000	24000	23000	13000
11/15/2019	20000	21000	25000	23000	14000
11/16/2019	20000	26000	22000	25000	12000
11/17/2019	23000	23000	25000	24000	13000
11/18/2019	21000	21000	22000	22000	11000
11/19/2019	19000	22000	24000	21000	12000
11/20/2019	20000	20000	21000	20000	11000
11/21/2019	21000	22000	23000	21000	13000
11/22/2019	20000	19000	22000	21000	11000
11/23/2019	20000	17000	19000	20000	10000
11/24/2019	22000	19000	21000	22000	11000
11/25/2019	22000	18000	18000	20000	12000
11/26/2019	23000	17000	18000	19000	10000
11/27/2019	24000	16000	19000	21000	11000
11/28/2019	24000	18000	18000	22000	12000
11/29/2019	24000	17000	19000	24000	11000
11/30/2019	24000	19000	20000	24000	13000
12/1/2019	24000	21000	21000	25000	14000
12/2/2019	24000	19000	20000	23000	12000

12/3/2019	23000	18000	17000	24000	11000
12/4/2019	25000	17000	21000	24000	13000
12/5/2019	24000	19000	22000	25000	14000
12/6/2019	26000	20000	24000	27000	15000
12/7/2019	26000	22000	22000	28000	15000
12/8/2019	27000	20000	21000	30000	16000
12/9/2019	25000	17000	19000	27000	13000
12/10/2019	25000	19000	20000	28000	14000
12/11/2019	25000	23000	20000	31000	14000
12/12/2019	26000	26000	24000	32000	14000
12/13/2019	26000	27000	25000	30000	12000
12/14/2019	27000	28000	25000	31000	13000
12/15/2019	29000	27000	23000	30000	11000
12/16/2019	32000	28000	23000	32000	14000
12/17/2019	33000	28000	25000	29000	12000
12/18/2019	35000	27000	24000	30000	12000
12/19/2019	33000	26000	23000	31000	11000
12/20/2019	34000	28000	25000	29000	11000
12/21/2019	33000	30000	30000	32000	15000
12/22/2019	34000	35000	33000	33000	17000
12/23/2019	33000	33000	30000	31000	15000
12/24/2019	31000	19000	32000	32000	16000
12/25/2019	30000	29000	30000	31000	17000
12/26/2019	25000	28000	32000	26000	14000
12/27/2019	23000	32000	33000	29000	17000
12/28/2019	18000	30000	35000	32000	15000
12/29/2019	17000	32000	36000	33000	16000
12/30/2019	18000	30000	33000	33000	17000
12/31/2019	21000	35000	39000	34000	16000
1/1/2020	22000	37000	40000	36000	17000
1/2/2020	21000	36000	40000	32000	12000

1/3/2020	21000	42000	45000	37000	18000
1/4/2020	20000	45000	50000	42000	20000
1/5/2020	21000	42000	50000	55000	20000
1/6/2020	21000	40000	52000	43000	21000
1/7/2020	19000	42000	50000	42000	18000
1/8/2020	19000	43000	51000	48000	19000
1/9/2020	20000	45000	53000	53000	21000
1/10/2020	20000	47000	57000	50000	20000
1/11/2020	20000	46000	62000	53000	19000
1/12/2020	22000	47000	61000	54000	20000
1/13/2020	18000	45000	60000	53000	18000
1/14/2020	18000	52000	63000	57000	21000
1/15/2020	19000	55000	65000	60000	22000
1/16/2020	20000	52000	63000	64000	24000
1/17/2020	21000	42000	62000	62000	23000
1/18/2020	20000	37000	65000	65000	24000
1/19/2020	20000	35000	63000	64000	22000
1/20/2020	21000	34000	64000	63000	24000
1/21/2020	22000	38000	61000	68000	25000
1/22/2020	21000	37000	57000	70000	24000
1/23/2020	22000	39000	66000	75000	28000
1/24/2020	22000	38000	68000	73000	27000
1/25/2020	22000	40000	71000	67000	30000
1/26/2020	22000	39000	70000	65000	29000
1/27/2020	20000	43000	72000	70000	25000
1/28/2020	20000	50000	71000	70000	28000
1/29/2020	21000	55000	72000	74000	30000
1/30/2020	22000	57000	70000	71000	29000
1/31/2020	22000	54000	67000	57000	27000