



TUGAS AKHIR - KS184822

**PERAMALAN KUALITAS UDARA DI KOTA
SURABAYA UNTUK MENENTUKAN KATEGORI
INDEKS STANDAR PENCEMAR UDARA**

**HENDRI PRABOWO
NRP 062115 4000 0068**

**Dosen Pembimbing
Dr. Suhartono**

**PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA, KOMPUTASI, DAN SAINS DATA
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2019**



TUGAS AKHIR - KS184822

**PERAMALAN KUALITAS UDARA DI KOTA
SURABAYA UNTUK MENENTUKAN KATEGORI
INDEKS STANDAR PENCEMAR UDARA**

**HENDRI PRABOWO
NRP 062115 4000 0068**

**Dosen Pembimbing
Dr. Suhartono**

**PROGRAM STUDI SARJANA
DEPARTEMEN STATISTIKA
FAKULTAS MATEMATIKA, KOMPUTASI, DAN SAINS DATA
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA**



FINAL PROJECT - KS184822

**FORECASTING AIR QUALITY IN SURABAYA TO
DETERMINE AIR POLLUTION INDEX CATEGORY**

**HENDRI PRABOWO
NRP 062115 4000 0068**

**Supervisor
Dr. Suhartono**

**UNDERGRADUATE PROGRAMME
DEPARTMENT OF STATISTICS
FACULTY OF MATHEMATICS, COMPUTING, AND DATA SCIENCE
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA 2019**

(Halaman ini sengaja dikosongkan)

LEMBAR PENGESAHAN

PERAMALAN KUALITAS UDARA DI KOTA SURABAYA UNTUK MENENTUKAN KATEGORI INDEKS STANDAR PENCEMAR UDARA

TUGAS AKHIR

Diajukan Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Statistika
pada

Program Studi Sarjana Departemen Statistika
Fakultas Matematika, Komputasi, dan Sains Data
Institut Teknologi Sepuluh Nopember

Oleh :


Hendri Prabowo

NRP. 062115 4000 0068

Disetujui oleh Pembimbing:

Dr. Suhartono

NIP. 19710929 199512 1 001



Mengetahui,
Kepala Departemen Statistika

Dr. Suhartono ^{SA}

NIP. 19710929 199512 1 001

SURABAYA, JULI 2019

(Halaman ini sengaja dikosongkan)

PERAMALAN KUALITAS UDARA DI KOTA SURABAYA UNTUK MENENTUKAN KATEGORI INDEKS STANDAR PENCEMAR UDARA

Nama Mahasiswa : **Hendri Prabowo**
NRP : **062115 4000 0068**
Departemen : **Statistika**
Dosen Pembimbing : **Dr. Suhartono**

Abstrak

Pencemaran udara merupakan salah satu permasalahan yang dihadapi Kota Surabaya. Untuk melihat kualitas udara digunakan Indeks Standar Pencemar Udara (ISPU) yang didapatkan dari alat AQMS yang ada di stasiun SUF. Terdapat tiga stasiun SUF yang masih aktif di Kota Surabaya. Tujuan dari penelitian ini adalah meramalkan lima parameter kualitas udara ISPU yaitu CO, NO₂, O₃, PM₁₀ dan SO₂ di tiga stasiun SUF Kota Surabaya sehingga didapatkan nilai ISPU dan kategori kualitas udara Kota Surabaya. Peramalan yang dilakukan menggunakan beberapa metode yaitu time series regression, ARIMA, FFNN, LSTM, time series regression dengan AR error, time series regression dengan ARMA error, hibrida time series regression dan FFNN serta hibrida time series regression dan LSTM. Data parameter kualitas udara memiliki pola double seasonal. Hasil analisis menunjukkan perbedaan model terbaik dalam meramalkan parameter kualitas udara. ARIMA, LSTM, hibrida time series regression dan FFNN, hibrida time series regression dan LSTM masing-masing baik untuk meramalkan tiga variabel. Sedangkan FFNN, time series regression dengan AR error, time series regression dengan ARMA error masing-masing baik untuk satu variabel. Hasil peramalan menunjukkan bahwa nilai ISPU secara umum tinggi pada saat jam berangkat kerja dan pulang kerja.

Kata kunci: *ARIMA, FFNN, Hibrida, ISPU, LSTM, Time Series Regression*

(Halaman ini sengaja dikosongkan)

FORECASTING AIR QUALITY IN SURABAYA TO DETERMINE AIR POLLUTION INDEX CATEGORY

Name : **Hendri Prabowo**
Student Number : **062115 4000 0068**
Department : **Statistics**
Supervisor : **Dr. Suhartono**

Abstract

Air pollution is one of the problems in Surabaya. To see the air quality, air pollution index (API) was obtained from the AQMS tools in the SUF station. There are three SUF stations that are still active in Surabaya. The purpose of this research is to forecast five air quality parameters API in the three SUF stations of Surabaya. From the result of forecast, the API value and the air quality category of Surabaya are obtained. The forecast use several methods that is time series regression, ARIMA, FFNN, LSTM, time series regression with AR error, time series regression with ARMA error, hybrid time series regression-FFNN and hybrid time series regression-LSTM. Air quality parameters data has double seasonal pattern. The result of analysis show difference of the best model in forecasting air quality parameters. ARIMA, LSTM, hybrid time series regression-FFNN and hybrid time series regression-LSTM respectively good for predicting three variables. While FFNN, time series regression with AR error and time series regression with ARMA error respectively good for predicting one variable. Forecasting results show that the API value is generally high at the time of leaving work and returning from work.

Keywords: *API, ARIMA, FFNN, Hybrid, LSTM, Time Series Regression*

(Halaman ini sengaja dikosongkan)

KATA PENGANTAR

Puji syukur penulis panjatkan atas rahmat dan hidayah yang diberikan Allah SWT sehingga penulis dapat menyelesaikan laporan Tugas Akhir yang berjudul “Peramalan Kualitas Udara di Kota Surabaya untuk Menentukan Kategori Indeks Standar Pencemar Udara” dengan lancar.

Penulis menyadari bahwa Tugas Akhir ini dapat terselesaikan tidak terlepas dari bantuan dan dukungan berbagai pihak. Oleh karena itu, penulis menyampaikan terima kasih kepada:

1. Kedua orang tua, atas segala do'a, nasehat, kasih sayang, dan dukungan yang diberikan kepada penulis demi kesuksesan dan kebahagiaan penulis.
2. Dr. Suhartono selaku dosen pembimbing dan Ketua Departemen Statistika yang telah meluangkan waktu dan dengan sangat sabar memberikan bimbingan, saran, dukungan serta motivasi selama penyusunan Tugas Akhir.
3. Diaz Fitra Aksioma S.Si., M.Si dan Novri Suhermi S.Si., M.Sc selaku dosen-dosen yang menjadi dosen wali selama masa studi yang telah banyak memberikan saran dan arahan dalam proses belajar di Departemen Statistika.
4. Dr. Setiawan. dan M Sjahid Akbar S.Si., M.Si selaku dosen penguji yang selalu sabar dalam mengomentari serta memberikan masukan dan saran dalam penyelesaian Tugas Akhir.
5. Seluruh dosen Statistika ITS yang telah memberikan ilmu dan pengetahuan yang tak ternilai harganya, serta segenap karyawan Departemen Statistika ITS.
6. Teman-teman Statistika ITS $\Sigma 26$ angkatan 2015, yang selalu memberikan dukungan kepada penulis selama ini.
7. Semua teman, relasi dan berbagai pihak yang tidak bisa penulis sebutkan namanya satu persatu yang telah membantu dalam penulisan tugas akhir ini.

Besar harapan penulis untuk mendapatkan kritik dan saran yang membangun sehingga Tugas Akhir ini dapat memberikan manfaat bagi semua pihak yang terkait.

Surabaya, Juli 2019

Penulis

DAFTAR ISI

	Halaman
LEMBAR PENGESAHAN	iii
ABSTRAK	v
ABSTRACT	vii
KATA PENGANTAR	ix
DAFTAR ISI	xi
DAFTAR GAMBAR	xv
DAFTAR TABEL	xxi
DAFTAR LAMPIRAN	xxiii
DAFTAR NOTASI	xxv
BAB I PENDAHULUAN	1
1.1. Latar Belakang.....	1
1.2. Rumusan Masalah	7
1.3. Tujuan.....	8
1.4. Manfaat Penelitian.....	8
1.5. Batasan Masalah.....	9
BAB II TINJAUAN PUSTAKA	11
2.1. <i>Time Series Regression</i>	11
2.2. <i>Autoregressive Integrated Moving Average (ARIMA)</i> ..	11
2.3. <i>Time Series Regression</i> dengan <i>ARIMA Error</i>	17
2.4. <i>Feed Forward Neural Network</i>	18
2.5. <i>Long Short Term Memory</i>	22
2.6. Model Hibrida (<i>Hybrid</i>)	26
2.7. Uji Linieritas.....	26
2.8. Kriteria Kebaikan Model	28
2.9. Pencemaran Udara.....	28
BAB III METODOLOGI PENELITIAN	33
3.1. Sumber Data	33
3.2. Variabel Penelitian	33
3.3. Langkah Analisis	33
BAB IV ANALISIS DAN PEMBAHASAN	55
4.1. Karakteristik Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya	55

4.1.1. Karakteristik Parameter Kualitas Udara CO di Kota Surabaya.....	55
4.1.2. Karakteristik Parameter Kualitas Udara NO ₂ di Kota Surabaya.....	59
4.1.3. Karakteristik Parameter Kualitas Udara O ₃ di Kota Surabaya.....	62
4.1.4. Karakteristik Parameter Kualitas Udara PM ₁₀ di Kota Surabaya.....	65
4.1.5. Karakteristik Parameter Kualitas Udara SO ₂ di Kota Surabaya.....	68
4.2. Pemodelan Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya	70
4.2.1. Pemodelan Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya dengan <i>Time Series Regression</i>	71
4.2.2. Pemodelan Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya dengan ARIMA	78
4.2.3. Pemodelan Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya dengan FFNN	88
4.2.4. Pemodelan Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya dengan LSTM.....	96
4.2.5. Pemodelan Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya dengan <i>Time Series Regression</i> dengan <i>AR Error</i>	102
4.2.6. Pemodelan Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya dengan <i>Time Series Regression</i> dengan <i>ARMA Error</i>	107
4.2.7. Pemodelan Parameter Kualitas Udara di 3 Stasiun SUF Kota Surabaya dengan Hibrida <i>Time Series Regression</i> dan FFNN.....	116
4.2.8. Pemodelan Parameter Kualitas Udara di 3 Stasiun SUF Kota Surabaya dengan Hibrida <i>Time Series Regression</i> dan LSTM	122

4.3. Perbandingan Keباikan Model	126
4.4. Peramalan Lima Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya	141
4.5. Penentuan Nilai ISPU di Kota Surabaya	146
BAB V KESIMPULAN DAN SARAN	149
5.1. Kesimpulan.....	149
5.2. Saran	150
DAFTAR PUSTAKA	151
LAMPIRAN	157

(Halaman ini sengaja dikosongkan)

DAFTAR GAMBAR

	Halaman
Gambar 2.1 Arsitektur FFNN	19
Gambar 2.2 Arsitektur LSTM.....	23
Gambar 2.3 Struktur <i>Memory Block</i> LSTM.....	24
Gambar 2.4 Peta Stasiun SUF Aktif Kota Surabaya.....	31
Gambar 2.5 Stasiun SUF 1 (a), SUF 6 (b) dan SUF 7 (c) Kota Surabaya.....	32
Gambar 3.1 Diagram Alir Penelitian Secara Umum.....	39
Gambar 3.2 Diagram Alir Pemodelan ARIMA	40
Gambar 3.3 Diagram Alir Pemodelan <i>Feed Forward Neural Network</i>	41
Gambar 3.4 Diagram Alir Pemodelan <i>Long Short Term Memory</i>	42
Gambar 3.5 Diagram Alir Pemodelan <i>Time Series Regression</i> dengan <i>AR error</i>	43
Gambar 3.6 Diagram Alir Pemodelan <i>Time Series Regression</i> dengan <i>ARMA error</i>	44
Gambar 3.7 Diagram Alir Pemodelan Hibrida <i>Time Series Regression</i> dan FFNN	45
Gambar 3.8 Diagram Alir Pemodelan Hibrida <i>Time Series Regression</i> dan LSTM.....	46
Gambar 3.9 Ilustrasi Pembentukan Model <i>Time Series Regression</i>	47
Gambar 3.10 Ilustrasi Pembentukan Model ARIMA	48
Gambar 3.11 Ilustrasi Pembentukan Model FFNN.....	49
Gambar 3.12 Ilustrasi Pembentukan Model LSTM	50
Gambar 3.13 Ilustrasi Pembentukan Model <i>Time Series Regression</i> dengan <i>AR Error</i>	51
Gambar 3.14 Ilustrasi Pembentukan Model <i>Time Series Regression</i> dengan <i>ARMA Error</i>	52
Gambar 3.15 Ilustrasi Pembentukan Model Hibrida <i>Time Series Regression</i> dan FFNN	53

Gambar 3.16	Ilustrasi Pembentukan Model Hibrida <i>Time Series Regression</i> dan LSTM.....	54
Gambar 4.1	<i>Time Series Plot</i> CO Tahun 2018 di SUF 1 (a), SUF 6 (b) dan SUF 7 (c) Kota Surabaya.....	56
Gambar 4.2	<i>Interval Plot</i> CO di SUF 1 (a), SUF 6 (b), SUF 7 (c) dan <i>Line Plot</i> CO di SUF 1 (d), SUF 6 (e), SUF 7 (f)	58
Gambar 4.3	<i>Time Series Plot</i> NO ₂ Tahun 2018 di SUF 1 (a), SUF 6 (b) dan SUF 7 (c) Kota Surabaya.....	59
Gambar 4.4	<i>Interval Plot</i> NO ₂ di SUF 1 (a), SUF 6 (b), SUF 7 (c) dan <i>Line Plot</i> NO ₂ di SUF 1 (d), SUF 6 (e), SUF 7 (f)	61
Gambar 4.5	<i>Time Series Plot</i> O ₃ Tahun 2018 di SUF 1 (a), SUF 6 (b) dan SUF 7 (c) Kota Surabaya.....	62
Gambar 4.6	<i>Interval Plot</i> O ₃ di SUF 1 (a), SUF 6 (b), SUF 7 (c) dan <i>Line Plot</i> O ₃ di SUF 1 (a), SUF 6 (b), SUF 7 (c).....	64
Gambar 4.7	<i>Time Series Plot</i> PM ₁₀ Tahun 2018 di SUF 1 (a), SUF 6 (b) dan SUF 7 (c) Kota Surabaya.....	65
Gambar 4.8	<i>Interval Plot</i> PM ₁₀ di SUF 1 (a), SUF 6 (b), SUF 7 (c) dan <i>Line Plot</i> PM ₁₀ di SUF 1 (d), SUF 6 (e), SUF 7 (f)	67
Gambar 4.9	<i>Time Series Plot</i> SO ₂ Tahun 2018 di SUF 1 (a), SUF 6 (b) dan SUF 7 (c) Kota Surabaya.....	68
Gambar 4.10	<i>Interval Plot</i> SO ₂ di SUF 1 (a), SUF 6 (b), SUF 7 (c) dan <i>Line Plot</i> SO ₂ di SUF 1 (d), SUF 6 (e), SUF 7 (f)	70
Gambar 4.11	Plot ACF (a) dan Pengujian Normalitas (b) Residual Model <i>Time Series Regression</i> CO SUF 1	76
Gambar 4.12	Perbandingan Data Aktual dan Ramalan CO SUF 1 Menggunakan <i>Time Series Regression</i> pada Data <i>In-Sample</i> (a) dan <i>Out-of-Sample</i> (b) ..	77

Gambar 4.13	Plot ACF (a) dan PACF (b) CO SUF 1.....	80
Gambar 4.14	Perbandingan Data Aktual dan Ramalan CO SUF 1 Menggunakan ARIMA pada Data <i>In-Sample</i> (a) dan <i>Out-of-Sample</i> (b).....	85
Gambar 4.15	<i>Feature Selection Input Neural Network</i> Variabel CO SUF 1	88
Gambar 4.16	Arsitektur FFNN CO SUF 1.....	90
Gambar 4.17	Perbandingan Data Aktual dan Ramalan CO SUF 1 Menggunakan FFNN pada Data <i>In-Sample</i> (a) dan <i>Out-of-Sample</i> (b)	94
Gambar 4.18	Arsitektur LSTM CO SUF 1	97
Gambar 4.19	Perbandingan Data Aktual dan Ramalan CO SUF 1 Menggunakan LSTM pada Data <i>In-Sample</i> (a) dan <i>Out-of-Sample</i> (b)	100
Gambar 4.20	Plot Antara Residual Model <i>Time Series Regression</i> dari CO SUF 1 dengan <i>Lag</i> 1 (a), <i>Lag</i> 48 (b) dan <i>Lag</i> 336 (c).....	103
Gambar 4.21	Perbandingan Data Aktual dan Ramalan CO SUF 1 Menggunakan <i>Time Series Regression</i> dengan <i>AR Error</i> pada Data <i>In-Sample</i> (a) dan <i>Out-of-Sample</i> (b).....	105
Gambar 4.22	Plot ACF (a) dan PACF (b) Residual Model <i>Time Series Regression</i> CO SUF 1	108
Gambar 4.23	Perbandingan Data Aktual dan Ramalan CO SUF 1 Menggunakan <i>Time Series Regression</i> dengan ARMA pada Data <i>In-Sample</i> (a) dan <i>Out-of-Sample</i> (b).....	113
Gambar 4.24	<i>Feature Selection Input Neural Network</i> Residual Model <i>Time Series Regression</i> CO SUF 1	116
Gambar 4.25	Arsitektur FFNN dari Model Hibrida CO SUF 1	118

Gambar 4.26	Perbandingan Data Aktual dan Ramalan CO SUF 1 Menggunakan Hibrida <i>Time Series</i> <i>Regression</i> dan FFNN pada Data <i>In-Sample</i> (a) dan <i>Out-of-Sample</i> (b).....	120
Gambar 4.27	Arsitektur LSTM dari Model Hibrida CO SUF 1	123
Gambar 4.28	Perbandingan Data Aktual dan Ramalan CO SUF 1 Menggunakan Hibrida <i>Time Series</i> <i>Regression</i> dan LSTM pada Data <i>In-Sample</i> (a) dan <i>Out-of-Sample</i> (b).....	125
Gambar 4.29	Frekuensi Metode Terbaik	135
Gambar 4.30	RMSE <i>Adaptive</i> Parameter Kualitas Udara CO SUF 1 (a), SUF 6 (b) dan SUF 7 (c).....	136
Gambar 4.31	RMSE <i>Adaptive</i> Parameter Kualitas Udara NO ₂ SUF 1 (a), SUF 6 (b) dan SUF 7 (c).....	137
Gambar 4.32	RMSE <i>Adaptive</i> Parameter Kualitas Udara O ₃ SUF 1 (a), SUF 6 (b) dan SUF 7 (c).....	138
Gambar 4.33	RMSE <i>Adaptive</i> Parameter Kualitas Udara PM ₁₀ SUF 1 (a), SUF 6 (b) dan SUF 7 (c).....	139
Gambar 4.34	RMSE <i>Adaptive</i> Parameter Kualitas Udara SO ₂ SUF 1 (a), SUF 6 (b) dan SUF 7 (c).....	140
Gambar 4.35	Hasil Peramalan CO pada Data <i>In-Sample</i> di SUF 1 (a), SUF 6 (c) dan SUF 7 (e) serta Data <i>Out-of-Sample</i> di SUF 1 (b), SUF 6 (d) dan SUF 7 (f).....	141
Gambar 4.36	Hasil Peramalan NO ₂ pada Data <i>In-Sample</i> di SUF 1 (a), SUF 6 (c) dan SUF 7 (e) serta Data <i>Out-of-Sample</i> di SUF 1 (b), SUF 6 (d) dan SUF 7 (f).....	142
Gambar 4.37	Hasil Peramalan O ₃ pada Data <i>In-Sample</i> di SUF 1 (a), SUF 6 (c) dan SUF 7 (e) serta Data <i>Out-of-Sample</i> di SUF 1 (b), SUF 6 (d) dan SUF 7 (f).....	144

Gambar 4.38	Hasil Peramalan PM_{10} pada Data <i>In-Sample</i> di SUF 1 (a), SUF 6 (c) dan SUF 7 (e) serta Data <i>Out-of-Sample</i> di SUF 1 (b), SUF 6 (d) dan SUF 7 (f).....	145
Gambar 4.39	Hasil Peramalan SO_2 pada Data <i>In-Sample</i> di SUF 1 (a), SUF 6 (c) dan SUF 7 (e) serta Data <i>Out-of-Sample</i> di SUF 1 (b), SUF 6 (d) dan SUF 7 (f).....	146
Gambar 4.40	Ramalan Nilai ISPU Kota Surabaya	147

(Halaman ini sengaja dikosongkan)

DAFTAR TABEL

	Halaman
Tabel 2.1	Bentuk Transformasi 13
Tabel 2.2	Plot ACF dan PACF Model ARIMA 14
Tabel 2.3	Angka dan Kategori ISPU 29
Tabel 2.4	Batas ISPU 30
Tabel 3.1	Struktur Data Kualitas Udara 34
Tabel 4.1	Karakteristik Data CO 57
Tabel 4.2	Karakteristik Data NO ₂ 60
Tabel 4.3	Karakteristik Data O ₃ 63
Tabel 4.4	Karakteristik Data PM ₁₀ 66
Tabel 4.5	Karakteristik Data SO ₂ 69
Tabel 4.6	Estimasi Parameter Model <i>Time Series</i> <i>Regression</i> CO SUF 1 71
Tabel 4.7	Transformasi <i>Box Cox</i> 78
Tabel 4.8	Hasil Pengujian Asumsi Residual <i>White Noise</i> Model ARIMA CO SUF 1 81
Tabel 4.9	Nilai Autokorelasi Residual Model ARIMA CO SUF 1 82
Tabel 4.10	Estimasi Parameter Model ARIMA CO SUF 1 ... 82
Tabel 4.11	Model ARIMA Masing-Masing Parameter Kualitas Udara di 3 Stasiun SUF Kota Surabaya. 86
Tabel 4.12	Perbandingan Nilai Akurasi Model FFNN CO SUF 1 pada Data <i>In-Sample</i> dan <i>Out-of-Sample</i> . 89
Tabel 4.13	Estimasi Parameter Pembobot FFNN CO SUF 1. 91
Tabel 4.14	Arsitektur FFNN Optimum 95
Tabel 4.15	Perbandingan Nilai Akurasi Model LSTM CO SUF 1 pada Data <i>In-Sample</i> dan <i>Out-of-Sample</i> . 98
Tabel 4.16	Arsitektur LSTM Optimum 101
Tabel 4.17	Perbandingan Nilai Akurasi TSR dengan AR <i>Error</i> CO SUF 1 pada Data <i>In-Sample</i> dan <i>Out-</i> <i>of-Sample</i> 104

Tabel 4.18	Hasil Pengujian Asumsi Residual <i>White Noise</i> Model AR dari Residual <i>Time Series Regression</i> CO SUF 1	104
Tabel 4.19	Model AR Terbaik dari Residual Masing-Masing Model <i>Time Series Regression</i> dari Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya.....	107
Tabel 4.20	Hasil Pengujian Asumsi Residual <i>White Noise</i> Model ARMA Residual Model <i>Time Series Regression</i> CO SUF 1	109
Tabel 4.21	Nilai Autokorelasi Residual Model ARMA dari Residual <i>Time Series Regression</i> CO SUF 1	110
Tabel 4.22	Estimasi Parameter Model ARMA dari Residual Model <i>Time Series Regression</i> CO SUF 1	111
Tabel 4.23	Model ARMA Terbaik dari Residual Masing-Masing Model <i>Time Series Regression</i> dari Parameter Kualitas Udara di 3 Stasiun SUF Kota Surabaya.....	114
Tabel 4.24	Perbandingan Nilai Akurasi Model Hibrida <i>Time Series Regression</i> dan FFNN CO SUF 1 pada Data <i>In-Sample</i> dan <i>Out-of-Sample</i>	117
Tabel 4.25	Arsitektur Model Hibrida <i>Time Series Regression</i> dan FFNN Optimum.....	121
Tabel 4.26	Perbandingan Nilai Akurasi Model Hibrida <i>Time Series Regression</i> dan LSTM CO SUF 1 pada Data <i>In-Sample</i> dan <i>Out-of-Sample</i>	122
Tabel 4.27	Arsitektur Model Hibrida <i>Time Series Regression</i> dan LSTM Optimum	126
Tabel 4.28	Perbandingan Nilai Akurasi Setiap Model pada Data <i>In-Sample</i> dan <i>Out-of-Sample</i>	127

DAFTAR LAMPIRAN

	Halaman
Lampiran 1. Data Lima Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya	157
Lampiran 2. <i>Output Time Series Regression</i> pada Lima Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya	158
Lampiran 3. <i>Output ARIMA</i> pada Lima Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya	186
Lampiran 4. Uji <i>White</i>	211
Lampiran 5. Perbandingan <i>Neuron Optimum</i> pada <i>Hidden Layer</i> FFNN	217
Lampiran 6. Arsitektur FFNN pada Lima Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya	220
Lampiran 7. Perbandingan <i>Neuron Optimum</i> pada <i>Hidden Layer</i> LSTM.....	227
Lampiran 8. <i>Output LSTM</i> pada Lima Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya	230
Lampiran 9. Perbandingan Model AR Terbaik pada Model TSR dengan AR <i>Error</i>	249
Lampiran 10. <i>Output Model AR</i> dari Residual <i>Time Series Regression</i> pada Lima Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya.....	253
Lampiran 11. <i>Output Model ARMA</i> dari Residual <i>Time Series Regression</i> pada Lima Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya.....	264
Lampiran 12. Perbandingan <i>Neuron Optimum</i> pada Model Hibrida <i>Time Series Regression</i> dan FFNN	284
Lampiran 13. Arsitektur FFNN dari Model Hibrida <i>Time Series Regression</i> dan FFNN pada Lima Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya	287

Lampiran 14. Perbandingan <i>Neuron</i> Optimum pada Model Hibrida <i>Time Series Regression</i> dan LSTM.....	294
Lampiran 15. Output LSTM dari Model Hibrida <i>Time Series Regression</i> dan LSTM pada Lima Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya.....	297
Lampiran 16. Nilai Ramalan ISPU	312
Lampiran 17. <i>Syntax</i> Uji <i>White</i>	318
Lampiran 18. <i>Syntax</i> FFNN.....	319
Lampiran 19. <i>Syntax</i> LSTM	321
Lampiran 20. Surat Keterangan Sumber Data.....	324

DAFTAR NOTASI

Time Series Regression

β_j Koefisien parameter ke- j *time series regression*

a_t Residual ke- t dari *time series regression*

ARIMA

a_t Residual ke- t dari ARIMA

B *Backshift* operator

$\phi_p(B)$ Koefisien parameter AR non musiman dengan orde p

$\theta_q(B)$ Koefisien parameter MA non musiman dengan orde q

$(1 - B)^d$ *Differencing* non musiman dengan orde d

$\Phi_p(B^S)$ Koefisien parameter AR musiman dengan orde P

$\Theta_Q(B^S)$ Koefisien parameter MA musiman dengan orde Q

$(1 - B^S)^D$ *Differencing* musiman dengan orde D

Time Series Regression dengan ARIMA Error

ε_t Residual ke- t dari model *time series regression* dengan ARIMA *error*

Feed Forward Neural Network

$X_{i(t)}$ Variabel *input* sebanyak p , ($i = 1, 2, \dots, p$)

$\hat{Y}_{(t)}$	Nilai dugaan dari variabel <i>output</i>
w_{ji}^h	Bobot dari <i>input</i> ke- <i>i</i> yang menuju <i>neuron</i> ke- <i>j</i> pada <i>hidden layer</i>
b_j^h	Bias pada <i>neuron</i> ke- <i>j</i> pada <i>hidden layer</i>
f_j^h	Fungsi aktivasi di <i>neuron</i> ke- <i>j</i> pada <i>hidden layer</i>
w_j^o	Bobot dari <i>neuron</i> ke- <i>j</i> di <i>hidden layer</i> yang menuju <i>neuron</i> pada <i>output layer</i>
b^o	Bias pada <i>neuron</i> di <i>output layer</i>
f^o	Fungsi aktivasi pada <i>neuron</i> di <i>output layer</i>

Long Short Term Memory

h_t	<i>Hidden state</i> ke- <i>t</i>
F_t	Nilai <i>forget gate</i> ke- <i>t</i>
W_{fh}	Bobot <i>hidden state</i> pada <i>forget gate</i>
W_{fx}	Bobot <i>input</i> pada <i>forget gate</i>
b_f	Bias pada <i>forget gate</i>
\hat{C}_t	Nilai kandidat <i>cell state</i> ke- <i>t</i>
W_{ch}	Bobot <i>hidden state</i> pada kandidat <i>cell state</i>

W_{cx}	Bobot <i>input</i> pada kandidat <i>cell state</i>
b_c	Bias pada kandidat <i>cell state</i>
U_t	Nilai <i>filter input gate</i> ke- t
W_{uh}	Bobot <i>hidden state</i> pada <i>filter input gate</i>
W_{ux}	Bobot <i>input</i> pada <i>filter input gate</i>
b_u	Bias pada <i>filter input gate</i>
C_t	Nilai <i>cell state</i> ke- t
O_t	Nilai <i>filter output gate</i> ke- t
W_{oh}	Bobot <i>hidden state</i> pada <i>filter output gate</i>
W_{ox}	Bobot <i>input</i> pada <i>filter output gate</i>
b_o	Bias pada <i>filter output gate</i>

Model Hibrida

L_t	Komponen linier model hibrida
a_t	Residual komponen linier
N_t	Komponen nonlinier model hibrida
ε_t	Residual model hibrida

(Halaman ini sengaja dikosongkan)

BAB I

PENDAHULUAN

1.1. Latar Belakang

Kota Surabaya merupakan ibukota dari provinsi Jawa Timur. Kota Surabaya terletak di antara $112^{\circ} 36'$ - $112^{\circ} 54'$ Bujur Timur dan $7^{\circ} 21'$ Lintang Selatan. Wilayah Kota Surabaya berbatasan langsung dengan Selat Madura di sebelah utara dan di sebelah timur, sedangkan di sebelah selatan berbatasan dengan Kabupaten Sidoarjo dan berbatasan dengan Kabupaten Gresik di sebelah barat. Total luas wilayah Surabaya adalah $326,36 \text{ km}^2$ dengan Kecamatan Benowo merupakan kecamatan dengan wilayah terluas yaitu $23,73 \text{ km}^2$ yang terletak di Surabaya Barat. Sedangkan Kecamatan Simokerto adalah kecamatan dengan luasan terkecil yaitu $2,59 \text{ km}^2$ terletak di Surabaya Pusat (Alamsyah, 2018). Jumlah penduduk Kota Surabaya terus mengalami pertambahan tiap tahun. Rata-rata laju pertumbuhan penduduk Kota Surabaya tahun 2013 hingga tahun 2017 adalah 0,49 persen per tahun (Alamsyah, 2018). Semakin bertambahnya jumlah penduduk, menjadikan Kota Surabaya semakin padat. Dengan jumlah penduduk mencapai 2,87 juta jiwa menjadikan Kota Surabaya sebagai kota terpadat kedua di Indonesia. Semakin padatnya Kota Surabaya mengakibatkan munculnya berbagai permasalahan. Hal ini dikarenakan meningkatnya kepadatan penduduk dapat mengakibatkan terjadinya perubahan lingkungan.

Permasalahan yang sering muncul di Kota Surabaya adalah pencemaran udara (Wardhana, 2004). Pencemaran udara merupakan permasalahan yang dialami oleh semua wilayah di dunia (Amann, Klimont & Wagner, 2013). Pencemaran udara dapat mempengaruhi kesejahteraan manusia, baik secara langsung ataupun secara tidak langsung. Pengaruh pencemaran udara secara langsung dapat berupa penyakit dan kematian (Tallon, Manjourides, Pun, Salhi & Suh, 2017), sedangkan pengaruhnya secara tidak langsung adalah terganggunya berbagai sumber daya

alam yang penting untuk kehidupan dan kesejahteraan manusia (Dahlan, 1989).

Pencemaran udara umumnya diartikan sebagai bertambahnya bahan atau substrat fisik/kimia ke dalam lingkungan udara normal yang mencapai jumlah tertentu, sehingga dapat dideteksi oleh manusia serta dapat memberikan efek pada manusia, binatang, vegetasi, dan material (Mukono, 1997). Sehingga pencemaran udara secara langsung maupun tidak langsung berdampak pada kehidupan manusia. Terdapat dua jenis sumber pencemaran udara, yang pertama adalah pencemaran akibat sumber alamiah (*natural sources*) seperti letusan gunung berapi dan yang kedua berasal dari kegiatan manusia (*anthropogenic sources*) seperti yang berasal dari transportasi, emisi pabrik, dan lain-lain (Simanjutak, 2007). Pencemaran udara dapat terjadi di berbagai tempat, seperti di dalam rumah, sekolah, dan kantor.

Tingkat pencemaran udara yang terjadi di Kota Surabaya sudah mencapai titik yang mengkhawatirkan (Wardhana, 2004). Penyebab utama terjadinya pencemaran di Kota Surabaya adalah sektor transportasi. Sebagai kota metropolitan, pusat industri dan perdagangan di Jawa Timur mengakibatkan volume lalu lintas di Kota Surabaya menjadi tinggi. Volume lalu lintas yang tinggi akan berdampak terhadap terjadinya pencemaran udara yang diakibatkan oleh gas buang dari kendaraan bermotor (Iskandar, 2006). Jumlah kendaraan bermotor di Kota Surabaya untuk kendaraan roda dua mencapai 2159069 dan untuk kendaraan roda 4 mencapai 670573 pada tahun 2017 (Priyambodo, 2018). Sebagian besar kendaraan bermotor menggunakan BBM. Penggunaan BBM ini menjadi penyumbang yang besar terhadap pencemaran udara karena di dalam bahan bakar tersebut terkandung bahan – bahan yang membahayakan terhadap kesehatan manusia dan merusak lingkungan. Bahan – bahan yang terkandung dalam BBM adalah CO, HC, NO_x, SO_x, timbal dan sejenisnya. Kontribusi pencemaran udara dari sektor transportasi mencapai 60%, di mana kendaraan bertanggung jawab 25% dari emisi CO₂, 90% dari CO, dan 50% dari NO_x yang dihasilkan emisi

di seluruh dunia (Kusuma, 2010). Selain itu, kendaraan bermotor juga dapat meningkatkan PM_{10} di udara. PM_{10} dan emisi dari kendaraan bermotor ini sangat berbahaya karena dapat mengakibatkan Infeksi Saluran Pernapasan Akut (ISPA).

Pencemaran udara merupakan permasalahan yang harus diselesaikan di Kota Surabaya. Udara merupakan salah satu sumber kehidupan dan udara yang biasa digunakan untuk kehidupan sehari-hari ini disebut udara ambien (PP No.41 Tahun 1999). Informasi yang dipakai untuk mengindikasikan kondisi kualitas udara ambien salah satunya adalah Indeks Standar Pencemar Udara (ISPU). ISPU adalah angka yang tidak mempunyai satuan yang menggambarkan kondisi kualitas udara ambien di lokasi dan waktu tertentu yang didasarkan pada dampak terhadap kesehatan manusia, nilai estetika dan makhluk hidup lainnya. Berdasarkan Keputusan Menteri Negara Lingkungan Hidup No 45 tentang Indeks Standar Pencemar Udara, parameter yang dipakai untuk menghitung ISPU adalah PM_{10} , CO, SO_2 , NO_2 dan O_3 .

Hampir semua manusia dan makhluk hidup lainnya membutuhkan udara demi kelangsungan hidupnya. Sehingga perlu untuk mengontrol kualitas udara. Pemantauan kualitas udara secara ambien di Indonesia menggunakan *Air Ambien Quality Monitoring System* (AQMS). Kualitas udara secara ambien dipengaruhi oleh beberapa faktor seperti faktor meteorologi, demografi, cuaca dan sumber emisi. AQMS ini telah dipasang di 10 kota besar di Indonesia pada tahun 1999 termasuk Kota Surabaya, tetapi pada akhir tahun 2010 terdapat banyak alat yang telah rusak (CAI-Asia, 2010). Pemantauan kualitas udara di Kota Surabaya telah dilakukan oleh Dinas Lingkungan Hidup Kota Surabaya dengan AQMS. AQMS adalah sistem terintegrasi yang memonitor kualitas udara ambien pada berbagai wilayah secara rutin dalam 24 jam oleh stasiun SUF yang kemudian ditampilkan pada *public data display* yang berada di beberapa tempat di Kota Surabaya (DLH, 2017). Pada *public data display* ini akan ditampilkan gambaran kategori dari ISPU, terdapat 5 kategori kualitas udara yaitu baik,

sedang, tidak sehat, sangat tidak sehat dan berbahaya. Di Kota Surabaya terdapat 7 stasiun SUF yang dipasang di berbagai wilayah, tetapi hanya terdapat 3 stasiun SUF yang berfungsi yaitu Taman Prestasi Kantor Gubernur, Wonorejo dan Kebonsari.

Pemantauan dengan stasiun SUF hanya menampilkan kualitas udara pada saat itu juga dan tidak dapat memprediksi kualitas udara beberapa waktu yang akan datang (Chrisdayanti & Suharsono, 2015). Sangat diperlukan peramalan mengenai kualitas udara beberapa waktu kedepan di Kota Surabaya agar bisa digunakan sebagai peringatan dini mengenai kualitas udara di Kota Surabaya. Sehingga dalam penelitian ini akan dicari model untuk meramalkan kualitas udara di Kota Surabaya berdasarkan 5 parameter ISPU dari 3 stasiun SUF. Berdasarkan hasil peramalan tersebut akan didapatkan kategori kualitas udara di Kota Surabaya untuk beberapa waktu kedepan.

Penelitian mengenai peramalan kualitas udara telah banyak dilakukan. Penelitian mengenai peramalan kualitas udara pernah dilakukan oleh Chrisdayanti dan Suharsono (2015) dengan menggunakan *Double Seasonal* ARIMA (DSARIMA) untuk meramalkan kandungan PM_{10} dalam udara ambien di Kota Surabaya. Peramalan yang dilakukan menggunakan data yang berasal dari 2 stasiun pemantauan yaitu SUF 6 dan 7. Dari penelitian yang telah dilakukan, belum ada penelitian yang melibatkan semua parameter kualitas udara ISPU. Sangat diperlukan untuk melakukan peramalan pada semua parameter ISPU di Kota Surabaya sehingga selain dapat meramalkan semua parameter kualitas udara juga bisa digunakan untuk menentukan kategori kualitas udara di Kota Surabaya. Penelitian lain yang pernah dilakukan yaitu dilakukan oleh Nahdliyah (2019), dengan melakukan peramalan kualitas udara di Kota Surabaya pada parameter CO dan PM_{10} pada 3 stasiun SUF. Analisis yang dilakukan melibatkan data *spatio temporal* dan dilakukan peramalan secara multivariat dengan MGSTAR. Peramalan yang dilakukan dibandingkan dengan peramalan secara univariat dengan DSARIMA. Kesimpulan yang didapatkan yaitu peramalan secara

univariat dengan DSARIMA menghasilkan hasil peramalan yang lebih baik pada kedua parameter di ketiga SUF berdasarkan nilai RMSE dan sMAPE. Hal ini menunjukkan bahwa tidak terdapat hubungan diantara parameter kualitas udara ISPU. Sehingga dalam penelitian ini akan dilakukan peramalan secara univariat, dengan data temporal dan melibatkan lima parameter kualitas udara dalam ISPU.

Salah satu metode peramalan yang umum digunakan adalah metode statistika seperti metode *naïve*, *exponential smoothing*, dan *autoregressive integrated moving average* (ARIMA) (Hanke & Wichern, 2005). Saat ini peramalan yang dilakukan banyak memanfaatkan *machine learning* yang merupakan bagian dari *artificial intelligence* dengan memanfaatkan metode-metode untuk mempelajari struktur suatu data di dimensi yang lebih tinggi untuk memprediksikan output dalam dimensi yang lebih rendah dengan menggunakan algoritma tertentu (Lewis, 2016). Selain itu juga terdapat metode hibrida, metode ini merupakan metode gabungan yang digunakan pada data yang memiliki pola gabungan. Hal ini dikarenakan jarang ditemukan data yang memiliki pola linier atau pola nonlinier saja. Sering ditemukan data dengan pola gabungan linier dan nonlinier, sehingga perlu untuk membentuk model berdasarkan kombinasi beberapa sistem (Zhang, 2003). Tetapi yang harus diperhatikan bahwa pada kasus tertentu metode yang lebih kompleks tidak menghasilkan hasil peramalan yang lebih baik dibandingkan dengan metode statistika (Makridakis & Hibbon, 2000).

Penelitian mengenai peramalan dengan membandingkan beberapa metode telah dilakukan oleh Ayu, Susilaningrum dan Suhartono (2016) yang melakukan pemodelan produksi minyak bumi dan gas bumi menggunakan metode ARIMA, *feed forward neural network* (FFNN) dan hibrida ARIMA-FFNN. Berdasarkan nilai RMSEP pada data *out-of-sample* menunjukkan bahwa pada peramalan minyak bumi metode FFNN yang terbaik sedangkan pada peramalan gas alam metode hibrida ARIMA-FFNN lebih baik. Penelitian yang dilakukan oleh Cheng, Zhang, Liu, Chen dan

Wang (2019) dengan melakukan peramalan $PM_{2.5}$ di lima kota di China dengan membandingkan beberapa metode individu yaitu ARIMA, ANN dan SVM dengan metode hibrida. Hasil penelitian menunjukkan bahwa metode hibrida lebih baik digunakan untuk meramalkan $PM_{2.5}$ dibandingkan metode individu. Penelitian yang dilakukan oleh Robles dkk (2008) dengan melakukan peramalan konsentrasi PM_{10} di Temuco Chile dengan metode ARIMA, *Artificial Neural Network* dan hibrida ARIMA ANN. Didapatkan bahwa metode hibrida ARIMA ANN merupakan metode terbaik untuk meramalkan PM_{10} . Pada penelitian Ma, Tao, Wang, Yu dan Wang (2015) dengan melakukan peramalan *traffic speed* menggunakan *remote microwave sensor data* menggunakan beberapa metode *elman neural network*, *kalman filler*, *long short term memory* (LSTM) dan ARIMA menghasilkan kesimpulan bahwa metode LSTM menghasilkan nilai MAPE dan MSE terkecil. Berdasarkan beberapa penelitian yang dilakukan menunjukkan bahwa tidak terdapat suatu metode peramalan yang selalu terbaik untuk meramalkan semua data. Sehingga perlu untuk membandingkan beberapa metode dalam melakukan peramalan. Hal ini dikarenakan bahwa tiap metode memiliki kelebihan dan kekurangan masing-masing (Makridakis, Spiliotis & Assimakopoulos, 2018).

Dalam penelitian ini akan dilakukan peramalan kualitas udara secara univariat pada lima parameter kualitas udara ISPU di tiga stasiun SUF di Kota Surabaya dengan menggunakan beberapa metode. Metode yang digunakan adalah metode individu dan hibrida. Metode individu yang digunakan adalah metode statistika yaitu *time series regression* dan ARIMA serta metode *machine learning* yaitu FFNN dan LSTM. Metode LSTM merupakan jaringan pengembangan dari RNN dengan konfigurasi empat gerbang (*gate*) yaitu gerbang *input*, gerbang modulasi *input*, gerbang lupa (*forget gate*) dan gerbang *output* yang digunakan untuk mengatasi *vanishing gradien* pada RNN (Azzouni & Pujolle, 2017). Kelebihan dari unit LSTM memiliki unit untuk menyimpan informasi selama periode waktu yang lebih lama. Juga digunakan

metode kombinasi beberapa metode statistika yaitu *time series regression* dengan *AR error* dan *time series regression* dengan *ARMA error*. Selain itu juga dilakukan peramalan dengan melakukan hibrida antara *time series regression* dengan FFNN dan hibrida antara *time series regression* dengan LSTM yang diharapkan dapat memperbaiki hasil peramalan. Model hibrida didapatkan dengan menggabungkan beberapa model sehingga dapat meningkatkan akurasi (Cheng, Zhang, Liu, Chen & Wang, 2019). Dari beberapa metode yang digunakan dipilih model terbaik untuk meramalkan masing-masing parameter kualitas udara ISPU pada tiga stasiun SUF. Sehingga bisa digunakan untuk memberikan informasi mengenai nilai masing-masing parameter kualitas udara ISPU dan memberikan informasi mengenai kategori kualitas udara ISPU pada beberapa waktu yang akan datang di Kota Surabaya. Hal ini bermanfaat untuk peringatan dini kualitas udara di Kota Surabaya.

1.2. Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, dalam penelitian ini akan dilakukan peramalan parameter kualitas udara ISPU yaitu PM_{10} , CO, SO₂, NO₂ dan O₃ pada tiga stasiun SUF di Kota Surabaya secara univariat. Secara khusus rumusan masalah dalam penelitian ini adalah sebagai berikut:

1. Bagaimana karakteristik lima parameter kualitas udara ISPU di tiga stasiun SUF Kota Surabaya?
2. Bagaimana model peramalan lima parameter kualitas udara ISPU di tiga stasiun SUF Kota Surabaya menggunakan *time series regression*, ARIMA, FFNN, LSTM, *time series regression* dengan *AR error*, *time series regression* dengan *ARMA error*, hibrida *time series regression* dan FFNN serta hibrida *time series regression* dan LSTM?
3. Bagaimana model peramalan terbaik pada lima parameter kualitas udara ISPU di tiga stasiun SUF Kota Surabaya?
4. Bagaimana hasil peramalan lima parameter kualitas udara ISPU di tiga stasiun SUF Kota Surabaya?

5. Bagaimana nilai ISPU di Kota Surabaya berdasarkan hasil peramalan?

1.3. Tujuan

Berdasarkan rumusan masalah yang ada, tujuan dalam penelitian ini adalah sebagai berikut:

1. Mendeskripsikan karakteristik dari masing-masing parameter kualitas udara ISPU di tiga stasiun SUF Kota Surabaya.
2. Mendapatkan model peramalan pada lima parameter kualitas udara ISPU di tiga stasiun SUF Kota Surabaya menggunakan *time series regression*, ARIMA, FFNN, LSTM, *time series regression* dengan AR error, *time series regression* dengan ARMA error, hibrida *time series regression* dan FFNN serta hibrida *time series regression* dan LSTM.
3. Membandingkan dan menentukan model terbaik untuk meramalkan lima parameter kualitas udara ISPU di tiga stasiun SUF Kota Surabaya.
4. Mendapatkan hasil peramalan lima parameter kualitas udara ISPU di tiga stasiun SUF Kota Surabaya.
5. Mendapatkan nilai ISPU dari lima parameter kualitas udara di tiga stasiun SUF Kota Surabaya berdasarkan hasil peramalan dan menentukan kategori kualitas udara di Kota Surabaya.

1.4. Manfaat Penelitian

Manfaat yang diharapkan dari penelitian ini adalah sebagai berikut:

1. Bagi Pemerintah Kota Surabaya khususnya Dinas Lingkungan Hidup sebagai bahan pertimbangan dalam menanggulangi masalah pencemaran udara. Selain itu juga bisa digunakan untuk memberikan informasi kepada masyarakat mengenai kualitas udara di Kota Surabaya beberapa waktu kedepan.

2. Memberikan informasi tambahan mengenai ilmu statistika yaitu *time series regression*, ARIMA, FFNN, LSTM, *time series regression* dengan *AR error*, *time series regression* dengan *ARMA error*, hibrida *time series regression* dan FFNN serta hibrida *time series regression* dan LSTM.

1.5. Batasan Masalah

Menurut Dinas Lingkungan Kota Surabaya dari 7 stasiun SUF hanya terdapat 3 stasiun SUF yang masih aktif. Sehingga dalam penelitian ini data yang digunakan hanya berasal dari 3 stasiun SUF yang masih aktif di Kota Surabaya. Selain itu hasil ramalan parameter kualitas udara yang bernilai negatif digantikan dengan nilai nol, karena parameter kualitas udara tidak mungkin bernilai negatif. Pada model *neural network* hanya digunakan satu *hidden layer* dan dicobakan satu hingga lima *neuron*.

(Halaman ini sengaja dikosongkan)

BAB II TINJAUAN PUSTAKA

2.1. *Time Series Regression*

Time series regression merupakan salah satu model *time series*. Model dari *time series regression* sama dengan model regresi linier secara umum yaitu terdapat variabel prediktor yang mempengaruhi variabel respon (Shumway & Stoffer, 2006). Berikut merupakan *time series regression* dari data yang terdapat unsur tren:

$$Y_t = \beta_0 + \beta_1 t + a_t, \quad (2.1)$$

dengan a_t merupakan *error* yang memenuhi asumsi identik, independen dan berdistribusi normal. Jika terdapat unsur musiman maka model *time series regression* yang terbentuk juga akan berubah. Terdapat dua jenis model *time series regression* yaitu aditif dan multiplikatif. Berikut merupakan model *time series regression* multiplikatif dengan 2 unsur musiman yaitu harian per setengah jam dan mingguan per hari serta terdapat unsur tren:

$$Y_t = \eta t + \beta_1 H_{1t} M_{1t} + \dots + \beta_{336} H_{48t} M_{7t} + a_t, \quad (2.2)$$

dengan H_{it} , merupakan variabel *dummy* dari setengah jam ke i pada suatu hari dengan $i=1,2,\dots,48$, sedangkan M_{mt} merupakan variabel *dummy* dari hari ke m dalam 1 minggu dengan $m=1,2,\dots,7$. Residual yang terbentuk harus memenuhi asumsi *white noise*. Jika asumsi belum terpenuhi maka residual akan dimodelkan kembali. Dalam peramalan termasuk *time series regression* sedikit berbeda dengan regresi linier umumnya. Signifikansi parameter dalam peramalan termasuk *time series regression* tidak terlalu diperhatikan yang lebih diperhatikan adalah akurasi peramalan (Kostenko & Hyndman, 2008).

2.2. *Autoregressive Integrated Moving Average (ARIMA)*

Data *time series* ada yang stasioner dan ada yang tidak stasioner dalam *mean* dan *varians*. Untuk melakukan analisis dengan menggunakan ARIMA data harus stasioner dalam *mean*

dan *varians*. ARIMA (p,d,q) adalah model ARMA (p,q) yang mengalami *differencing* sebanyak d agar stasioner. Model ARIMA dapat digunakan untuk data yang berpola musiman maupun yang tidak berpola musiman. Secara umum, ARIMA (p,d,q) dapat ditulis sebagai berikut (Wei, 2006):

$$\phi_p(B)(1-B)^d Y_t = \theta_0 + \theta_q(B)a_t, \quad (2.3)$$

dengan

(p,d,q) = order AR p , order *differencing* d , order MA q untuk pola non musiman

$\phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$, p merupakan orde untuk AR

$\theta_q(B) = (1 - \theta_1 B - \dots - \theta_q B^q)$, q merupakan orde untuk MA

$(1 - B)^d$ = operator *differencing* untuk orde d .

Sedangkan model untuk ARIMA dengan pola musiman adalah sebagai berikut:

$$\Phi_p(B^S)(1-B^S)^D Y_t = \Theta_Q(B^S)a_t, \quad (2.4)$$

dengan

(P, D, Q) = order AR P , order *differencing* D , order MA Q untuk pola musiman

S = periode musiman

$\Phi_p(B^S) = (1 - \phi_1 B^S - \dots - \phi_p B^{pS})$, P merupakan orde untuk AR

$\Theta_Q(B^S) = (1 - \theta_1 B^S - \dots - \theta_Q B^{QS})$, Q merupakan orde untuk MA

$(1 - B^S)^D$ = operator *differencing* untuk orde D untuk pola musiman.

Jika dalam model ARIMA terdapat pola musiman dan pola non musiman maka model ARIMA yang terbentuk merupakan model multiplikatif ARIMA $(p,d,q) (P,D,Q)^S$. Berikut merupakan model umumnya:

$$\phi_p(B)(1-B)^d \Phi_P(B^S)(1-B^S)^D Y_t = \theta_q(B)\Theta_Q(B^S)a_t. \quad (2.5)$$

Pemodelan ARIMA dilakukan melalui beberapa tahapan. Berikut adalah tahap-tahap yang dilakukan dalam pemodelan ARIMA (Wei, 2006).

(i). Tahap Identifikasi

Tahap identifikasi ini dilakukan untuk melihat stasioneritas dari data yang digunakan. Dalam melakukan analisis dengan menggunakan ARIMA data harus stasioner dalam *mean* dan *varians*. Stasioner dalam *mean* pada data *time series* bisa menggunakan *time series plot*, plot ACF, plot PACF dan pengujian *Augmented Dicky Fuller*. Jika data tidak stasioner dalam *mean* maka dilakukan *differencing* sebanyak d , bisa ditulis sebagai berikut:

$$W_t = (1 - B)^d Y_t. \quad (2.6)$$

Tabel 2.1 Bentuk Transformasi

Nilai Estimasi λ	Transformasi
-1	$\frac{1}{Y_t}$
-0,5	$\frac{1}{\sqrt{Y_t}}$
0	$\ln Y_t$
0,5	$\sqrt{Y_t}$
1	Y_t (tidak ada transformasi)

Sedangkan untuk melihat data stasioner dalam *varians* atau tidak dapat menggunakan pengujian dengan transformasi *Box-Cox*. Untuk melihat data stasioner atau tidak dilihat dari nilai λ . Jika nilai λ tidak sama dengan 1 maka data tidak stasioner sehingga dilakukan transformasi. Bentuk transformasi *Box-Cox* terdapat pada Tabel 2.1.

Selanjutnya dilakukan identifikasi order dari model ARIMA berdasarkan plot ACF dan PACF. Berikut merupakan persamaan dari ACF dan PACF:

$$\hat{\rho}_k = \frac{\sum_{t=1}^{n-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2}, k = 0, 1, 2, \dots, \quad (2.7)$$

dengan $\bar{Y} = \frac{\sum_{t=1}^n Y_t}{n}$ adalah rata-rata dari sampel.

$$\hat{\phi}_{k+1, k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^k \hat{\phi}_{kj} \hat{\rho}_j}, \quad (2.8)$$

dan

$$\hat{\phi}_{k+1, j} = \hat{\phi}_{k, j} - \hat{\phi}_{k+1, k+1} \hat{\phi}_{k, k+1-j}, j = 1, 2, \dots, k. \quad (2.9)$$

Untuk menduga orde p dan q dari model ARIMA dilakukan dengan melihat bentuk dari plot ACF dan PACF. Tabel 2.2 merupakan bentuk-bentuk plot ACF dan PACF dari model ARIMA secara teoritis. Berdasarkan plot ACF dan PACF terdapat beberapa dugaan model ARIMA.

Tabel 2.2 Plot ACF dan PACF Model ARIMA

Model	Plot ACF	Plot PACF
AR (p)	Turun cepat secara eksponensial	Terpotong setelah lag ke- p
MA (q)	Terpotong setelah lag ke- q	Turun cepat secara eksponensial
ARMA (p, q)	Turun cepat	Turun cepat

(ii). Tahap Estimasi dan Pengujian Signifikansi Parameter

Estimasi parameter dilakukan untuk mendapatkan nilai dari setiap parameter model ARIMA. Estimasi dari model ARIMA dapat menggunakan *Conditional Least Square* (CLS). Berikut merupakan metode CLS untuk model AR(1):

$$Y_t - \mu = \phi(Y_{t-1} - \mu) + a_t \quad (2.10)$$

Sehingga didapatkan:

$$a_t = (Y_t - \mu) - \phi(Y_{t-1} - \mu) \quad (2.11)$$

dengan Y_1, Y_2, \dots, Y_n adalah observasi, maka dapat dilakukan penjumlahan sehingga fungsi CLS adalah:

$$S_c(\phi, \mu) = \sum_{t=2}^n [(Y_t - \mu) - \phi(Y_{t-1} - \mu)]^2 \quad (2.12)$$

Estimasi ϕ dan μ dari masing-masing nilai dengan meminimumkan $S_c(\phi, \mu)$ didapatkan:

$$\frac{\partial S_c}{\partial \mu} = \sum_{t=2}^n 2[(Y_t - \mu) - \phi(Y_{t-1} - \mu)](-1 + \phi) = 0 \quad (2.13)$$

Sehingga berdasarkan persamaan (2.13) didapatkan persamaan sebagai berikut:

$$\mu = \frac{1}{(n-1)(1-\phi)} \left[\sum_{t=2}^n Y_t - \phi \sum_{t=2}^n Y_{t-1} \right] \quad (2.14)$$

Tanpa memperhatikan ϕ didapatkan nilai estimasi untuk μ sebagai berikut:

$$\hat{\mu} = \frac{1}{(1-\phi)} [\bar{Y} - \phi \bar{Y}] = \bar{Y} \quad (2.15)$$

Sedangkan solusi untuk mendapatkan ϕ adalah sebagai berikut:

$$\frac{\partial S_c}{\partial \phi} = \sum_{t=2}^n 2[(Y_t - \bar{Y}) - \phi(Y_{t-1} - \bar{Y})](Y_{t-1} - \bar{Y}) = 0 \quad (2.16)$$

Sehingga didapatkan nilai estimasi untuk ϕ sebagai berikut:

$$\hat{\phi} = \frac{\sum_{t=2}^n (Y_t - \bar{Y})(Y_{t-1} - \bar{Y})}{\sum_{t=2}^n (Y_{t-1} - \bar{Y})^2} \quad (2.17)$$

Untuk MA(1) estimasi parameter dengan CLS sebagai berikut:

$$S_c(\theta) = \sum (a_t)^2 = \sum [Y_t + \theta Y_{t-1} + \theta^2 Y_{t-2} + \dots] \quad (2.18)$$

Persamaan (2.18) merupakan persamaan dengan parameter yang tidak linier. Sehingga model MA(q) dibutuhkan algoritma optimasi numerik karena merupakan persamaan tidak linier dalam penyelesaian estimasi parameter (Cryer & Chan, 2008).

Kemudian setelah mendapatkan estimasi parameter dari model ARIMA dilakukan pengujian signifikansi parameter. Pengujian signifikansi parameter dilakukan dengan pengujian t . Misalkan ω merupakan parameter dari AR atau MA maka uji signifikansi parameter model dilakukan dengan hipotesis:

$$H_0: \omega_i = 0$$

$$H_1: \omega_i \neq 0.$$

Statistik uji yang digunakan adalah:

$$t_{hitung} = \frac{\hat{\omega}_i}{SE(\hat{\omega}_i)}, \quad (2.19)$$

H_0 ditolak apabila nilai statistik uji $|t_{hitung}| > t_{\alpha/2, n-(p+q)}$ dengan n merupakan banyaknya pengamatan, p merupakan banyak parameter AR dan q merupakan banyak parameter MA.

(iii). Tahap Uji Diagnostik

Setelah dilakukan identifikasi dan estimasi parameter, selanjutnya akan dilakukan uji diagnostik untuk mengetahui residual dari model *white noise* dan berdistribusi normal atau belum. Residual *white noise* jika tidak terdapat korelasi antar pengamatan. Untuk melakukan pengujian residual *white noise* digunakan uji *Ljung Box*. Berikut merupakan hipotesisnya:

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_K \text{ (residual independen)}$$

$$H_1 : \text{minimal ada satu nilai } \rho_k \neq 0 \text{ dengan } k=1,2,\dots,K \text{ (residual tidak independen).}$$

Statistik uji yang digunakan adalah:

$$Q = n(n+2) \sum_{k=1}^K \frac{\hat{\rho}_k^2}{n-k}, \quad (2.20)$$

H_0 ditolak apabila nilai $Q > \chi_{\alpha, K-p-q}^2$ dengan $\hat{\rho}_k$ merupakan autokorelasi dari residual, nilai p adalah banyaknya parameter AR pada model, q adalah banyaknya parameter MA pada model, n adalah banyaknya pengamatan, dan α adalah taraf signifikansi yang digunakan.

Untuk melakukan pengujian residual berdistribusi normal atau tidak digunakan pengujian *Kolmogorov-Smirnov* (Daniel, 1990). Berikut merupakan hipotesisnya:

H_0 : Residual berdistribusi normal

H_1 : Residual tidak berdistribusi normal.

Statistik uji yang digunakan adalah

$$D = \text{Sup}_{a_i} |S(a_i) - F_0(a_i)|, \quad (2.21)$$

$S(a_i)$ merupakan fungsi kumulatif yang dihitung dari data sampel sedangkan $F_0(a_i)$ merupakan fungsi kumulatif yang dihitung dari distribusi normal dan *Sup* adalah nilai maksimum dari harga mutlak D . H_0 ditolak apabila nilai $D > D_{1-\alpha, n}$ atau $p\text{-value} < \alpha$.

2.3. *Time Series Regression dengan ARIMA Error*

Error pada model *time series regression* yang masih belum *white noise* masih dapat dimodelkan, salah satu cara yang digunakan adalah memodelkan *error/residual* dengan menggunakan ARIMA (Hyndman & Athanasopoulos, 2018). Sehingga hasil prediksi yang didapatkan akan lebih bagus, hal ini dikarenakan *error* yang masih belum *white noise* (terdapat autokorelasi) dimodelkan dengan ARIMA. Berikut merupakan model *time series regression* dengan ARIMA *error* pada model yang terdapat unsur tren dan 2 unsur musiman yaitu harian dan mingguan.

$$Y_t = \eta t + \beta_1 H_{1_t} M_{1_t} + \dots + \beta_{336} H_{48_t} M_{7_t} + \frac{\theta_q(B)}{\phi_p(B)(1-B)^d} \varepsilon_t. \quad (2.22)$$

Model dibentuk dengan menjumlahkan hasil peramalan data awal dengan *time series regression* dan residual dari *time series regression* dengan model ARIMA.

2.4. *Feed Forward Neural Network*

Neural Network (NN) adalah sistem pemroses informasi yang memiliki karakteristik mirip dengan jaringan syaraf biologi yaitu otak manusia terdiri yang dari sejumlah neuron yang melakukan tugas sederhana untuk memproses informasi. NN merupakan salah satu model nonlinier yang mampu digunakan untuk memodelkan dan memprediksi data *time series* (Tealab, 2018). NN dapat memperkirakan hampir semua fungsi linier atau nonlinier dengan cara yang efisien dan stabil, apabila data yang mendasari tidak diketahui. Terdapat banyak model dalam *neural network*. Arsitektur NN yang secara umum paling banyak digunakan dalam aplikasi bidang teknik atau rekayasa adalah *Feedforward Neural Network* (FFNN) atau juga disebut *Multi Layer Perceptron* (Azzouni & Pujolle, 2017). Dalam struktur FFNN terdapat beberapa *layer*, yaitu *input layer*, satu atau lebih *hidden layers* dan *output layer*. Setiap *neuron* akan menerima informasi hanya dari *neuron* pada *layer* sebelumnya dimana *input neuron* berasal dari bobot *output* pada *layer* sebelumnya (Chong & Zak, 2001). Pada FFNN proses akan dimulai ketika *neuron* menerima *input* yang dikelompokkan menjadi *input layer* kemudian informasi diarahkan melewati *hidden layer* kemudian urut hingga mencapai *output layer* (Suhartono, 2007). Saat ini model NN telah banyak digunakan dalam berbagai hal seperti *image classification*, *speech recognition* dan *natural language processing* (Kim, Kim, Huh, Lee & Choi, 2018). Bentuk umum dari (FFNN) adalah sebagai berikut:


$$\hat{Y}_{(t)} = f^o \left[\sum_{j=1}^q \left[w_j^o f_j^h \left(\sum_{i=1}^p w_{ji}^h X_{i(t)} + b_j^h \right) + b_j^o \right] \right], \quad (2.23)$$

dengan:

$$X_{i(t)} = \text{variabel input sebanyak } p, (i = 1, 2, \dots, p)$$

- $\hat{Y}_{(t)}$ = nilai dugaan dari variabel *output*
 t = indeks pasangan data *input-target* $(x_{i(k)}, y_{(k)})$, $k = 1, 2, \dots, n$
 w_{ji}^h = bobot dari *input* ke- i yang menuju *neuron* ke- j pada *hidden layer*, dengan $j = 1, 2, \dots, q$
 b_j^h = bias pada *neuron* ke- j pada *hidden layer*, ($j = 1, 2, \dots, q$)
 f_j^h = fungsi aktivasi di *neuron* ke- j pada *hidden layer*
 w_j^o = bobot dari *neuron* ke- j di *hidden layer* yang menuju *neuron* pada *output layer*
 b^o = bias pada *neuron* di *output layer*
 f^o = fungsi aktivasi pada *neuron* di *output layer*.

Berikut adalah gambar arsitektur dari FFNN dengan 1 *hidden layer* dan p variabel *input*.



Gambar 2.1 Arsitektur FFNN

Fungsi \hat{Y} terjadi bentuk nonlinier melalui suatu fungsi yang disebut fungsi aktivasi f_j^h pada *hidden layer* dan f^o pada *output layer*. Notasi v_j^h digunakan untuk menyatakan suatu vektor nilai-nilai setelah proses penjumlahan *input* dan bobot-bobot (bias termasuk di dalamnya) pada *hidden layer* di *neuron* ke- j , yaitu:

$$v_j^h = \sum_{i=1}^p w_{ji}^h X_i + b_j^h, \quad (2.24)$$

atau untuk data ke t diperoleh:

$$v_{j(t)}^h = \sum_{i=1}^p w_{ji}^h X_{i(t)} + b_j^h. \quad (2.25)$$

Output pada *hidden layer* yang terproses di *neuron* ke- j adalah:

$$a_j^h = f_j^h(v_j^h), \quad (2.26)$$

atau untuk data ke t diperoleh:

$$a_{j(t)}^h = f_j^h \left(\sum_{i=1}^p w_{ji}^h X_{i(t)} + b_j^h \right). \quad (2.27)$$

Dengan cara yang sama, maka beberapa notasi yang menyatakan penjumlahan *input* dan bobot-bobot pada *output layer* adalah:

$$v^o = \sum_{j=1}^q w_j^o a_j^h + b^o, \quad (2.28)$$

atau untuk data ke t diperoleh:

$$v_{(t)}^o = \sum_{j=1}^q w_j^o a_{j(t)}^h + b^o, \quad (2.29)$$

Output pada *output layer* adalah:

$$\hat{Y}_{(t)} = a_{(t)}^o = f^o(v_{(t)}^o), \quad (2.30)$$

dengan demikian, hubungan antara *input* $X_{i(t)}$, $i = 1, 2, \dots, p$ dan $t = 1, 2, \dots, n$, dengan *output* $\hat{Y}_{(t)}$ adalah:

$$\begin{aligned}
\hat{Y}_{(t)} &= f^o \left(\sum_{j=1}^q w_j^o f_j^h (v_{j(t)}^h) + b^o \right) \\
&= f^o \left[\sum_{j=1}^q \left[w_j^o f_j^h \left(\sum_{i=1}^p w_{ji}^h X_{i(t)} + b_j^h \right) + b^o \right] \right] \quad (2.32) \\
&= F(X_{1(t)}, X_{2(t)}, \dots, X_{p(t)}).
\end{aligned}$$

Pemetaan secara keseluruhan yang terjadi pada FFNN ini selanjutnya dapat ditulis dalam bentuk:

$$\begin{bmatrix} \hat{Y}_{(1)} \\ \hat{Y}_{(2)} \\ \vdots \\ \hat{Y}_{(n)} \end{bmatrix} = \begin{bmatrix} F(X_{1(1)}, X_{2(1)}, \dots, X_{p(1)}) \\ F(X_{1(2)}, X_{2(2)}, \dots, X_{p(2)}) \\ \vdots \\ F(X_{1(n)}, X_{2(n)}, \dots, X_{p(n)}) \end{bmatrix}. \quad (2.33)$$

FFNN menggunakan penurunan algoritma *backpropagation* yang banyak digunakan untuk analisis *time series* dan regresi yaitu dengan melakukan *fitting* terhadap parameter-parameter fungsi dengan metode *least squares*. Misalkan beberapa pasang sampel *input* dan target $(X_{(t)}, Y_{(t)})$, dan *output* dari *networks* adalah $\hat{Y} = f(X, \mathbf{w})$. Maka, vektor parameter \mathbf{w} dipilih dengan cara meminimumkan:

$$Q(\mathbf{w}) = \frac{1}{2} \sum_{t=1}^n [Y_{(t)} - f(X_{(t)}; \mathbf{w})]^2, \quad (2.34)$$

seperti yang dilakukan dalam regresi nonlinier.

Update bobot pada metode FFNN menggunakan metode *gradient descent*, berikut merupakan *updating* bobot dan bias pada *output layer*:

$$w_j^{o(m+1)} = w_j^{o(m)} + \eta \sum_{t=1}^n \delta_{(t)}^{o(m)} a_{j(t)}^{h(m)}, \quad (2.35)$$

$$b^o(m+1) = b^o(m) + \eta \sum_{t=1}^n \delta_{(t)}^{o(m)}. \quad (2.36)$$

Berikut merupakan *updating* bobot dan bias pada *hidden layer*:

$$w_{ji}^{h(m+1)} = w_{ji}^{h(m)} + \eta \sum_{t=1}^n \delta_{j(t)}^{h(m)} X_{i(t)}, \quad (2.37)$$


$$b_j^{h(m+1)} = b_j^{h(m)} + \eta \sum_{t=1}^n \delta_{j(t)}^{h(m)}. \quad (2.38)$$

2.5. Long Short Term Memory

Long short term memory (LSTM) merupakan salah satu metode dalam *neural network* yang pertama kali ditemukan oleh Sepp Hochreiter dan Jurgen Schmiduber pada tahun 1997. *Long short term memory* merupakan pengembangan dari metode *recurrent neural network* (RNN), hal ini dikarenakan terdapat banyak kelemahan pada metode RNN yaitu kelambatan jangka panjang tidak dapat diakses dalam sebuah arsitektur (Hochreiter & Schmiduber, 1997). Selain itu LSTM dapat mengatasi masalah *vanishing gradient* pada RNN (Azzouni & Pujolle, 2017). Akibat adanya *vanishing gradient* ini mengakibatkan informasi yang terdapat pada interval waktu sebelumnya akan semakin berkurang/dilupakan karena bobot yang semakin kecil pada informasi tersebut sehingga mengakibatkan informasi di interval waktu sebelumnya akan hilang. LSTM ini biasa disebut *cell state*, pada LSTM ini memungkinkan untuk menyimpan informasi dari interval waktu sebelumnya di LSTM *cell*. Perbedaan antara LSTM dan RNN adalah pada RNN *input* hanya berasal dari *hidden state* sebelumnya dan *input* saja, sehingga tidak terdapat informasi sebelumnya yang diingat untuk dijadikan *input*.


Struktur dari LSTM terdiri dari beberapa *layer* yaitu *input layer*, *recurrent hidden layer* dan *output layer* (Ma, Tao, Wang, Yu

& Wang, 2015). Perbedaan dengan NN biasa adalah *hidden layer* yang digunakan merupakan *memory block*. *Hidden layer* dari jaringan LSTM ini mengandung *memory cell* dan sepasang unit *gating* adaptif, multiplikatif yang mengarahkan *input* dan *output* ke semua sel di blok. Sebuah sel LSTM terdiri dari empat gerbang (*gate*) yaitu gerbang *input*, gerbang modulasi *input*, gerbang lupa (*forget gate*) dan gerbang *output* (Hochreiter & Schmidhuber, 1997). Gerbang *input* (*input gate*) mengambil titik *input* baru dari luar dan *input* dari *output* sel LSTM pada iterasi terakhir (*hidden state* sebelumnya). Gerbang lupa (*forget gate*) memutuskan kapan untuk melupakan hasil *output* dan dengan demikian memilih jeda waktu optimal untuk urutan *input*. Gerbang *output* mengambil semua hasil yang dihitung dan menghasilkan *output* dari LSTM. LSTM mendesain ulang *node* komputasi berdasarkan struktur jaringan RNN dengan menambahkan *forget gate*. Struktur LSTM dengan 1 *hidden layer* dan 1 *neuron* ditampilkan pada gambar berikut.



Gambar 2.2 Arsitektur LSTM

Sedangkan berikut ini merupakan struktur *memory block* dari LSTM yang terdiri dari empat gerbang (*gate*) yaitu gerbang *input*, gerbang modulasi *input*, gerbang lupa (*forget gate*) dan gerbang *output*.



Gambar 2.3 Struktur *Memory Block* LSTM

Berdasarkan Gambar 2.3 diketahui bahwa pada *forget gate* terdapat fungsi aktivasi *sigmoid*. Adanya fungsi *sigmoid* ini akan menghasilkan nilai antara 0 hingga 1. Nilai 0 menunjukkan bahwa tidak memberikan akses untuk melewati komponen, sedangkan nilai 1 menunjukkan bahwa memberikan akses untuk melewati komponen. Nilai 0 ini mengakibatkan informasi pada *hidden state* sebelumnya akan dilupakan (Li & Cao, 2018). Berikut merupakan persamaan pada *forget gate*:

$$F_t = \sigma(W_{fh}h_{t-1} + W_{fx}X_t + b_f), \quad (2.39)$$

dengan F_t merupakan *forget gate*, σ merupakan fungsi aktivasi *sigmoid*, W_{fh} merupakan bobot dari *hidden state* sebelumnya pada *forget gate*, h_{t-1} merupakan *hidden state* sebelumnya, W_{fx} merupakan bobot dari *input* pada *forget gate*, X_t merupakan *input* pada waktu ke t dan b_f merupakan bias dari *forget gate*.

Selanjutnya pada *input gate* terdapat fungsi aktivasi *tanh*, fungsi aktivasi *tanh* ini digunakan untuk membentuk kandidat vektor *cell state* yang akan digunakan untuk memperbarui *cell state* sebelumnya. Selain itu juga terdapat fungsi aktivasi *sigmoid* yang digunakan untuk memperbarui *filter* pada *input*. Berikut merupakan persamaan yang terbentuk pada *input gate* hingga mendapatkan *cell state* yang telah mendapatkan informasi terbaru:

$$\hat{C}_t = \tanh(W_{ch}h_{t-1} + W_{cx}X_t + b_c), \quad (2.40)$$

$$U_t = \sigma(W_{uh}h_{t-1} + W_{ux}X_t + b_u), \quad (2.41)$$

$$C_t = F_t C_{t-1} + U_t \hat{C}_t, \quad (2.42)$$

dengan \hat{C}_t merupakan kandidat dari *cell state*, \tanh merupakan fungsi aktivasi \tanh , W_{ch} merupakan bobot dari *hidden state* sebelumnya pada kandidat *cell state*, W_{cx} merupakan bobot dari *input* pada kandidat *cell state*, b_c merupakan bias dari kandidat *cell state*, W_{uh} merupakan bobot dari *hidden state* sebelumnya pada *filter input*, W_{ux} merupakan bobot dari *input* pada *filter input*, b_u merupakan bias dari *filter input*, C_{t-1} merupakan *cell state* pada *hidden state* sebelumnya, U_t merupakan *filter* pada *input* dan C_t merupakan *cell state* pada waktu ke t .

Pada *output gate* terdapat fungsi aktivasi *sigmoid* yang digunakan untuk memfilter *cell state* yang menuju *output*. *Cell state* akan melewati fungsi aktivasi \tanh untuk mengubah nilainya agar berada diantara -1 hingga 1. Selanjutnya *cell state* ini akan dikalikan dengan *filter* O_t sehingga akan didapatkan *hidden state* yang selanjutnya akan digunakan sebagai *input* pada *cell state* selanjutnya. Berikut merupakan persamaannya:

$$O_t = \sigma(W_{oh}h_{t-1} + W_{ox}X_t + b_o), \quad (2.43)$$

$$h_t = O_t \tanh(C_t), \quad (2.44)$$

dengan O_t merupakan *filter* pada *output*, W_{oh} merupakan bobot dari *hidden state* sebelumnya pada *filter output*, W_{ox} merupakan bobot dari *input* pada *filter output*, h_t merupakan *hidden state* pada waktu ke t dan b_f merupakan bias dari *filter output*. Setelah itu akan didapatkan nilai *output* dari LSTM dengan persamaan sebagai berikut:

$$\hat{Y}_t = W_y h_t + b_y, \quad (2.45)$$

dengan \hat{Y}_t merupakan nilai dugaan dari variabel *output*, W_y merupakan bobot dari *hidden layer* dan b_y merupakan bias dari *output*.

2.6. Model Hibrida (*Hybrid*)

Hibrida adalah kombinasi dua atau lebih sistem dalam satu fungsi, dalam hal ini adalah kombinasi antara model *time series regression* dan model *neural network*. Model statistika dapat menghasilkan peramalan yang baik pada kondisi yang linier, tetapi akan buruk jika bertemu dengan kondisi yang nonlinier untuk itu dilakukan kombinasi dengan *neural network* yang menunjukkan performa yang baik jika data bersifat nonlinier. Jadi model hibrida dapat membantu mengatasi struktur yang kompleks dari suatu data (Zheng & Zhong, 2011). Secara umum kombinasi dari model *time series* dapat dituliskan sebagai berikut:

$$Y_t = L_t + N_t + \varepsilon_t, \quad (2.46)$$

dengan L_t menunjukkan komponen linier yang diwakili oleh *time series regression* dan N_t menunjukkan komponen nonlinier yang diwakili oleh metode *neural network* di mana residual dari model yang linier masih mengandung informasi hubungan nonlinier. Secara matematis untuk level 1 dapat dituliskan sebagai berikut:

$$a_t = Y_t - \hat{L}_t, \quad (2.47)$$

\hat{L}_t merupakan nilai peramalan dari model linier pada waktu ke- t . Selanjutnya untuk level 2 dilakukan pemodelan a_t dengan *neural network*. Residual model linier sebagai berikut:

$$\begin{aligned} a_t &= f(a_{t-1}, a_{t-2}, \dots, a_{t-k}) + \varepsilon_t \\ &= \hat{N}_t + \varepsilon_t, \end{aligned} \quad (2.48)$$

dengan f merupakan fungsi nonlinier yang didapatkan dari *neural network* dan N_t dan merupakan hasil peramalan dari *neural network* pada waktu ke- t . Sehingga didapatkan model hibrida sebagai berikut (Zhang, 2003):

$$\hat{Y}_t = \hat{L}_t + \hat{N}_t. \quad (2.49)$$

2.7. Uji Linieritas

White test digunakan untuk menguji apakah terdapat hubungan nonlinier antara suatu deret waktu dengan lag-lagnya.

Pengujian ini dikembangkan dari model *neural network* yang ditemukan White pada 1989. *White test* menguji hubungan nonlinier antara *input* dan *output* dengan 1 *hidden layer* (Lee, White & Granger, 1993). Persamaan (2.50) merupakan komponen linier dan persamaan (2.51) merupakan komponen nonlinier yang digunakan.

$$Y_t = \delta_0 + \delta_1 Y_{t-1} + \dots + \delta_p Y_{t-p} + a_t \quad (2.50)$$

$$Y_t = \delta_0 + \delta_1 Y_{t-1} + \dots + \delta_p Y_{t-p} + \lambda_1 f(Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}) \\ + \lambda_2 f(Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}) + a_t \quad (2.51)$$

Hipotesis yang digunakan dalam *White Test* ini adalah sebagai berikut:

H_0 : $\lambda_1 = \lambda_2 = 0$ (Tidak ada hubungan nonlinier),

H_1 : minimal ada satu $\lambda_i \neq 0$, dengan $i=1, 2$ (Terdapat hubungan nonlinier).

Statistik uji yang digunakan adalah F yang melalui perhitungan sebagai berikut.

1. Meregresikan Y_t dengan Y_{t-1}, \dots, Y_{t-p} kemudian menghitung nilai-nilai residual dan menghitung jumlah kuadrat residual yang disebut SSR_0 .
2. Meregresikan residual pada langkah 1 dengan semua variabel prediktor pada langkah 1 dan juga 2 prediktor tambahan, dan menghitung residual sehingga diperoleh jumlah kuadrat residualnya yang disebut SSR_1 .
3. Menghitung statistik uji F , yaitu:

$$F_{\text{hitung}} = \frac{(SSR_0 - SSR_1) / 2}{SSR_1 / (n - p - 1 - 2)}, \quad (2.52)$$

dengan n merupakan banyaknya pengamatan yang digunakan, 2 merupakan jumlah prediktor tambahan dan p merupakan jumlah prediktor awal. Statistik uji yang digunakan mengikuti distribusi F dengan derajat bebas $v_1 = 2$ dan $v_2 = (n - p - 1 - 2)$.

2.8. Kriteria Kebaikan Model

Pemilihan model terbaik dilakukan jika terdapat lebih dari satu model yang dapat digunakan. Dalam pendekatan *out of sample* pemilihan model terbaik dilakukan berdasarkan *error* dari hasil ramalan. Kriteria yang digunakan adalah *Root Mean Square Error Prediction* (RMSEP) dan *symmetric Mean Absolute Percentage Error Prediction* (sMAPEP). RMSE (Wei, 2006) dan sMAPE (Makridakis, Spiliotis & Assimakopoulus, 2018) dapat dihitung dengan rumus sebagai berikut:

$$RMSEP = \sqrt{\frac{1}{L} \sum_{l=1}^L (Y_{n+l} - \hat{Y}_n(l))^2}, \quad (2.53)$$

$$sMAPEP = \left(\frac{1}{L} \sum_{l=1}^L \frac{2|Y_{n+l} - \hat{Y}_n(l)|}{(|Y_{n+l}| + |\hat{Y}_n(l)|)} \right) \times 100\%, \quad (2.54)$$

dengan,

Y_{n+l} : data *out of sample* yang ke- l ($l=1,2,\dots,L$)

$\hat{Y}_n(l)$: ramalan untuk data *out of sample* yang ke- l

L : panjang data *out of sample*.

2.9. Pencemaran Udara

Pencemaran udara umumnya diartikan sebagai bertambahnya bahan atau substrat fisik/kimia ke dalam lingkungan udara normal yang mencapai jumlah tertentu, sehingga dapat dideteksi oleh manusia (atau yang dapat dihitung dan diukur) serta dapat memberikan efek pada manusia, binatang, vegetasi, dan material (Mukono, 1997). Sehingga pencemaran udara secara langsung maupun tidak langsung berdampak pada kehidupan manusia. Pencemaran udara dapat terjadi dimana-mana, seperti di dalam rumah, sekolah, dan kantor.

Informasi yang dipakai untuk mengindikasikan kondisi kualitas udara ambien salah satunya adalah ISPU. Berdasarkan Keputusan Menteri Negara Lingkungan Hidup No 45 tentang Indeks Standar Pencemar Udara, parameter yang dipakai untuk menghitung ISPU adalah PM_{10} , CO, SO_2 , NO_2 dan O_3 . ISPU

disampaikan kepada masyarakat setiap 24 jam dari rata-rata data sebelumnya (24 jam sebelumnya). Dari masing-masing parameter ISPU akan dihitung angka dan kategori dari ISPU. Berikut nilainya.

Tabel 2.3 Angka dan Kategori ISPU

Indeks	Kategori
1-50	Baik
51-100	Sedang
101-199	Tidak Sehat
200-299	Sangat Tidak Sehat
300-Lebih	Berbahaya

Untuk mendapatkan angka dan kategori dari ISPU digunakan rumus sebagai berikut, dengan memilih parameter yang memiliki nilai ISPU tertinggi dibandingkan parameter ISPU lain pada setiap stasiun SUF:

$$I = \frac{I_a - I_b}{X_a - X_b}(X_x - X_b) + I_b, \quad (2.55)$$

dengan


- I : ISPU terhitung
- I_a : ISPU batas atas
- I_b : ISPU batas bawah
- X_a : Ambien batas atas
- X_b : Ambien batas bawah
- X_x : Ambien hasil pengukuran.

Untuk mendapatkan nilai ISPU batas atas, ISPU batas bawah, ambien batas atas dan ambien batas bawah digunakan Tabel 2.4. Dalam penentuan nilai ISPU batas atas dan ISPU batas bawah didasarkan pada nilai ambien batas atas dan ambien batas bawah. Untuk menghitung nilai ambien batas atas dan batas bawah yaitu berdasarkan nilai ambien hasil pengukuran. Ditentukan nilai ambien hasil pengukuran tersebut berada di antara baris berapa dalam Tabel 2.4, hal tersebut yang digunakan sebagai ambien batas atas dan ambien batas bawah.

Tabel 2.4 Batas ISPU

Indeks Standar Pencemar Udara	24 Jam PM ₁₀ µg/m ³	24 Jam SO ₂ µg/m ³	8 Jam CO µg/m ³	1 Jam O ₃ µg/m ³	1 Jam NO ₂ µg/m ³
50	50	80	5	120	
100	150	365	10	235	
200	350	800	17	400	1130
300	420	1600	34	800	2260
400	500	2100	46	1000	3000
500	600	2620	57.5	1200	3750

Pemantauan kualitas udara di Kota Surabaya telah dilakukan oleh Dinas Lingkungan Hidup Kota Surabaya salah satunya dengan AQMS. AQMS adalah sistem terintegrasi yang memonitor kualitas udara ambien pada berbagai wilayah secara rutin dalam 24 jam oleh stasiun SUF yang kemudian ditampilkan pada *public data display* (DLH, 2017). Jaringan AQMS dipasang pada setiap stasiun SUF yang ada di Kota Surabaya. Setiap setengah jam, stasiun SUF mengambil sampel udara secara otomatis. Selanjutnya, sampel udara tersebut diproses pada jaringan AQMS yang dapat mengukur konsentrasi dari setiap parameter kualitas udara. Konsentrasi yang diapat dicatat dengan sistem yang terintegrasi dengan stasiun kerja yang ada di Dinas Lingkungan Hidup Kota Surabaya. Di Kota Surabaya terdapat 7 stasiun SUF yang dipasang di berbagai wilayah, namun hanya terdapat 3 stasiun SUF yang aktif hingga saat ini, yaitu stasiun SUF 1, SUF 6, dan SUF 7 dengan lokasi yang disajikan pada Gambar 2.6. Stasiun SUF 1 berada di Taman Prestasi Ketabang, SUF 6 berada di Taman Bibit Wonorejo dan SUF 7 berada di Kebonsari.



Gambar 2.4 Peta Stasiun SUF Aktif Kota Surabaya

Stasiun pengamatan kualitas udara SUF 1 terletak di Taman Prestasi, Ketabang yang merupakan wilayah Surabaya Pusat. Lokasi SUF 1 merupakan taman yang hijau dan berada di tepi sungai. Taman tersebut dilalui oleh jalan raya alternatif, bukan jalan raya utama, sehingga jarang dilewati oleh kendaraan bermotor. Di sekitar stasiun SUF 1 terdapat beberapa gedung besar dan perkantoran seperti Balai Kota, Grahadi, Plaza Surabaya dan Grand City. Kondisi ini mengakibatkan wilayah di sekitar SUF 1 menjadi cukup ramai. Stasiun pengamatan kualitas udara SUF 6 terletak di Wonorejo Rungkut yang merupakan wilayah Surabaya Timur. Wonorejo cenderung tidak dilalui oleh jalan raya yang besar, sehingga jumlah kendaraan yang melalui wilayah tersebut juga cenderung sedikit. Selain itu, Wonorejo juga merupakan wilayah yang masih hijau dan terdapat beberapa wilayah yang masih berupa tanah kosong. Di Wonorejo juga terdapat kebun bibit dan hutan mangrove. Stasiun pengamatan kualitas udara SUF 7 terletak di Kebonsari, Jambangan yang merupakan wilayah Surabaya Selatan. Kebonsari merupakan wilayah yang padat pemukiman dan perkantoran/perusahaan. Hal ini ditunjukkan

dengan adanya beberapa perumahan dan sejumlah perusahaan yang berada di sekitar Kebonsari. Selain itu disekitar SUF 7 terdapat jalan tol Surabaya-Porong dan Masjid Al-Akbar. Hal ini mengakibatkan wilayah disekitar SUF 7 menjadi cukup ramai



Gambar 2.5 Stasiun SUF 1 (a), SUF 6 (b) dan SUF 7 (c) Kota Surabaya

BAB III METODOLOGI PENELITIAN

3.1. Sumber Data

Data yang digunakan dalam penelitian adalah data sekunder yang merupakan data hasil pemantauan kualitas udara di tiga stasiun SUF di Kota Surabaya per setengah jam. Periode data yang digunakan adalah data 1 Januari 2018 hingga 20 Desember 2018. Data 1 Januari 2018 pukul 00.30 hingga 20 Desember 2018 pukul 19.00 menjadi data *in-sample* dan data 20 Desember 2018 pukul 19.30 hingga pukul 00.00 menjadi data *out-of-sample*.

3.2. Variabel Penelitian

Variabel penelitian yang digunakan dalam penelitian ini adalah lima parameter kualitas udara ISPU yaitu PM_{10} , CO, SO₂, NO₂ dan O₃ pada tiga stasiun SUF di Kota Surabaya dengan struktur data pada Tabel 3.1. Variabel yang digunakan dalam penelitian ini disimbolkan $Y_{i,t}^j$ dengan:

- i : indeks dari jenis parameter kualitas udara ISPU dengan $i = 1, 2, 3, 4, 5$. Dalam hal ini 1 merupakan kadar CO, 2 merupakan kadar NO₂, 3 merupakan kadar O₃, 4 merupakan kadar PM_{10} dan 5 merupakan kadar SO₂,
- j : indeks dari jenis stasiun SUF dengan $j = 1, 2, 3$. Dalam hal ini 1 merupakan stasiun SUF 1, 2 merupakan stasiun SUF 6 dan 3 merupakan stasiun SUF 7,
- t : indeks dari urutan waktu kejadian dengan $t = 1, 2, \dots, 16992$.

3.3. Langkah Analisis

Langkah-langkah yang dilakukan dalam penelitian ini adalah sebagai berikut.

1. Mendeskripsikan karakteristik data masing-masing parameter kualitas udara di tiga stasiun SUF di Kota Surabaya.

Tabel 3.1 Struktur Data Kualitas Udara

t	Tahun	Jam	Hari	Bulan	$Y_{1,t}^1$...	$Y_{5,t}^1$...	$Y_{1,t}^3$...	$Y_{5,t}^3$
1	2018	00:30	Senin	Januari	$Y_{1,1}^1$...	$Y_{5,1}^1$...	$Y_{1,1}^3$...	$Y_{5,1}^3$
2	2018	01:00	Senin	Januari	$Y_{1,2}^1$...	$Y_{5,2}^1$...	$Y_{1,2}^3$...	$Y_{5,2}^3$
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
47	2018	23:30	Senin	Januari	$Y_{1,47}^1$...	$Y_{5,47}^1$...	$Y_{1,47}^3$...	$Y_{5,47}^3$
48	2018	24:00	Senin	Januari	$Y_{1,48}^1$...	$Y_{5,48}^1$...	$Y_{1,48}^3$...	$Y_{5,48}^3$
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
16991	2018	23:30	Kamis	Desember	$Y_{1,16991}^1$...	$Y_{5,16991}^1$...	$Y_{1,16991}^3$...	$Y_{5,16991}^3$
16992	2018	24:00	Kamis	Desember	$Y_{1,16992}^1$...	$Y_{5,16992}^1$...	$Y_{1,16992}^3$...	$Y_{5,16992}^3$

2. Melakukan *preprocessing* data dengan melakukan imputasi pada data yang hilang.
3. Melakukan pemodelan dan peramalan pada lima parameter kualitas udara di tiga stasiun SUF di Kota Surabaya.
 - a. Melakukan peramalan menggunakan metode *time series regression* dengan langkah-langkah sebagai berikut.
 1. Menentukan variabel *input* yang digunakan yaitu unsur tren dan musiman.
 2. Melakukan pemodelan lima parameter kualitas udara di tiga stasiun SUF di Kota Surabaya menggunakan *time series regression*.
 3. Melakukan peramalan lima parameter kualitas udara di tiga stasiun SUF di Kota Surabaya menggunakan *time series regression*.
 - b. Melakukan peramalan menggunakan metode ARIMA dengan langkah-langkah sebagai berikut.
 1. Melakukan identifikasi untuk melihat data sudah stasioner dalam *mean* dan *varians* atau belum.
 2. Melakukan identifikasi order AR dan MA berdasarkan plot ACF dan PACF.
 3. Melakukan estimasi parameter pada ARIMA.
 4. Melakukan pemeriksaan diagnostik pada residual. Residual memenuhi asumsi *white noise* dan distribusi normal atau belum.
 5. Pemilihan model terbaik ARIMA.
 6. Melakukan peramalan lima parameter kualitas udara di tiga stasiun SUF di Kota Surabaya menggunakan ARIMA.
 - c. Melakukan peramalan menggunakan metode *Feed Forward Neural Network* (FFNN) dengan langkah-langkah sebagai berikut.
 1. Menentukan variabel *input* yang digunakan yaitu lag AR yang signifikan pada model ARIMA.
 2. Melakukan *preprocessing* dengan normalisasi data dengan persamaan :

$$Y_t^* = \frac{Y_t - \min(Y_t)}{\max(Y_t) - \min(Y_t)}.$$

3. Melakukan pengujian linieritas data dengan uji *White*.
 4. Menentukan jumlah *neuron* pada *hidden layer*. Jumlah *neuron* yang digunakan adalah 1 hingga 5.
 5. Melakukan estimasi parameter pada FFNN.
 6. Pemilihan model terbaik FFNN.
 7. Melakukan peramalan lima parameter kualitas udara di tiga stasiun SUF di Kota Surabaya menggunakan FFNN.
 8. Melakukan *postprocessing* data hasil ramalan.
- d. Melakukan peramalan menggunakan metode *Long Short Term Memory* (LSTM) dengan langkah-langkah sebagai berikut.
1. Menentukan jumlah *time steps* yang akan digunakan sebagai variabel *input*. Variabel *input* yang digunakan yaitu lag AR yang signifikan pada model ARIMA.
 2. Melakukan *preprocessing* dengan normalisasi data dengan persamaan :

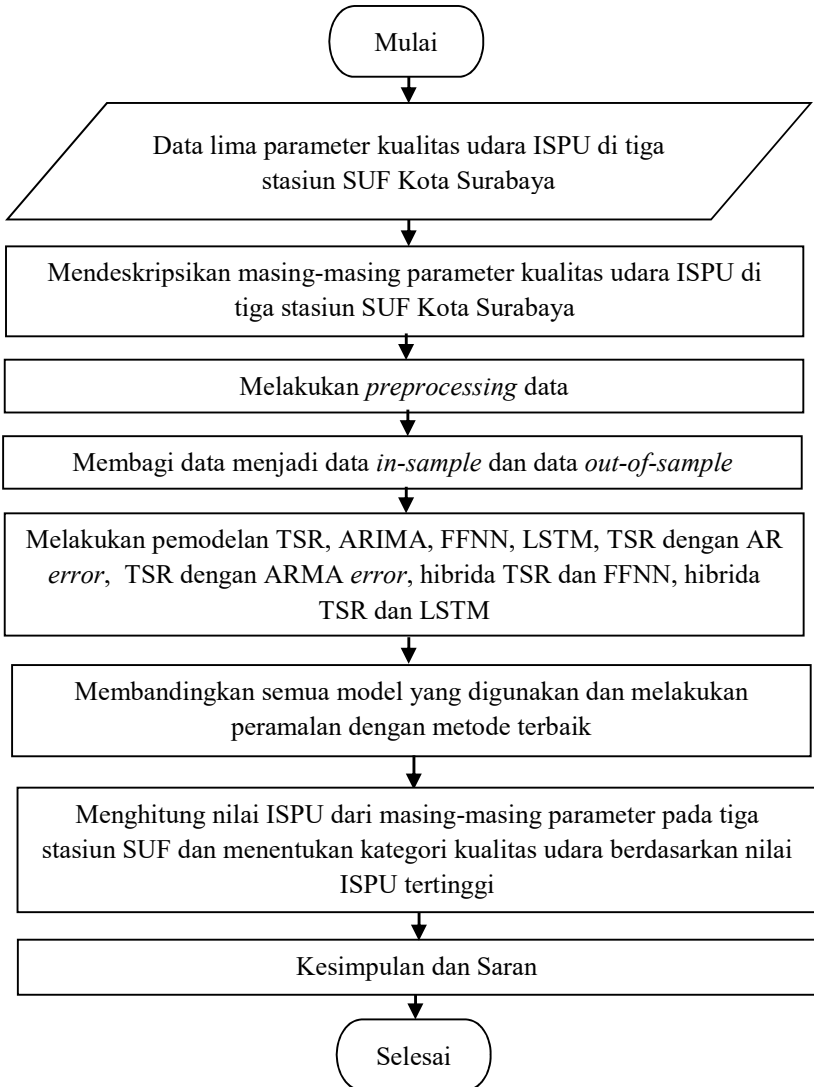
$$Y_t^* = \frac{Y_t - \min(Y_t)}{\max(Y_t) - \min(Y_t)}.$$

3. Mengubah variabel *input* menjadi bentuk 3 dimensi dengan bentuk (jumlah sampel, *time steps*, *feature*). *Time steps* yang digunakan adalah 1.
4. Menentukan jumlah *neuron* pada *hidden layer* LSTM. Jumlah *neuron* yang digunakan adalah 1 hingga 5.
5. Melakukan estimasi parameter pada LSTM.
6. Melakukan peramalan lima parameter kualitas udara di tiga stasiun SUF di Kota Surabaya menggunakan LSTM.
7. Melakukan *postprocessing* data hasil ramalan.

- e. Melakukan peramalan menggunakan metode *time series regression* dengan AR error dengan langkah-langkah sebagai berikut.
1. Memodelkan residual hasil *time series regression* yang belum *white noise* dengan menggunakan AR. Model AR yang dicobakan yaitu AR(1), AR(1)⁴⁸, AR(1)³³⁶, AR(1)(1)⁴⁸, AR(1)(1)³³⁶ dan AR(1)(1)⁴⁸(1)³³⁶.
 2. Melakukan pemodelan lima parameter kualitas udara di tiga stasiun SUF di Kota Surabaya menggunakan *time series regression* dengan AR error.
 3. Pemilihan model terbaik *time series regression* dengan AR error.
 4. Melakukan peramalan lima parameter kualitas udara di tiga stasiun SUF di Kota Surabaya menggunakan *time series regression* dengan AR error.
- f. Melakukan peramalan menggunakan metode *time series regression* dengan ARMA error dengan langkah-langkah sebagai berikut.
1. Memodelkan residual hasil *time series regression* yang belum *white noise* dengan menggunakan ARMA. Identifikasi orde AR dan MA didasarkan pada plot ACF dan PACF.
 2. Melakukan pemodelan lima parameter kualitas udara di tiga stasiun SUF di Kota Surabaya menggunakan *time series regression* dengan ARMA error.
 3. Pemilihan model terbaik *time series regression* dengan ARMA error.
 4. Melakukan peramalan lima parameter kualitas udara di tiga stasiun SUF di Kota Surabaya menggunakan *time series regression* dengan ARMA error.


- g. Melakukan peramalan menggunakan model hibrida *time series regression* dan FFNN dengan langkah-langkah sebagai berikut.
 1. Mencari model *time series regression* yang sesuai.
 2. Memodelkan residual dari model statistika dengan menggunakan FFNN. Digunakan 1 *hidden layer* dan dicobakan *neuron* 1 hingga 5.
 3. Menggabungkan model *time series regression* dan model FFNN sehingga didapatkan model hibrida.
 4. Melakukan peramalan lima parameter kualitas udara di tiga stasiun SUF di Kota Surabaya menggunakan model hibrida.
- h. Melakukan peramalan menggunakan model hibrida *time series regression* dan LSTM dengan langkah-langkah sebagai berikut.
 1. Mencari model *time series regression* yang sesuai.
 2. Memodelkan residual dari model statistika dengan menggunakan LSTM. Digunakan 1 *hidden layer* dan dicobakan *neuron* 1 hingga 5.
 3. Menggabungkan model *time series regression* dan model LSTM sehingga didapatkan model hibrida.
 4. Melakukan peramalan lima parameter kualitas udara di tiga stasiun SUF di Kota Surabaya menggunakan model hibrida.
4. Melakukan peramalan masing-masing parameter kualitas udara ISPU pada 3 stasiun SUF di Kota Surabaya berdasarkan model terbaik.
5. Menghitung nilai ISPU dari masing-masing parameter pada tiga stasiun SUF berdasarkan hasil peramalan dan menentukan kategori kualitas udara Kota Surabaya berdasarkan nilai ISPU tertinggi.

Langkah analisis dalam penelitian ini digambarkan dalam diagram alir Gambar 3.1.



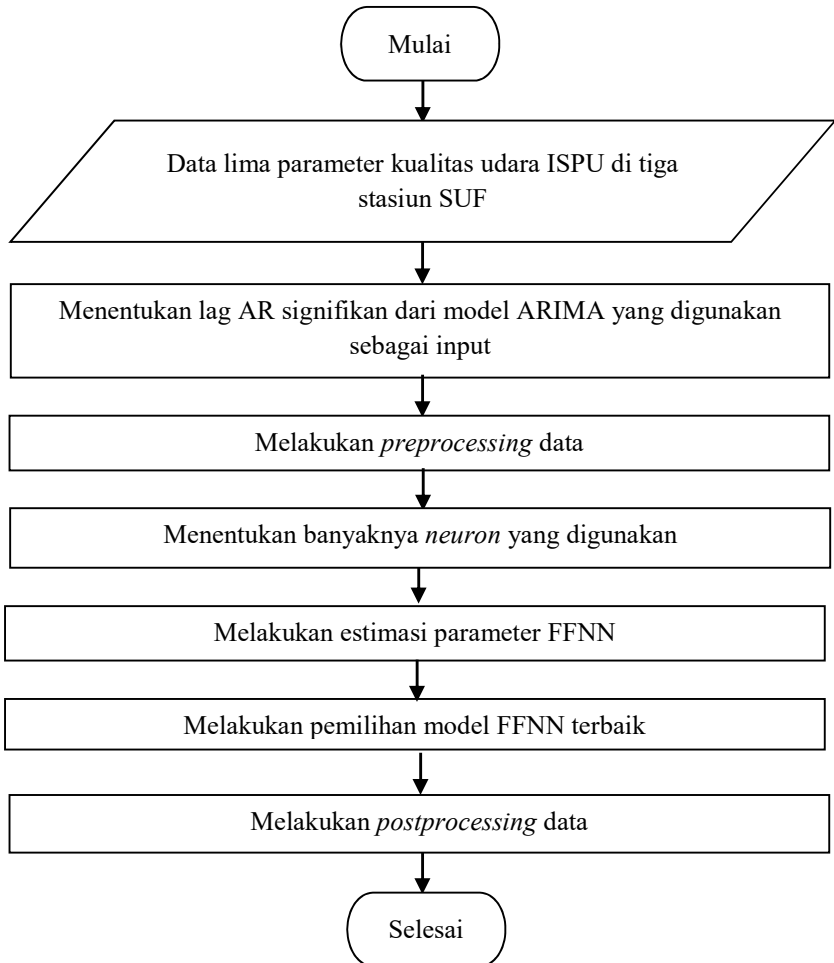
Gambar 3.1 Diagram Alir Penelitian Secara Umum

Langkah pemodelan dengan ARIMA adalah sebagai berikut



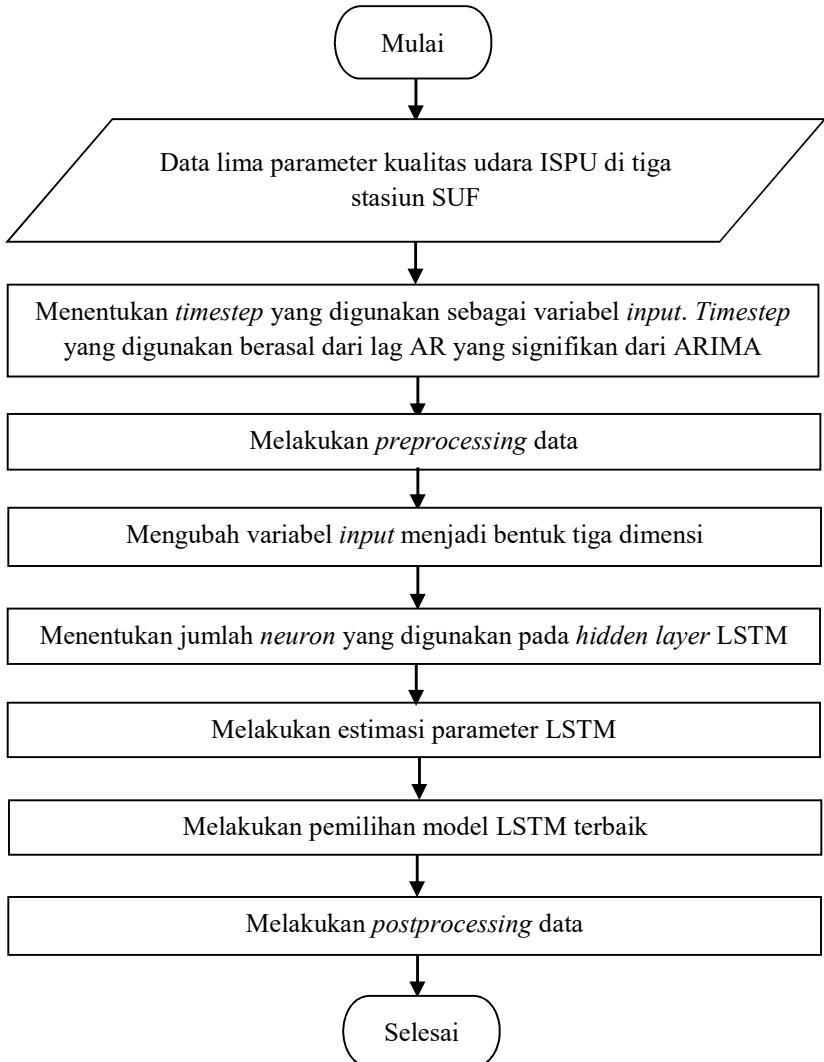
Gambar 3.2 Diagram Alir Pemodelan ARIMA

Langkah pemodelan dengan *Feed Forward Neural Network* (FFNN) adalah sebagai berikut



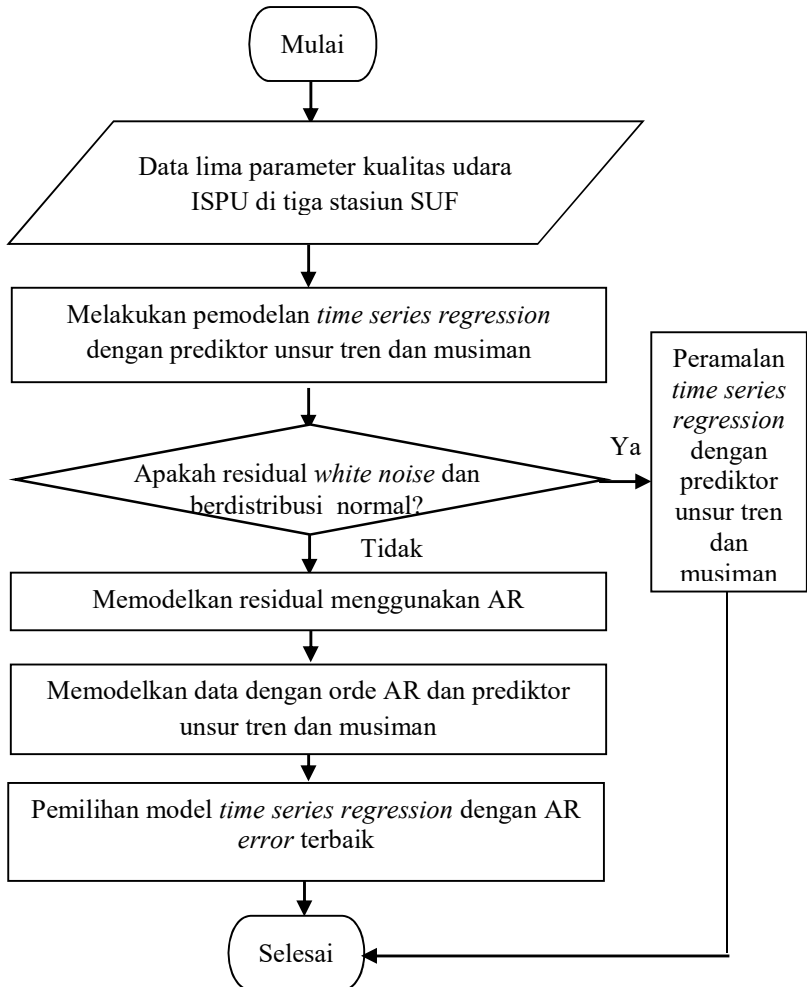
Gambar 3.3 Diagram Alir Pemodelan *Feed Forward Neural Network*

Langkah pemodelan dengan *Long Short Term Memory* (LSTM) adalah sebagai berikut



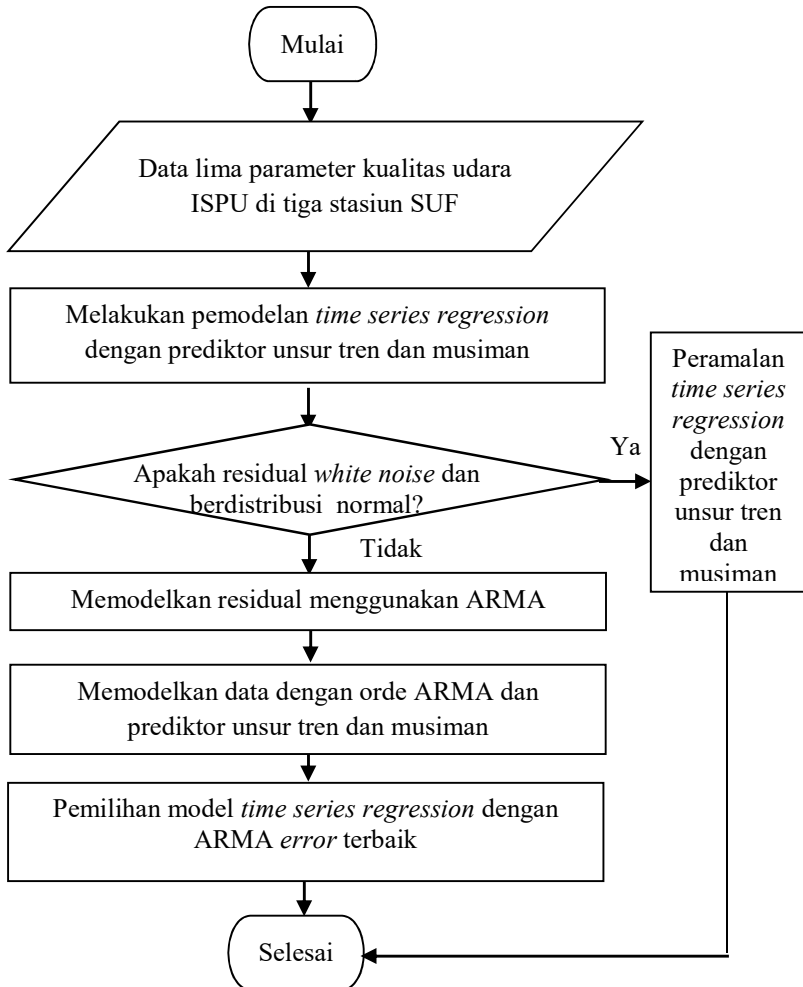
Gambar 3.4 Diagram Alir Pemodelan *Long Short Term Memory*

Langkah pemodelan dengan *time series regression* dengan AR *error* adalah sebagai berikut



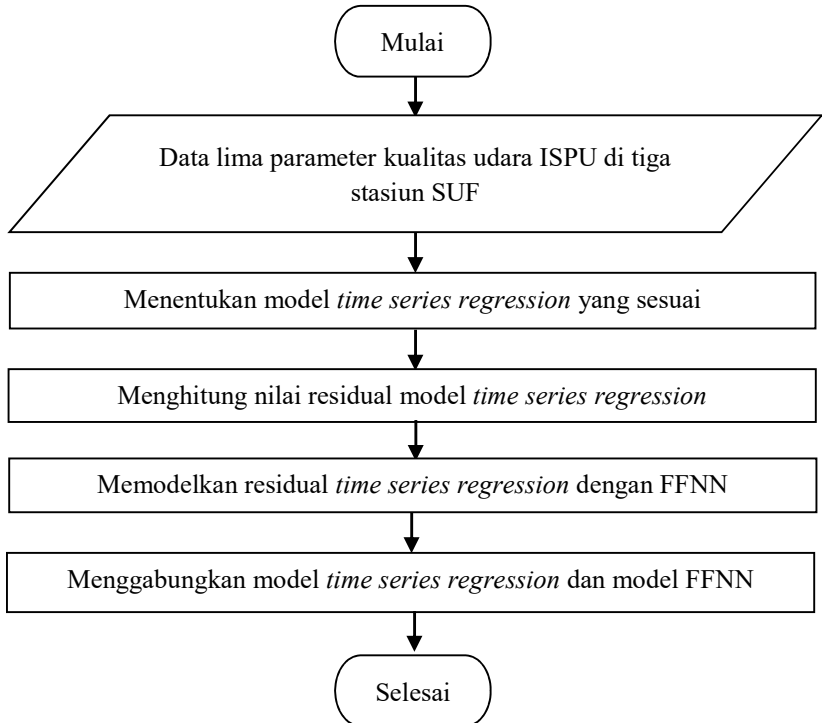
Gambar 3.5 Diagram Alir Pemodelan *Time Series Regression* dengan AR *error*

Langkah pemodelan dengan *time series regression* dengan ARMA *error* adalah sebagai berikut



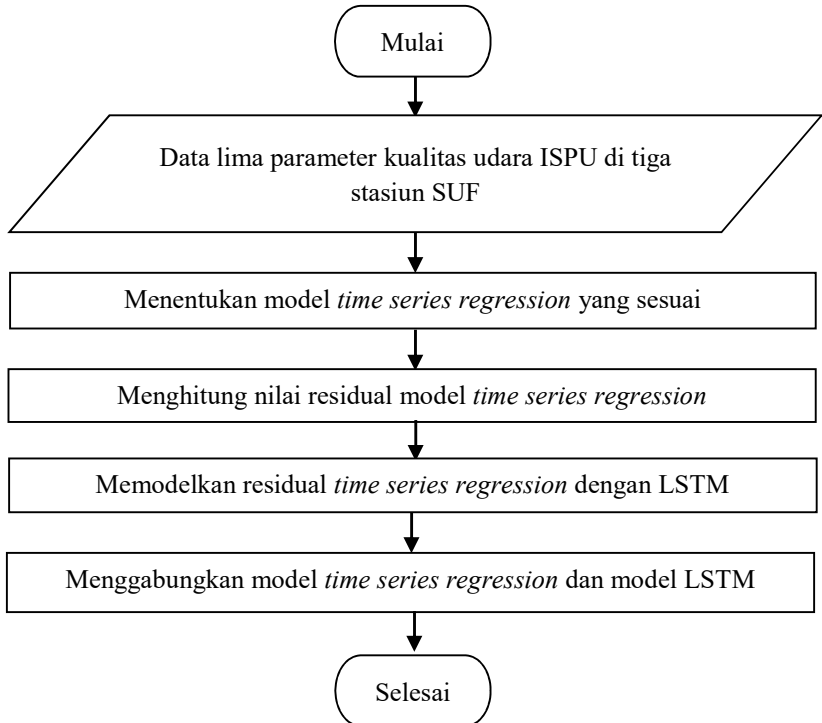
Gambar 3.6 Diagram Alir Pemodelan *Time Series Regression* dengan ARMA *error*

Langkah pemodelan dengan hibrida *time series regression* dan FFNN adalah sebagai berikut




Gambar 3.7 Diagram Alir Pemodelan Hibrida *Time Series Regression* dan FFNN

Langkah pemodelan dengan hibrida *time series regression* dan LSTM adalah sebagai berikut



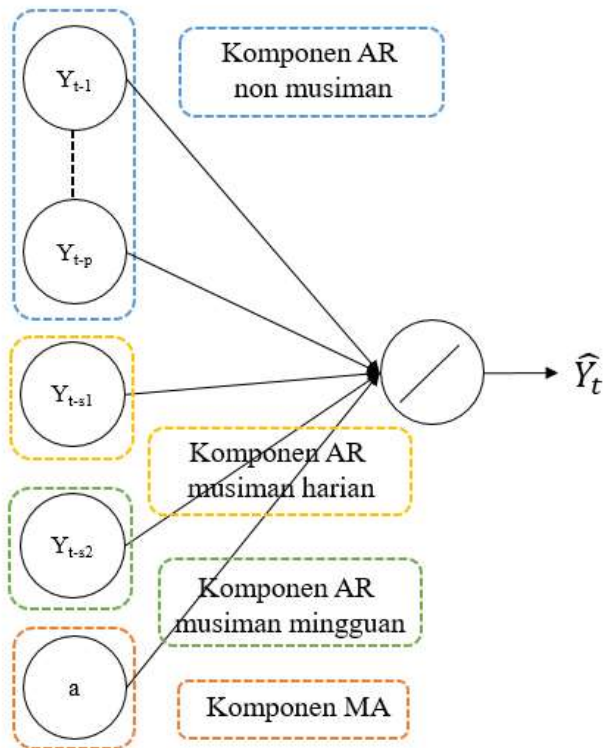
Gambar 3.8 Diagram Alir Pemodelan Hibrida *Time Series Regression* dan LSTM

Berikut merupakan ilustrasi pembentukan model *time series regression*




Gambar 3.9 Ilustrasi Pembentukan Model *Time Series Regression*

Berikut merupakan ilustrasi pembentukan model ARIMA



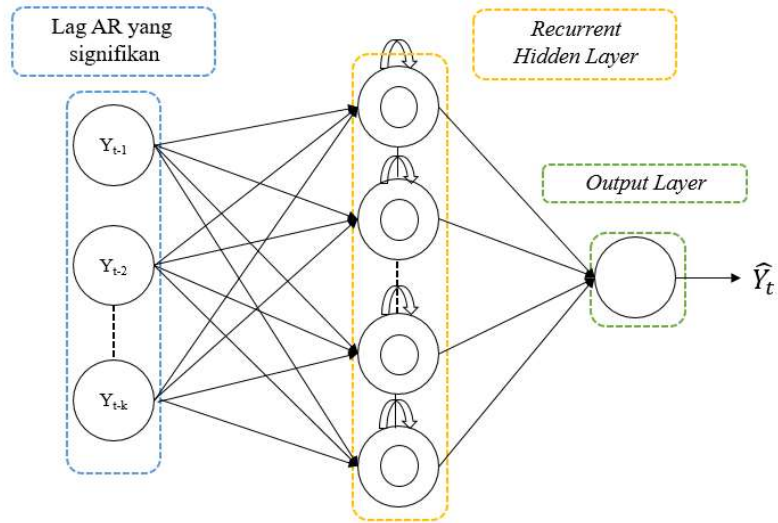
Gambar 3.10 Ilustrasi Pembentukan Model ARIMA

Berikut merupakan ilustrasi pembentukan model FFNN




Gambar 3.11 Ilustrasi Pembentukan Model FFNN

Berikut merupakan ilustrasi pembentukan model LSTM



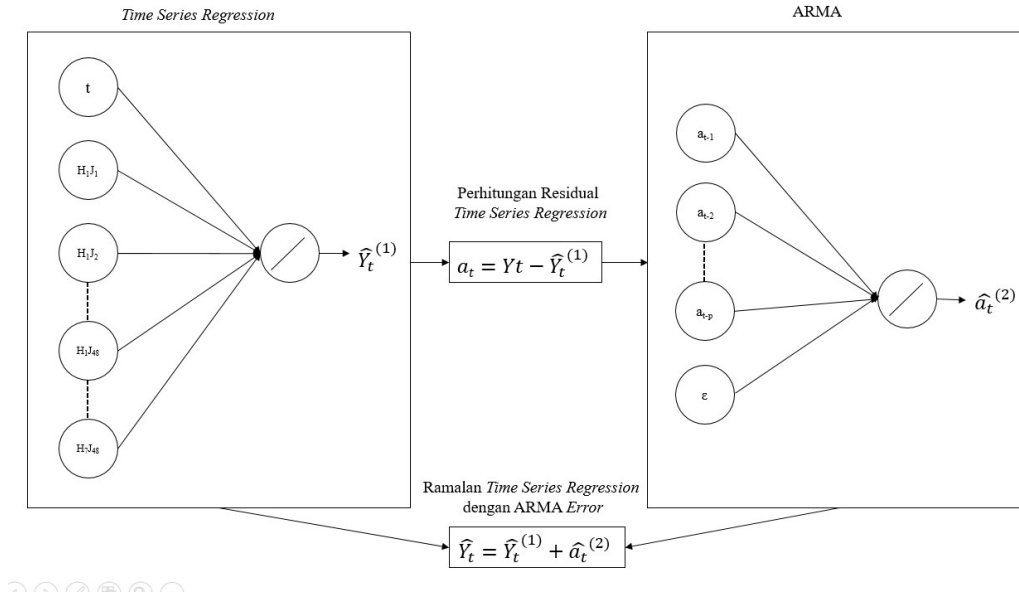
Gambar 3.12 Ilustrasi Pembentukan Model LSTM

Berikut merupakan ilustrasi pembentukan model *time series regression* dengan AR error




Gambar 3.13 Ilustrasi Pembentukan Model *Time Series Regression* dengan AR Error

Berikut merupakan ilustrasi pembentukan model *time series regression* dengan ARMA error




Gambar 3.14 Ilustrasi Pembentukan Model *Time Series Regression* dengan ARMA Error

Berikut merupakan ilustrasi pembentukan model hibrida *time series regression* dan FFNN



Gambar 3.15 Ilustrasi Pembentukan Model Hibrida *Time Series Regression* dan FFNN

Berikut merupakan ilustrasi pembentukan model hibrida *time series regression* dan LSTM



Gambar 3.16 Ilustrasi Pembentukan Model Hibrida *Time Series Regression* dan LSTM

BAB IV

ANALISIS DAN PEMBAHASAN


Pada penelitian ini, analisis dan pembahasan berisi mengenai delapan metode yang digunakan dalam penelitian ini yaitu *time series regression* (TSR), ARIMA, FFNN, LSTM, *time series regression* dengan AR error, *time series regression* dengan ARMA error, hibrida *time series regression* dan FFNN serta hibrida *time series regression* dan LSTM. Evaluasi kebaikan model lima parameter kualitas udara pada tiga stasiun SUF Kota Surabaya digunakan RMSE dan sMAPE pada data *out-of-sample*. Evaluasi kebaikan model ini dilakukan untuk menentukan metode terbaik yang akan digunakan untuk peramalan. Selanjutnya hasil peramalan masing-masing parameter kualitas udara akan digunakan untuk meramalkan nilai Indeks Standar Pencemar Udara (ISPU) dan kategori kualitas udara Kota Surabaya.

4.1. Karakteristik Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya

Parameter kualitas udara di Kota Surabaya diukur menggunakan AQMS yang berada pada tiga stasiun SUF yaitu SUF 1 di Taman Prestasi, SUF 6 di Kebun Bibit Wonorejo dan SUF 7 di Kebonsari. Terdapat lima parameter yang digunakan yaitu CO, NO₂, O₃, PM₁₀ dan SO₂. Data yang digunakan merupakan data parameter kualitas udara per setengah jam tahun 2018. Karakteristik dari kelima parameter kualitas udara di Kota Surabaya ditunjukkan oleh visualisasi dan eksplorasi data yang akan membantu dalam melakukan pemodelan.

4.1.1. Karakteristik Parameter Kualitas Udara CO di Kota Surabaya

CO merupakan salah satu parameter kualitas udara yang digunakan dalam menentukan ISPU Karakteristik CO di Kota Surabaya dapat dilihat pada Gambar 4.1.



Gambar 4.1 Time Series Plot CO Tahun 2018 di SUF 1 (a), SUF 6 (b) dan SUF 7 (c) Kota Surabaya

Dari Gambar 4.1 diketahui bahwa konsentrasi CO pada SUF 1, SUF 6 dan SUF 7 selama tahun 2018 cenderung stasioner, tetapi pada akhir tahun di SUF 1 dan SUF 6 konsentrasi CO tinggi. Konsentrasi CO di SUF 7 lebih tinggi dibandingkan di stasiun SUF lainnya hal ini dikarenakan letak stasiun SUF 7 yang berada di Kebonsari. Kebonsari merupakan wilayah yang dekat dengan jalan tol, sehingga banyak terdapat kendaraan bermotor yang menghasilkan CO. Kendaraan bermotor terutama yang berbahan bakar bensin merupakan salah satu sumber pencemaran utama CO. Tingginya konsentrasi CO di SUF 7 ini ditunjukkan pada Tabel 4.1 yang memiliki rata-rata tertinggi dibandingkan dengan stasiun SUF lainnya di Kota Surabaya. Tetapi dari Tabel 4.1 nilai maksimum dari SUF 6 paling tinggi yaitu 20,51, hal ini dikarenakan oleh beberapa hal yaitu kondisi alat yang rusak atau perubahan kondisi udara yang ekstrim di SUF 6.

Dari Gambar 4.1 juga bisa diketahui bahwa banyak terdapat data yang hilang (*missing value*) pada ketiga stasiun SUF sehingga dilakukan imputasi berdasarkan nilai median per setengah jam per

hari agar dapat dilakukan pemodelan. *Missing value* yang terjadi diakibatkan oleh kondisi alat AQMS yang sedang tidak berfungsi, sehingga tidak dapat mengeluarkan nilai parameter kualitas udara. Diketahui bahwa pada SUF 6 jumlah data *missing* paling banyak dibandingkan di stasiun SUF lainnya yaitu 41,22%, sedangkan SUF 7 memiliki jumlah data *missing* paling sedikit yaitu 6,58%. Artinya alat pencatat parameter kualitas udara CO di SUF 6 pada tahun 2018 paling sering mengalami gangguan.


Tabel 4.1 Karakteristik Data CO

CO	% <i>Missing</i>	Rata- Rata	Standar Deviasi	Minimum	Maksimum
SUF 1	11,08	0,64	0,53	0	7,17
SUF 6	41,22	1,18	1,45	0	20,51
SUF 7	6,58	1,24	1,08	0	11,21

Pada Gambar 4.2 diketahui bahwa konsentrasi CO di SUF 1 tertinggi pada sekitar pukul 08.00 hal ini dikarenakan pada sekitar pukul 08.00 merupakan waktu bagi mayoritas warga Surabaya di sekitar Taman Prestasi untuk memulai aktivitas sehingga terdapat banyak kendaraan yang beroperasi di jalanan. Tetapi pada hari sabtu konsentrasi CO di SUF 1 cenderung tinggi menjelang tengah malam, hal ini dikarenakan banyak warga Surabaya di sekitar SUF 1 yang beraktivitas di luar rumah untuk mengisi malam minggu. Pada hari senin hingga sabtu konsentrasi CO di SUF 1 hampir sama tetapi ketika hari minggu konsentrasi CO di SUF 1 cenderung rendah. Hal ini dikarenakan hari libur, di mana daerah di sekitar Taman Prestasi merupakan perkantoran sehingga tidak terdapat aktivitas.

Untuk SUF 6 dan SUF 7 hampir sama yaitu konsentrasi CO cenderung tinggi pada pukul 08.00 dan hari minggu lebih rendah dibandingkan hari lain. Pada SUF 6 konsentrasi CO sangat tinggi ketika hari minggu antara pukul 00.00 hingga 01.00 hal ini dikarenakan di sekitar Taman Bibit Wonorejo terdapat jalan yang merupakan salah satu akses keluar dari Surabaya. Pada sekitar waktu tersebut banyak kendaraan yang akan keluar Kota Surabaya


melewati area disekitar Taman Bibit Wonorejo. Sehingga berdasarkan Gambar 4.2 diketahui bahwa parameter kualitas udara CO di tiga stasiun SUF Kota Surabaya memiliki pola *double seasonal* yaitu musiman harian per setengah jam dan musiman mingguan per hari.



Gambar 4.2 Interval Plot CO di SUF 1 (a), SUF 6 (b), SUF 7 (c) dan Line Plot CO di SUF 1 (d), SUF 6 (e), SUF 7 (f)

4.1.2. Karakteristik Parameter Kualitas Udara NO₂ di Kota Surabaya

Karakteristik parameter kualitas udara NO₂ di Kota Surabaya dapat dilihat pada Gambar 4.3.



Gambar 4.3 Time Series Plot NO₂ Tahun 2018 di SUF 1 (a), SUF 6 (b) dan SUF 7 (c) Kota Surabaya

Berdasarkan Gambar 4.3 diketahui bahwa konsentrasi NO₂ pada SUF 1, SUF 6 dan SUF 7 selama tahun 2018 cenderung stasioner walaupun pada waktu-waktu tertentu konsentrasi NO₂ meningkat. Meskipun terlihat stasioner tetapi pada akhir tahun di SUF 1 konsentrasi NO₂ rendah. Konsentrasi NO₂ di SUF 7 lebih tinggi dibandingkan di stasiun SUF lainnya hal ini dikarenakan letak stasiun SUF 7 yang berada di Kebonsari. Kebonsari merupakan wilayah yang dekat dengan jalan tol, sehingga banyak terdapat kendaraan bermotor yang menghasilkan NO₂. Kendaraan bermotor merupakan salah satu sumber pencemaran utama NO₂, selain yang berasal dari proses industri. Tingginya konsentrasi NO₂ di SUF 7 ini ditunjukkan pada Tabel 4.2 yang memiliki rata-rata tertinggi dibandingkan dengan stasiun SUF lainnya di Kota Surabaya. Sebaliknya SUF 6 memiliki konsentrasi NO₂ yang


paling rendah bila dibandingkan dengan stasiun SUF lainnya, hal ini dikarenakan letak SUF 6 yang berada di Taman Bibit.

Dari Gambar 4.3 juga bisa diketahui bahwa banyak terdapat data yang hilang (*missing value*) pada ketiga stasiun SUF sehingga dilakukan imputasi berdasarkan nilai median per setengah jam per hari agar dapat dilakukan pemodelan. *Missing value* yang terjadi diakibatkan oleh kondisi alat AQMS yang sedang tidak berfungsi, sehingga tidak dapat mengeluarkan nilai parameter kualitas udara. Diketahui bahwa pada SUF 1 dan SUF 6 jumlah data *missing* hampir sama yaitu 14,61% dan 14,73%, sedangkan SUF 7 memiliki jumlah data *missing* paling sedikit yaitu 5,07%. Artinya alat pencatat parameter kualitas udara NO₂ di SUF 7 pada tahun 2018 paling jarang mengalami gangguan.

Tabel 4.2 Karakteristik Data NO₂

NO ₂	% <i>Missing</i>	Rata- Rata	Standar Deviasi	Minimum	Maksimum
SUF 1	14,61	22,15	16,88	0	135,58
SUF 6	14,73	15,11	15,03	0	97,176
SUF 7	5,07	32,47	19,24	1,06	176,66

Berdasarkan Gambar 4.4 diketahui bahwa konsentrasi NO₂ di SUF 1 tertinggi pada sekitar pukul 08.00 hal ini dikarenakan pada sekitar pukul 08.00 merupakan waktu bagi mayoritas warga Surabaya di sekitar Taman Prestasi untuk memulai aktivitas seperti berangkat kerja dan sekolah sehingga terdapat banyak kendaraan yang beroperasi di jalanan. Konsentrasi NO₂ terendah terjadi pada sekitar pukul 12.00, karena pada waktu ini kondisi jalanan sedang panas mengakibatkan kendaraan yang beroperasi menjadi berkurang. Pada hari senin hingga sabtu konsentrasi NO₂ di SUF 1 hampir sama tetapi ketika hari minggu konsentrasi NO₂ di SUF 1 cenderung rendah. Hal ini dikarenakan hari libur, di mana daerah di sekitar Taman Prestasi merupakan perkantoran sehingga tidak terdapat aktivitas.




Gambar 4.4 Interval Plot NO₂ di SUF 1 (a), SUF 6 (b), SUF 7 (c) dan Line Plot NO₂ di SUF 1 (d), SUF 6 (e), SUF 7 (f)

Untuk SUF 6 hampir sama dengan SUF 1 yaitu konsentrasi NO₂ cenderung tinggi pada pukul 08.00 dan hari minggu lebih rendah dibandingkan hari lain. Tetapi pada pukul 12.00 konsentrasi NO₂ rendah dan sedikit mengalami peningkatan hingga pukul 00.00. Pada SUF 7 konsentrasi NO₂ tertinggi pada hari senin hingga sabtu terjadi pada sekitar pukul 08.00, 16.00 dan 20.00. Hal ini dikarenakan pada pukul 08.00 di SUF 7 yang wilayahnya dekat dengan jalan tol aktivitas kendaraan sedang padat. Sedangkan pada pukul 16.00 dan 20.00 selain diakibatkan oleh aktivitas kendaraan

bermotor yang padat juga diindikasikan terjadi reaksi antara NO di alam dengan O_3 yang terkumpul sepanjang hari. Hal ini mengakibatkan kadar NO_2 meningkat. Sehingga berdasarkan Gambar 4.4 diketahui bahwa parameter kualitas udara NO_2 di tiga stasiun SUF Kota Surabaya memiliki pola *double seasonal* yaitu musiman harian per setengah jam dan musiman mingguan per hari.

4.1.3. Karakteristik Parameter Kualitas Udara O_3 di Kota Surabaya

Karakteristik parameter kualitas udara O_3 di Kota Surabaya dapat dilihat pada Gambar 4.5.



Gambar 4.5 Time Series Plot O_3 Tahun 2018 di SUF 1 (a), SUF 6 (b) dan SUF 7 (c) Kota Surabaya

Berdasarkan Gambar 4.5 diketahui bahwa konsentrasi O_3 pada SUF 1, SUF 6 dan SUF 7 selama tahun 2018 cenderung terjadi tren kenaikan. Pada pertengahan tahun 2018 di SUF 1 konsentrasi O_3 meningkat secara drastis hal ini diindikasikan diakibatkan oleh alat yang rusak atau perubahan iklim yang ekstrim di SUF 1. Konsentrasi O_3 di SUF 1 lebih tinggi dibandingkan di stasiun SUF lainnya hal ini dikarenakan letak stasiun SUF 1 yang berada di Taman Prestasi. O_3 merupakan salah satu parameter

kualitas udara yang tidak diemisikan secara langsung dari suatu sumber tetapi merupakan reaksi antara sinar matahari dengan udara. Terdapat indikasi bahwa intensitas penyinaran matahari di sekitar SUF 1 lebih tinggi dibandingkan wilayah lain. Tingginya konsentrasi O₃ di SUF 1 ini ditunjukkan pada Tabel 4.3 yang memiliki rata-rata tertinggi dibandingkan dengan stasiun SUF lainnya di Kota Surabaya. Tetapi dari Tabel 4.3 nilai maksimum dari SUF 7 paling tinggi yaitu 241,20, hal ini dikarenakan oleh beberapa hal yaitu kondisi alat yang rusak atau perubahan kondisi iklim yang ekstrim di SUF 1.


Dari Gambar 4.5 juga bisa diketahui bahwa banyak terdapat data yang hilang (*missing value*) pada ketiga stasiun SUF sehingga dilakukan imputasi berdasarkan nilai median per jam per hari agar dapat dilakukan pemodelan. *Missing value* yang terjadi diakibatkan oleh kondisi alat AQMS yang sedang tidak berfungsi, sehingga tidak dapat mengeluarkan nilai parameter kualitas udara. Diketahui bahwa pada SUF 6 jumlah data *missing* paling banyak dibandingkan di stasiun SUF lainnya yaitu 5,84%, sedangkan SUF 1 memiliki jumlah data *missing* paling sedikit yaitu 2,77%. Artinya alat pencatat parameter kualitas udara O₃ di SUF 6 pada tahun 2018 paling sering mengalami gangguan.

Tabel 4.3 Karakteristik Data O₃

O ₃	% <i>Missing</i>	Rata- Rata	Standar Deviasi	Minimum	Maksimum
SUF 1	2,77	36,26	30,08	1,01	176,53
SUF 6	5,81	26,02	21,09	0	143,30
SUF 7	3,84	18,65	19,32	0	241,20

Berdasarkan Gambar 4.6 diketahui bahwa konsentrasi O₃ di SUF 1 tertinggi pada sekitar pukul 12.00 hal ini dikarenakan pada sekitar pukul 12.00 intensitas penyinaran matahari tinggi. Konsentrasi O₃ terendah terjadi pada saat dinihari. Pada hari senin hingga minggu konsentrasi O₃ di SUF 1 hampir sama. Hal ini dikarenakan kadar O₃ tidak diemisikan secara langsung dari suatu sumber. Untuk SUF 6 dan SUF 7 hampir sama dengan SUF 1 yaitu


konsentrasi O_3 cenderung tinggi pada pukul 12.00. Sehingga berdasarkan Gambar 4.6 diketahui bahwa parameter kualitas udara O_3 di tiga stasiun SUF Kota Surabaya memiliki pola *double seasonal* yaitu musiman harian per setengah jam dan musiman mingguan per hari.



Gambar 4.6 Interval Plot O_3 di SUF 1 (a), SUF 6 (b), SUF 7 (c) dan Line Plot O_3 di SUF 1 (a), SUF 6 (b), SUF 7 (c)

4.1.4. Karakteristik Parameter Kualitas Udara PM₁₀ di Kota Surabaya

Karakteristik parameter kualitas udara PM₁₀ di Kota Surabaya dapat dilihat pada Gambar 4.7.



Gambar 4.7 Time Series Plot PM₁₀ Tahun 2018 di SUF 1 (a), SUF 6 (b) dan SUF 7 (c) Kota Surabaya

Berdasarkan Gambar 4.7 diketahui bahwa konsentrasi PM₁₀ pada SUF 6 dan SUF 7 selama tahun 2018 cenderung stasioner walaupun pada waktu-waktu tertentu konsentrasi PM₁₀ di SUF 6 dan SUF 7 meningkat. Sedangkan konsentrasi PM₁₀ di SUF 1 pada awal tahun mengalami kenaikan setelah itu konsentrasi PM₁₀ tidak tercatat yang diakibatkan oleh alat yang rusak. Konsentrasi PM₁₀ di SUF 7 lebih tinggi dibandingkan di stasiun SUF lainnya hal ini dikarenakan letak stasiun SUF 7 yang berada di Kebonsari. Kebonsari merupakan wilayah yang dekat dengan jalan tol, sehingga banyak terdapat kendaraan bermotor yang menghasilkan partikel debu berupa PM₁₀. Kendaraan bermotor dan aktivitas pembakaran yang dilakukan manusia merupakan salah satu sumber pencemaran utama PM₁₀. Tingginya konsentrasi PM₁₀ di SUF 7 ini ditunjukkan pada Tabel 4.4 yang memiliki rata-rata tertinggi


dibandingkan dengan stasiun SUF lainnya di Kota Surabaya. Sebaliknya SUF 6 memiliki konsentrasi PM_{10} yang paling rendah bila dibandingkan dengan stasiun SUF lainnya, hal ini dikarenakan letak SUF 6 yang berada di Taman Bibit.

Dari Gambar 4.3 juga bisa diketahui bahwa banyak terdapat data yang hilang (*missing value*) pada ketiga stasiun SUF sehingga dilakukan imputasi berdasarkan nilai median per setengah jam per hari agar dapat dilakukan pemodelan. *Missing value* yang terjadi diakibatkan oleh kondisi alat AQMS yang sedang tidak berfungsi, sehingga tidak dapat mengeluarkan nilai parameter kualitas udara. Diketahui bahwa pada SUF 1 jumlah data *missing* terbanyak yaitu 43,61%. Jumlah data *missing* di SUF 1 ini sangat banyak selama 2018 hampir 50%. Artinya alat pencatat parameter kualitas udara PM_{10} di SUF 1 pada tahun 2018 paling sering mengalami gangguan.

Tabel 4.4 Karakteristik Data PM_{10}

PM_{10}	% <i>Missing</i>	Rata- Rata	Standar Deviasi	Minimum	Maksimum
SUF 1	43,61	26,54	35,59	0	342,60
SUF 6	9,09	13,36	14,19	0	355,00
SUF 7	12,64	74,81	46,78	0	387,00

Berdasarkan Gambar 4.8 diketahui bahwa konsentrasi tertinggi PM_{10} di SUF 1 dalam satu minggu berbeda-beda. Pada hari senin hingga rabu pada sekitar pukul 16.00 konsentrasi PM_{10} cenderung lebih tinggi dibandingkan waktu lainnya. Pada hari kamis dan sabtu konsentrasi PM_{10} cenderung lebih tinggi pada pukul 12.00. Pada hari jumat lebih tinggi pada pukul 20.00. Sedangkan di hari minggu konsentrasi PM_{10} cenderung sama dalam 1 hari. Selain itu juga terlihat bahwa konsentrasi PM_{10} di SUF 1 pada hari kamis lebih tinggi dibandingkan hari lainnya.




Gambar 4.8 Interval Plot PM₁₀ di SUF 1 (a), SUF 6 (b), SUF 7 (c) dan Line Plot PM₁₀ di SUF 1 (d), SUF 6 (e), SUF 7 (f)

Untuk SUF 6 konsentrasi PM₁₀ cenderung tinggi sekitar pukul 11.00 dan pada hari senin konsentrasi PM₁₀ cenderung lebih rendah dibandingkan hari lainnya. Pada SUF 7 konsentrasi PM₁₀ lebih tinggi sekitar pukul 08.00. Hal ini dikarenakan pada pukul 08.00 di SUF 7 yang wilayahnya dekat dengan jalan tol aktivitas kendaraan sedang padat. Asap kendaraan bermotor ini merupakan salah satu sumber emisi PM₁₀. Hal ini mengakibatkan kadar PM₁₀ meningkat. Konsentrasi PM₁₀ di SUF 7 terendah pada hari senin. Kondisi ini hampir sama dengan kondisi di SUF 6. Sehingga

berdasarkan Gambar 4.8 diketahui bahwa parameter kualitas udara PM_{10} di tiga stasiun SUF Kota Surabaya memiliki pola *double seasonal* yaitu musiman harian per setengah jam dan musiman mingguan per hari.

4.1.5. Karakteristik Parameter Kualitas Udara SO_2 di Kota Surabaya

Karakteristik parameter kualitas udara SO_2 di Kota Surabaya dapat dilihat pada Gambar 4.9.



Gambar 4.9 Time Series Plot SO_2 Tahun 2018 di SUF 1 (a), SUF 6 (b) dan SUF 7 (c) Kota Surabaya

Berdasarkan Gambar 4.9 diketahui bahwa konsentrasi SO_2 pada SUF 1, SUF 6 dan SUF 7 selama tahun 2018 cenderung mengalami tren kenaikan walaupun diakhir tahun cenderung mengalami penurunan. Konsentrasi SO_2 di SUF 1 lebih tinggi dibandingkan di stasiun SUF lainnya. Transportasi bukan merupakan sumber utama SO_2 . Sumber utama SO_2 merupakan berbagai macam proses pembakaran. Hal ini yang mengakibatkan konsentrasi SO_2 di SUF 1 lebih tinggi dibandingkan SUF 7. Tingginya konsentrasi SO_2 di SUF 1 ini ditunjukkan pada Tabel 4.5

yang memiliki rata-rata tertinggi dibandingkan dengan stasiun SUF lainnya di Kota Surabaya.

Dari Gambar 4.9 juga bisa diketahui bahwa banyak terdapat data yang hilang (*missing value*) pada ketiga stasiun SUF sehingga dilakukan imputasi berdasarkan nilai median per setengah jam per hari agar dapat dilakukan pemodelan. *Missing value* yang terjadi diakibatkan oleh kondisi alat AQMS yang sedang tidak berfungsi, sehingga tidak dapat mengeluarkan nilai parameter kualitas udara. Diketahui bahwa pada SUF 1 dan SUF 6 jumlah data *missing* hampir sama yaitu 7,59% dan 6,59%, sedangkan SUF 7 memiliki jumlah data *missing* paling banyak yaitu 9,34%. Artinya alat pencatat parameter kualitas udara SO₂ di SUF 7 pada tahun 2018 paling sering mengalami gangguan.


Tabel 4.5 Karakteristik Data SO₂

SO ₂	% <i>Missing</i>	Rata- Rata	Standar Deviasi	Minimum	Maksimum
SUF 1	7,59	27,94	25,76	0	374,16
SUF 6	6,59	19,69	15,62	0	221,19
SUF 7	9,34	16,30	8,91	0	101,79

Berdasarkan Gambar 4.10 diketahui bahwa konsentrasi SO₂ di SUF 1 tertinggi pada sekitar pukul 08.00 hal ini dikarenakan pada sekitar pukul 08.00 merupakan waktu bagi mayoritas warga Surabaya di sekitar Taman Prestasi untuk memulai aktivitas sehingga terdapat banyak kendaraan yang beroperasi di jalanan. Konsentrasi SO₂ ini mengalami penurunan ketika sore hari hingga dinihari. Pada hari senin hingga sabtu konsentrasi SO₂ di SUF 1 hampir sama tetapi ketika hari minggu konsentrasi SO₂ di SUF 1 cenderung rendah. Hal ini dikarenakan hari libur, sehingga jarang terdapat aktivitas di sekitar SUF 1.

Pada SUF 7 dan SUF 6 konsentrasi SO₂ hampir sama dengan SUF 1 yaitu tertinggi pada pukul 08.00 dan pada hari minggu konsentrasi SO₂ cenderung lebih rendah dibandingkan hari lainnya. Pada SUF 7 konsentrasi SO₂ terlihat sangat rendah sekitar pukul 18.00. Hal ini diakibatkan oleh aktivitas masyarakat dan jalan tol

yang menurun saat pukul 18.00. Sehingga berdasarkan Gambar 4.4 diketahui bahwa parameter kualitas udara SO_2 di tiga stasiun SUF Kota Surabaya memiliki pola *double seasonal* yaitu musiman harian per setengah jam dan musiman mingguan per hari.



Gambar 4.10 Interval Plot SO_2 di SUF 1 (a), SUF 6 (b), SUF 7 (c) dan Line Plot SO_2 di SUF 1 (d), SUF 6 (e), SUF 7 (f)

4.2. Pemodelan Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya

Pada subbab ini akan menjelaskan mengenai pemodelan parameter kualitas udara di 3 stasiun SUF di Kota Surabaya dengan

metode *time series regression*, ARIMA, FFNN, LSTM, *time series regression* dengan AR error, *time series regression* dengan ARMA error, hibrida *time series regression* dan FFNN, dan hibrida *time series regression* dan LSTM.

4.2.1. Pemodelan Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya dengan *Time Series Regression*

Pemodelan parameter kualitas udara di 3 stasiun SUF di Kota Surabaya dengan *time series regression* dilakukan dengan menggunakan *dummy* sebagai variabel prediktor. Data parameter kualitas udara memiliki pola *double seasonal* yaitu harian dan mingguan, sehingga terdapat 2 jenis variabel *dummy*. Variabel *dummy* yang digunakan yaitu *dummy* per setengah jam dalam 1 hari dan *dummy* hari dalam 1 minggu. Model *time series regression* yang dibentuk merupakan model multiplikatif sehingga terdapat 336 variabel *dummy*. *Time series regression* yang dilakukan menggunakan variabel prediktor tren dan 336 *dummy* dari *double seasonal* dengan variabel respon yaitu parameter kualitas udara per setengah jam di Kota Surabaya. Berikut merupakan estimasi parameter model *time series regression* dari CO di SUF 1.

Tabel 4.6 Estimasi Parameter Model *Time Series Regression* CO SUF 1

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
Tren	0,000034 (0,00)						
00:30	0,25 (0,00)	0,29 (0,00)	0,38 (0,00)	0,22 (0,00)	0,33 (0,00)	0,30 (0,00)	0,45 (0,00)
01:00	0,20 (0,00)	0,28 (0,00)	0,32 (0,00)	0,22 (0,00)	0,29 (0,00)	0,27 (0,00)	0,44 (0,00)
01:30	0,19 (0,00)	0,28 (0,00)	0,24 (0,00)	0,33 (0,00)	0,24 (0,00)	0,26 (0,00)	0,40 (0,00)
02:00	0,20 (0,00)	0,24 (0,00)	0,25 (0,00)	0,26 (0,00)	0,22 (0,00)	0,30 (0,00)	0,40 (0,00)
02:30	0,20 (0,00)	0,26 (0,00)	0,27 (0,00)	0,24 (0,00)	0,23 (0,00)	0,27 (0,00)	0,35 (0,00)

Tabel 4.6 Estimasi Parameter Model *Time Series Regression* CO SUF 1
(Lanjutan)

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
03:00	0,21 (0,00)	0,23 (0,00)	0,21 (0,00)	0,23 (0,00)	0,24 (0,00)	0,24 (0,00)	0,32 (0,00)
03:30	0,21 (0,00)	0,21 (0,00)	0,25 (0,00)	0,19 (0,00)	0,22 (0,00)	0,26 (0,00)	0,30 (0,00)
04:00	0,24 (0,00)	0,24 (0,00)	0,21 (0,00)	0,19 (0,00)	0,20 (0,00)	0,24 (0,00)	0,28 (0,00)
04:30	0,25 (0,00)	0,27 (0,00)	0,21 (0,00)	0,22 (0,00)	0,22 (0,00)	0,19 (0,00)	0,28 (0,00)
05:00	0,28 (0,00)	0,28 (0,00)	0,24 (0,00)	0,24 (0,00)	0,21 (0,00)	0,23 (0,00)	0,30 (0,00)
05:30	0,32 (0,00)	0,29 (0,00)	0,28 (0,00)	0,29 (0,00)	0,24 (0,00)	0,34 (0,00)	0,33 (0,00)
06:00	0,42 (0,00)	0,36 (0,00)	0,36 (0,00)	0,42 (0,00)	0,38 (0,00)	0,45 (0,00)	0,39 (0,00)
06:30	0,53 (0,00)	0,49 (0,00)	0,47 (0,00)	0,55 (0,00)	0,52 (0,00)	0,60 (0,00)	0,50 (0,00)
07:00	0,76 (0,00)	0,74 (0,00)	0,62 (0,00)	0,78 (0,00)	0,75 (0,00)	0,69 (0,00)	0,54 (0,00)
07:30	0,84 (0,00)	0,76 (0,00)	0,74 (0,00)	0,81 (0,00)	0,80 (0,00)	0,69 (0,00)	0,52 (0,00)
08:00	0,70 (0,00)	0,68 (0,00)	0,72 (0,00)	0,84 (0,00)	0,74 (0,00)	0,63 (0,00)	0,46 (0,00)
08:30	0,61 (0,00)	0,60 (0,00)	0,60 (0,00)	0,75 (0,00)	0,59 (0,00)	0,59 (0,00)	0,37 (0,00)
09:00	0,52 (0,00)	0,48 (0,00)	0,49 (0,00)	0,57 (0,00)	0,47 (0,00)	0,46 (0,00)	0,34 (0,00)
09:30	0,40 (0,00)	0,33 (0,00)	0,42 (0,00)	0,43 (0,00)	0,32 (0,00)	0,37 (0,00)	0,31 (0,00)
10:00	0,30 (0,00)	0,25 (0,00)	0,32 (0,00)	0,32 (0,00)	0,24 (0,00)	0,29 (0,00)	0,26 (0,00)

Tabel 4.6 Estimasi Parameter Model *Time Series Regression* CO SUF 1
(Lanjutan)

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
10:30	0,22 (0,00)	0,16 (0,01)	0,25 (0,00)	0,17 (0,00)	0,19 (0,00)	0,25 (0,00)	0,24 (0,00)
11:00	0,17 (0,01)	0,14 (0,02)	0,21 (0,00)	0,15 (0,01)	0,17 (0,01)	0,16 (0,01)	0,24 (0,00)
11:30	0,13 (0,03)	0,12 (0,02)	0,15 (0,02)	0,14 (0,02)	0,13 (0,03)	0,14 (0,02)	0,21 (0,00)
12:00	0,10 (0,09)	0,08 (0,19)	0,16 (0,09)	0,14 (0,01)	0,11 (0,06)	0,10 (0,10)	0,16 (0,00)
12:30	0,08 (0,15)	0,07 (0,26)	0,11 (0,07)	0,12 (0,04)	0,05 (0,41)	0,07 (0,24)	0,10 (0,10)
13:00	0,08 (0,18)	0,08 (0,20)	0,09 (0,07)	0,11 (0,04)	0,02 (0,71)	0,07 (0,28)	0,00 (0,24)
13:30	0,08 (0,18)	0,06 (0,28)	0,10 (0,08)	0,09 (0,15)	0,08 (0,20)	0,06 (0,35)	0,02 (0,76)
14:00	0,09 (0,13)	0,06 (0,33)	0,13 (0,03)	0,11 (0,07)	0,09 (0,16)	0,09 (0,12)	0,03 (0,59)
14:30	0,13 (0,03)	0,10 (0,08)	0,17 (0,01)	0,12 (0,05)	0,12 (0,04)	0,11 (0,07)	0,03 (0,59)
15:00	0,16 (0,01)	0,10 (0,08)	0,18 (0,00)	0,14 (0,02)	0,16 (0,01)	0,11 (0,06)	0,02 (0,69)
15:30	0,20 (0,00)	0,12 (0,04)	0,21 (0,00)	0,18 (0,00)	0,17 (0,00)	0,14 (0,02)	0,04 (0,54)
16:00	0,22 (0,00)	0,14 (0,02)	0,21 (0,00)	0,21 (0,00)	0,18 (0,00)	0,16 (0,01)	0,03 (0,58)
16:30	0,27 (0,00)	0,18 (0,00)	0,25 (0,00)	0,25 (0,00)	0,19 (0,00)	0,21 (0,00)	0,06 (0,32)

Tabel 4.6 Estimasi Parameter Model *Time Series Regression* CO SUF 1
(Lanjutan)


Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
17:00	0,35 (0,00)	0,22 (0,00)	0,32 (0,00)	0,30 (0,00)	0,29 (0,00)	0,26 (0,00)	0,11 (0,07)
17:30	0,43 (0,00)	0,32 (0,00)	0,39 (0,00)	0,36 (0,00)	0,38 (0,00)	0,30 (0,00)	0,14 (0,02)
18:00	0,55 (0,00)	0,44 (0,00)	0,54 (0,00)	0,51 (0,00)	0,49 (0,00)	0,36 (0,00)	0,16 (0,01)
18:30	0,47 (0,00)	0,44 (0,00)	0,49 (0,00)	0,46 (0,00)	0,43 (0,00)	0,34 (0,00)	0,17 (0,01)
19:00	0,47 (0,00)	0,45 (0,00)	0,44 (0,00)	0,43 (0,00)	0,44 (0,00)	0,40 (0,00)	0,27 (0,00)
19:30	0,47 (0,00)	0,40 (0,00)	0,43 (0,00)	0,47 (0,00)	0,45 (0,00)	0,48 (0,00)	0,36 (0,00)
20:00	0,42 (0,00)	0,45 (0,00)	0,42 (0,00)	0,50 (0,00)	0,45 (0,00)	0,57 (0,00)	0,39 (0,00)
20:30	0,47 (0,00)	0,46 (0,00)	0,44 (0,00)	0,48 (0,00)	0,45 (0,00)	0,65 (0,00)	0,42 (0,00)
21:00	0,46 (0,00)	0,49 (0,00)	0,42 (0,00)	0,45 (0,00)	0,47 (0,00)	0,66 (0,00)	0,43 (0,00)
21:30	0,41 (0,00)	0,48 (0,00)	0,44 (0,00)	0,53 (0,00)	0,47 (0,00)	0,66 (0,00)	0,35 (0,00)
22:00	0,36 (0,00)	0,46 (0,00)	0,54 (0,00)	0,50 (0,00)	0,45 (0,00)	0,59 (0,00)	0,33 (0,00)
22:30	0,39 (0,00)	0,44 (0,00)	0,53 (0,00)	0,48 (0,00)	0,42 (0,00)	0,58 (0,00)	0,24 (0,00)
23:00	0,40 (0,00)	0,44 (0,00)	0,53 (0,00)	0,42 (0,00)	0,43 (0,00)	0,55 (0,00)	0,32 (0,00)

Tabel 4.6 Estimasi Parameter Model *Time Series Regression* CO SUF 1
(Lanjutan)

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
23:30	0,38 (0,00)	0,44 (0,00)	0,41 (0,00)	0,40 (0,00)	0,32 (0,00)	0,51 (0,00)	0,29 (0,00)
00:00	0,31 (0,00)	0,43 (0,00)	0,30 (0,00)	0,33 (0,00)	0,29 (0,00)	0,49 (0,00)	0,28 (0,00)

Berdasarkan estimasi parameter model *time series regression* pada variabel CO di SUF 1 diketahui bahwa koefisien dari tren memiliki nilai positif dan signifikan karena memiliki *p-value* kurang dari 0,05. Artinya semakin lama kadar CO di wilayah Kota Surabaya di sekitar SUF 1 akan semakin meningkat. Pada pukul 07.30 di hari senin memiliki nilai koefisien *time series regression* yang paling besar bila dibandingkan waktu lain. Sedangkan pukul 13.30 di hari minggu memiliki kadar CO terendah di SUF 1 berdasarkan nilai koefisiennya. Terdapat beberapa parameter *time series regression* variabel CO SUF 1 yang tidak signifikan seperti pada pukul 13.30 di hari minggu yang memiliki nilai *p-value* sebesar 0,76. Pada waktu ini nilai parameternya tidak signifikan karena nilainya mendekati 0, artinya kadar CO di SUF 1 saat nilai parameternya tidak signifikan maka nilainya mendekati 0. Hal ini dibuktikan pada Gambar 4.2. Pada peramalan tidak terlalu memperhatikan signifikansi parameter yang diperhatikan adalah akurasi dari peramalan (Amstrong, 2007). Dari estimasi parameter di Tabel 4.6 dapat dituliskan model *time series regression* seperti pada Persamaan (2.2).


Setelah dilakukan estimasi parameter pada model *time series regression*, selanjutnya dilakukan pengecekan residual dari model *time series regression* sudah *white noise* atau belum dan pengujian asumsi normalitas. Jika residual dari model *time series regression* belum *white noise* dan tidak normal, maka residual masih dapat dimodelkan.



Gambar 4.11 Plot ACF (a) dan Pengujian Normalitas (b) Residual Model *Time Series Regression* CO SUF 1

Berdasarkan Gambar 4.11 diketahui bahwa residual masih belum *white noise*, dari plot ACF terlihat bahwa hampir semua lag dari residual masih keluar batas. Artinya masih terdapat korelasi diantara residualnya. Dari pengujian distribusi normal diketahui bahwa residual dari CO di SUF 1 masih belum normal karena memiliki *p-value* kurang dari 0,01. Data yang tidak normal ini disebabkan oleh banyaknya *outlier* pada data dan diduga terdapat pola nonlinier. Karena residual masih belum *white noise* dan tidak berdistribusi normal maka residual masih dapat dimodelkan. Pada penelitian ini residual dari model *time series regression* akan dimodelkan dengan beberapa metode yaitu AR, ARMA, FFNN dan LSTM.

Gambar 4.12 merupakan perbandingan antara data aktual dan ramalan pada data *in-sample* dan *out-of-sample* pada variabel CO di SUF 1. Pada data *in-sample* hasil ramalan tidak mengikuti pola data aktual, hal ini dikarenakan model *time series regression* hanya dapat menangkap pola tren dan *double seasonal* yang berasal dari variabel *dummy* saja. Sehingga perlu untuk melakukan pemodelan dengan metode lain. Karena pemodelan dengan *time series regression* ini menghasilkan residual yang masih belum *white noise*. Pada data *out-of-sample* hasil ramalan mengikuti pola pada 2 periode awal, tetapi setelah itu hasil ramalan tidak mengikuti pola data aktual.



Gambar 4.12 Perbandingan Data Aktual dan Ramalan CO SUF 1 Menggunakan *Time Series Regression* pada Data *In-Sample* (a) dan *Out-of-Sample* (b)

Dengan cara yang sama, dilakukan pemodelan menggunakan *time series regression* pada parameter kualitas udara yang lain di 3 stasiun SUF di Kota Surabaya. Hasil yang didapatkan yaitu semua pemodelan *time series regression* pada semua parameter kualitas udara menghasilkan residual yang masih belum *white noise* dan tidak berdistribusi normal sehingga perlu untuk memodelkan residual. Nilai estimasi parameter pada parameter kualitas udara yang lain terdapat di Lampiran 2.

4.2.2. Pemodelan Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya dengan ARIMA

Pemodelan parameter kualitas udara di 3 stasiun SUF di Kota Surabaya dengan ARIMA diawali dengan melakukan identifikasi stasioneritas data. Data yang akan dimodelkan dengan ARIMA harus stasioner dalam *mean* dan *varians*. Jika data tidak stasioner dalam *mean* dilakukan *differencing* pada data dan jika data tidak stasioner dalam *varians* dilakukan transformasi. Untuk melihat stasioneritas data digunakan nilai *rounded value* optimum pada transformasi *box cox*.

Tabel 4.7 Transformasi *Box Cox*


Variabel	<i>Rounded Value</i> Optimum
CO SUF 1	-1,71
CO SUF 6	-0.94
CO SUF 7	-0,43
NO ₂ SUF 1	0,21
NO ₂ SUF 6	0,04
NO ₂ SUF 7	0,00
O ₃ SUF 1	0,31
O ₃ SUF 6	0,27
O ₃ SUF 7	-0,19
PM ₁₀ SUF 1	0,00
PM ₁₀ SUF 6	0,27
PM ₁₀ SUF 7	0,41
SO ₂ SUF 1	0,03
SO ₂ SUF 6	-0,10
SO ₂ SUF 7	-0,50

Berdasarkan Tabel 4.7 diketahui bahwa semua parameter kualitas udara di 3 stasiun SUF Kota Surabaya tidak stasioner dalam *varians*. Hal ini dikarenakan nilai *rounded value* dari transformasi *box cox* tidak ada yang bernilai 1. Selain melihat stasioneritas dalam *varians* juga mengecek stasioneritas dalam *mean*. Salah satu cara yang dapat digunakan untuk melihat data

stasioner dalam *mean* adalah dengan melihat *time series plot*. Berdasarkan Gambar 4.1, Gambar 4.3, Gambar 4.5, Gambar 4.7 dan Gambar 4.9 bisa diketahui bahwa parameter kualitas udara CO, NO₂, O₃, PM₁₀ dan SO₂ di tiga SUF Kota Surabaya masih belum stasioner. Masih terdapat tren pada data, selain itu juga pada periode harian dan mingguan data masih belum stasioner. Ditunjukkan oleh Gambar 4.2, Gambar 4.4, Gambar 4.6, Gambar 4.8 dan Gambar 4.10 bahwa terdapat perbedaan rata-rata untuk setiap setengah jam dan hari. Karena data semua parameter kualitas udara di 3 stasiun SUF belum stasioner maka dilakukan transformasi. Selain itu juga dilakukan *differencing* pada *lag* non musiman yaitu *lag* 1 serta *lag* musiman yaitu *lag* 48 dan *lag* 336.

Identifikasi order dari ARIMA dilakukan dengan melihat plot ACF dan PACF dari data. Gambar 4.13 merupakan plot ACF dan PACF dari variabel CO di SUF 1 Kota Surabaya. Berdasarkan Gambar 4.13 dugaan awal model ARIMA untuk CO di SUF 1 adalah ARIMA(0,1,1)(0,1,1)⁴⁸(0,1,1)³³⁶. Model ini merupakan model dugaan awal pada semua parameter kualitas udara di tiga stasiun SUF Kota Surabaya. Setelah didapatkan model ARIMA untuk CO di SUF 1 maka dilakukan pengujian asumsi residual.

Residual dari model ARIMA(0,1,1)(0,1,1)⁴⁸(0,1,1)³³⁶ pada parameter CO di SUF 1 masih belum *white noise*. Oleh karena itu dilakukan kembali pemodelan dengan memasukan orde MA non musiman. Orde MA non musiman yang digunakan dibatasi hingga *lag* 48. Orde MA ditentukan berdasarkan *lag* ACF yang signifikan. Beberapa *lag* pada ACF yang signifikan adalah *lag* 2, 3, 4, 5, 6, 7, 8, 9, 12, 13, 22, 32, 42, 45, 46, 47, 48. Sehingga model ARIMA baru tahap kedua yang didapatkan adalah ARIMA(0,1,[1,2,3,4,5,6,7,8,9,12,13,22,32,42,45,46,47,48])(0,1,1)⁴⁸(0,1,1)³³⁶. Pada model tahap kedua ini dihasilkan model yang hampir *white noise*.



Gambar 4.13 Plot ACF (a) dan PACF (b) CO SUF 1

Pemodelan ARIMA dalam penelitian ini digunakan nilai $\alpha = 10\%$. Dari model tahap kedua dari CO di SUF 1 terdapat beberapa parameter yang tidak signifikan yaitu *lag* 13, 22, 32, 42, 45. Kelima

parameter yang tidak signifikan ini dieliminasi sehingga didapatkan model ARIMA(0,1,[1,2,3,4,5,6,7,8,9,12,46,47,48])(0,1,1)⁴⁸(0,1,1)³³⁶. Model ARIMA yang didapatkan ini masih belum *white noise*. Sehingga dimasukan orde AR non musiman berdasarkan plot PACF. Orde AR non musiman yang dimasukan merupakan beberapa *lag* signifikan pada PACF yaitu *lag* 10, 11, 13, 23, 25, 29, 32, 37 dan 43. Model ARIMA tahap keempat yang didapatkan yaitu ARIMA([10,11,13,23,25,29,32,37,43],1,[1,2,3,4,5,6,7,8,9,12,46,47,48])(0,1,1)⁴⁸(0,1,1)³³⁶. Setelah memasukan orde AR non musiman maka didapatkan model ARIMA dari CO SUF 1 sudah *white noise*.

Tabel 4.8 Hasil Pengujian Asumsi Residual *White Noise* Model ARIMA CO SUF 1

<i>Lag</i>	<i>Chi-Square</i>	Df	<i>P-Value</i>
30	10,21	6	0,12
36	12,72	12	0,39
42	14,79	18	0,68
48	18,62	24	0,77

Pengujian *white noise* pada model ARIMA CO di SUF 1 dapat dilakukan dengan melihat nilai *Ljung Box* dan nilai autokorelasinya. Berdasarkan nilai *Ljung Box* diketahui bahwa model sudah *white noise* karena nilainya hingga *lag* 30, 36, 42 dan 48 tidak signifikan. Selain itu juga melihat nilai autokorelasi, karena data yang digunakan cukup besar yaitu 16982 data. Jika hanya melihat nilai *Ljung Box* akan bias karena nilai statistik ujinya sangat bergantung pada jumlah sampel dan derajat bebas. Batas dari nilai autokorelasinya adalah $\pm 0,015$. Jika nilai autokorelasinya berada diluar interval $-0,015$ hingga $0,015$ maka *lag* tersebut masih terdapat autokorelasi. Berdasarkan Tabel 4.9 diketahui bahwa nilai autokorelasi hingga *lag* 48 masih berada diantara $-0,015$ hingga $0,015$ sehingga residual dari model ARIMA([10,11,13,23,25,29,32,37,43],1,[1,2,3,4,5,6,7,8,9,12,46,47,48])(0,1,1)⁴⁸(0,1,1)³³⁶ pada variabel CO SUF 1 sudah *white noise*. Tetapi dari pengujian normalitas residual masih belum normal, karena *p-value* kurang

dari 0,01. Hal ini dikarenakan banyak data yang *outlier* dan diduga data memiliki pola nonlinier.

Tabel 4.9 Nilai Autokorelasi Residual Model ARIMA CO SUF 1

<i>Lag</i>	Autokorelasi					
6	-0,000	0,001	-0,000	0,003	-0,001	0,001
12	0,000	0,002	0,002	-0,001	-0,000	0,005
18	-0,000	-0,002	-0,009	-0,000	0,003	-0,006
24	0,008	-0,008	-0,001	0,011	0,000	-0,010
30	-0,000	0,004	0,004	-0,004	-0,000	-0,007
36	0,004	-0,000	-0,001	-0,008	-0,008	-0,004
42	0,000	-0,003	0,002	0,000	0,006	-0,008
48	-0,000	0,011	-0,007	0,001	0,008	0,001

Estimasi parameter model ARIMA dilakukan dengan menggunakan *conditional least square*. Nilai estimasi parameter model ARIMA dari variabel CO di SUF 1 Kota Surabaya ditunjukkan pada Tabel 4.10.

Tabel 4.10 Estimasi Parameter Model ARIMA CO SUF 1

Parameter	Estimasi	SE	<i>T-Value</i>	<i>P-Value</i>
θ_1	0,212	0.008	27,430	0,000
θ_2	0,145	0.008	18,400	0,000
θ_3	0,099	0.008	12,520	0,000
θ_4	0,066	0.008	8,210	0,000
θ_5	0,052	0.008	6,540	0,000
θ_6	0,063	0.008	7,860	0,000
θ_7	0,033	0.008	4,150	0,000

Tabel 4.10 Estimasi Parameter Model ARIMA CO SUF 1 (Lanjutan)

Parameter	Estimasi	SE	<i>T-Value</i>	<i>P-Value</i>
θ_8	0,023	0,008	2,880	0,004
θ_9	0,022	0,008	2,800	0,005
θ_{10}	0,024	0,008	3,120	0,002
θ_{11}	-0,018	0,008	-2,330	0,019
θ_{12}	-0,099	0,008	-13,040	0,000
θ_{13}	0,084	0,009	8,970	0,000
Θ_1	0,769	0,007	118,060	0,000
Ψ_1	0,766	0,005	146,180	0,000
ϕ_1	-0,016	0,008	-1,940	0,052
ϕ_2	-0,014	0,008	-1,710	0,087
ϕ_3	-0,016	0,008	-1,950	0,051
ϕ_4	-0,013	0,008	-1,720	0,085
ϕ_5	-0,015	0,008	-1,970	0,049
ϕ_6	0,014	0,008	1,760	0,079
ϕ_7	-0,018	0,008	-2,320	0,020
ϕ_8	0,013	0,008	1,670	0,096
ϕ_9	0,014	0,008	1,810	0,071

Berdasarkan Tabel 4.10 dapat dituliskan model ARIMA dari variabel CO di SUF 1 di Persamaan (4.1). Dari Tabel 4.10 diketahui bahwa semua parameter model baik AR maupun MA telah signifikan. Model persamaan dapat digunakan untuk meramalkan CO SUF 1 di Kota Surabaya yang ditunjukkan oleh Gambar 4.14.


$$\begin{aligned}
& (1+0,016B^{10} + 0,014B^{11} + 0,016B^{13} + 0,013B^{23} \\
& + 0,015B^{25} - 0,014B^{29} + 0,018B^{32} - 0,013B^{37} \\
& - 0,014B^{43})(1-B)(1-B^{48})(1-B^{336})Y_{1,t}^{1*} = \\
& \quad (1-0,212B-0,145B^2-0,099B^3-0,066B^4 \\
& \quad -0,052B^5-0,063B^6-0,033B^7-0,023B^8 \\
& \quad -0,022B^9-0,024B^{12}+0,018B^{46}+0,099B^{47} \\
& \quad -0,084B^{48})(1-0,769B^{48})(1-0,766B^{336})a_{1,t}^1
\end{aligned} \tag{4.1}$$

Sehingga didapatkan

$$\begin{aligned}
Y_{1,t}^{1*} &= Y_{1,t-1}^{1*} - 0,016Y_{1,t-10}^{1*} + 0,002Y_{1,t-11}^{1*} + 0,014Y_{1,t-12}^{1*} \\
&\quad - 0,016Y_{1,t-13}^{1*} + \dots + 0,018Y_{1,t-417}^{1*} + 0,013Y_{1,t-421}^{1*} \\
&\quad - 0,013Y_{1,t-422}^{1*} + 0,014Y_{1,t-427}^{1*} - 0,014Y_{1,t-428}^{1*} \\
&\quad + a_{1,t}^1 - 0,212a_{1,t-1}^1 - 0,145a_{1,t-2}^1 - 0,0996a_{1,t-3}^1 \\
&\quad - 0,066a_{1,t-4}^1 - \dots - 0,013a_{1,t-393}^1 - 0,01393a_{1,t-396}^1 \\
&\quad + 0,010a_{1,t-430}^1 + 0,059a_{1,t-431}^1 + 0,049a_{1,t-432}^1
\end{aligned} \tag{4.2}$$

dengan $Y_{1,t}^{1*} = \frac{1}{(Y_{1,t}^1 + 1)^{1,70}}$

Berdasarkan Gambar 4.14 hasil ramalan CO SUF 1 dengan ARIMA pada data *in-sample* telah mengikuti pola data aktual. Walaupun terdapat beberapa hasil ramalan pada data *in-sample* yang nilainya sangat jauh jika dibandingkan data aktualnya. Sedangkan hasil ramalan pada data *out-of-sample* mengikuti pola data aktual, tetapi masih terdapat jarak antara data ramalan dan data aktual di *out-of-sample*.



Gambar 4.14 Perbandingan Data Aktual dan Ramalan CO SUF 1 Menggunakan ARIMA pada Data *In-Sample* (a) dan *Out-of-Sample* (b)

Pemodelan untuk parameter kualitas udara yang lain yaitu CO, NO₂, O₃, PM₁₀ dan NO₂ pada tiga stasiun SUF dengan ARIMA dilakukan dengan cara yang sama seperti pemodelan CO di SUF 1 yaitu dengan memasukkan orde MA berdasarkan *lag* yang signifikan pada plot ACF, memasukkan orde AR berdasarkan *lag* yang signifikan pada plot PACF dan mengeluarkan *lag* yang tidak signifikan pada AR atau MA. Model ARIMA dari masing-masing parameter ditunjukkan oleh Tabel 4.11.

Tabel 4.11 Model ARIMA Masing-Masing Parameter Kualitas Udara di 3 Stasiun SUF Kota Surabaya

Variabel	Model ARIMA	Residual <i>White Noise</i>	Distribusi Normal
CO SUF 1	ARIMA([10,11,13,23,25, 29,32,37,43],1,[1,2,3,4,5,6, 7,8,9,12,46,47,48]) (0,1,1) ⁴⁸ (0,1,1) ³³⁶	Ya	Tidak
CO SUF 6	ARIMA([1,14,17,42,46,47 ,1,[2,3,4,5,6,7,8,9,11,14, 22,35,40,43])(0,1,1) ⁴⁸ (0,1,1) ³³⁶	Ya	Tidak
CO SUF 7	ARIMA([11,21,26,28,30, 39,47],1,[1,2,3,4,5,6,7,8,13 ,16,32])(0,1,1) ⁴⁸ (0,1,1) ³³⁶	Ya	Tidak
NO ₂ SUF 1	ARIMA([6,9,13,33,36,47, 48],1,[1,2,3,4,5,7,8,10,11, 18,19,20,21,24,27,29]) (0,1,1) ⁴⁸ (0,1,1) ³³⁶	Ya	Tidak
NO ₂ SUF 6	ARIMA([8,15,16,17,33,35 ,43,47,48],1,[1,2,3,4,5,6,7, 9,11,21,22,45,47])(0,1,1) ⁴⁸ (0,1,1) ³³⁶	Ya	Tidak
NO ₂ SUF 7	ARIMA([8,10,14,15,21,29 ,40,47],1,[1,2,3,4,5,6,7,9, 13,16,22,26,27,33,38,46]) (0,1,1) ⁴⁸ (0,1,1) ³³⁶	Ya	Tidak
O ₃ SUF 1	ARIMA([1,4,6,14,38,40, 43,44,45,47,48],1,[1,2,3,4, 5,6,7,8,14,25,26,31,35,43, 44,46,47])(0,1,1) ⁴⁸ (0,1,1) ³³⁶	Tidak	Tidak
O ₃ SUF 6	ARIMA([2,3,5,26,28,34, 43,44,46,47,48],1,[1,2,3,46 ,47])(0,1,1) ⁴⁸ (0,1,1) ³³⁶	Ya	Tidak

Tabel 4.11 Model ARIMA Masing-Masing Parameter Kualitas Udara di 3 Stasiun SUF Kota Surabaya (Lanjutan)


Variabel	Model ARIMA	Residual <i>White Noise</i>	Distribusi Normal
O ₃ SUF 7	ARIMA([13,16,19,24],1,[1,2,3,4,5,6,7,8,11,12,19,38,39,48])(0,1,1) ⁴⁸ (0,1,1) ³³⁶	Ya	Tidak
PM ₁₀ SUF 1	ARIMA([11,13,25,33,44,47],1,[1,2,3,4,5,6,7,8,9,10,15,16,18,19,22,23,24,27,28,32,35,40,46,47])(0,1,1) ⁴⁸ (0,1,1) ³³⁶	Ya	Tidak
PM ₁₀ SUF 6	ARIMA([1,6,14,17,33,45,46,48],1,[1,2,4,8,13,15,16,20,47])(0,1,1) ⁴⁸ (0,1,1) ³³⁶	Ya	Tidak
PM ₁₀ SUF 7	ARIMA([7,8,9,11,15,18,27,37,38,44,48],1,[1,2,3,4,5,6,10,12,14,16,21,22,23,24,41,47])(0,1,1) ⁴⁸ (0,1,1) ³³⁶	Ya	Tidak
SO ₂ SUF 1	ARIMA([1,7,15,17,18,19,20,42,43,44,45,46,47],1,[2,3,4,5,6,8,9,21,27,43,45,46,47])(0,1,1) ⁴⁸ (0,1,1) ³³⁶	Tidak	Tidak
SO ₂ SUF 6	ARIMA([5,6,7,9,10,11,12,13,14,18,23,31,38,47,48],1,[1,2,3,4,8,15,16,17,20,21,22,28,29,30,36,45,46,47])(0,1,1) ⁴⁸ (0,1,1) ³³⁶	Tidak	Tidak
SO ₂ SUF 7	ARIMA([16,23,28,38,48],1,[1,2,3,4,5,6,7,8,9,10,15,18,27,43,46])(0,1,1) ⁴⁸ (0,1,1) ³³⁶	Ya	Tidak

Berdasarkan Tabel 4.11 residual dari model ARIMA untuk lima parameter kualitas udara di tiga stasiun SUF Kota Surabaya memiliki residual yang masih belum berdistribusi normal. Selain

itu juga terdapat 3 model yang memiliki residual yang masih belum *white noise* yaitu O₃ SUF 1, SO₂ SUF 1 dan SO₂ SUF 6.

4.2.3. Pemodelan Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya dengan FFNN

Pemodelan parameter kualitas udara di 3 stasiun SUF di Kota Surabaya selain menggunakan metode klasik juga digunakan metode *machine learning* dengan menggunakan *neural network*. Salah satu metode *neural network* yang digunakan dalam penelitian ini adalah *feed forward neural network*. Salah satu komponen terpenting dalam pembentukan jaringan *neural network* adalah *input* yang digunakan.



Gambar 4.15 Feature Selection Input Neural Network Variabel CO SUF 1

Penelitian ini menggunakan satu *hidden layer* dan dicobakan *neuron* sebanyak satu hingga lima. Digunakan satu *hidden layer* karena merupakan jaringan dengan tingkat perlakuan yang fleksibel serta mampu konvergen lebih cepat untuk fungsi target linier dibandingkan jaringan *multiple hidden layer* (Nakama, 2011). Penentuan *input* jaringan didasarkan pada *lag* orde AR pada model ARIMA di sub bab 4.2.2. Tetapi tidak semua *lag* AR dari model ARIMA digunakan, dilakukan *feature selection* untuk mendapatkan *lag* yang optimum untuk *input* jaringan. Sehingga waktu komputasi lebih cepat tetapi mendapatkan hasil ramalan


yang lebih baik. Gambar 4.15 merupakan *feature selection lag* untuk *input* FFNN variabel CO SUF 1.

Feature selection dilakukan dengan memilih *lag* yang memiliki korelasi dengan data awal lebih dari ± 0.5 . Artinya *lag* yang digunakan memiliki korelasi diluar interval $-0,5$ hingga $0,5$. Berdasarkan Gambar 4.15 dari 75 *lag* AR dari model ARIMA terbaik CO SUF 1, didapatkan 17 *lag* yang digunakan sebagai *input* pada model FFNN dari CO SUF 1 yaitu *lag* 1, 23, 24, 25, 26, 44, 48, 49, 71, 72, 73, 74, 92, 336, 337, 384 dan 385. Setelah menentukan *input* dilakukan uji *White* untuk melihat data memiliki hubungan linier atau nonlinier. Berdasarkan uji *White* variabel CO SUF 1 pada Lampiran 4, CO SUF 1 memiliki hubungan linier. Pada variabel CO di SUF 1 didapatkan jumlah *neuron* optimum sebanyak 2 *neuron*. Dalam menghasilkan *neuron* optimum dicobakan 5 *neuron*. Selain itu juga digunakan fungsi aktivasi *sigmoid* pada *hidden layer* dan fungsi aktivasi linier pada *output layer*. Hasil dari proses tersebut didapatkan nilai akurasi model berupa RMSE, RMSEP, sMAPE dan sMAPEP yang dibandingkan antara data *in-sample* dan data *out-of-sample*.

Tabel 4.12 Perbandingan Nilai Akurasi Model FFNN CO SUF 1 pada Data *In-Sample* dan *Out-of-Sample*

Jumlah <i>Neuron</i>	RMSE	RMSEP	sMAPE	sMAPEP
1	0,192	0,235	16,721	15,454
2	0,191	0,225	16,703	14,773
3	0,189	0,247	16,686	14,178
4	0,188	0,272	16,682	15,066
5	0,186	0,261	16,672	12,840

Berdasarkan Tabel 4.12 diketahui bahwa nilai RMSE dan sMAPE nilainya selalu turun seiring dengan bertambahnya jumlah *neuron*. Tetapi nilai RMSEP dan sMAPEP nilainya naik turun dan tidak dipengaruhi oleh jumlah *neuron*. Sehingga dalam penentuan jumlah *neuron* optimum dalam arsitektur FFNN dipilih nilai RMSEP dan sMAPEP terkecil.



Gambar 4.16 Arsitektur FFNN CO SUF 1

Pada variabel CO SUF 1 berdasarkan Tabel 4.12, *neuron* optimum berdasarkan nilai RMSEP sebanyak 2 unit, namun berdasarkan nilai SMAPEP sebanyak 5 unit. Dipilih *neuron* sebanyak 2 unit karena nilai RMSEP dari 5 unit ke 2 unit turun

sebesar 13,84% sedangkan nilai sMAPEP hanya turun sebesar 13,08%. Pemilihan *neuron* didasarkan dari dua pemilihan kriteria yaitu RMSEP dan sMAPEP. Namun dari nilai sMAPEP sangat rentan dengan data bernilai nol, sehingga dapat memberikan hasil kesalahan yang bias. Arsitektur FFNN pada CO SUF 1 dengan 2 *neuron* dan satu *hidden layer* ditunjukkan pada Gambar 4.16.

Berdasarkan arsitektur jaringan FFNN pada Gambar 4.16 berikut merupakan estimasi parameter pembobot dari model FFNN CO SUF 1.

Tabel 4.13 Estimasi Parameter Pembobot FFNN CO SUF 1

Prediktor	Variabel	Hidden Layer		Output Layer
		Neuron 1	Neuron 2	
Input Layer	Intercept	-1,6700	-0,0003	
	Lag 1	1,7568	2,0609	
	Lag 23	-1,0287	0,8226	
	Lag 24	-0,1439	0,0650	
	Lag 25	1,0496	-0,7316	
	Lag 26	-0,0930	0,0515	
	Lag 44	-0,1329	0,2890	
	Lag 48	0,2369	-0,0219	
	Lag 49	0,4004	-0,4023	
	Lag 71	0,3537	-0,1477	
	Lag 72	-0,7601	0,4496	
	Lag 73	0,6667	-0,4504	
	Lag 74	-0,0929	0,0805	
	Lag 92	-0,2176	0,3372	
	Lag 336	-0,8876	1,0199	
	Lag 337	0,1182	-0,3198	
	Lag 384	-0,1359	0,3293	
Lag 385	0,2479	-0,3268		

Tabel 4.13 Estimasi Parameter Pembobot FFNN CO SUF 1 (Lanjutan)

Prediktor	Variabel	<i>Hidden Layer</i>		<i>Output Layer</i>
		<i>Neuron 1</i>	<i>Neuron 2</i>	
<i>Hidden Layer</i>	<i>Intercept</i>			-0,7041
	<i>Neuron1</i>			1,1762
	<i>Neuron2</i>			1,0325

Berdasarkan nilai estimasi parameter model FFNN pada CO SUF 1 diperoleh persamaan sebagai berikut.

$$Y_{1,t}^{1*} = -0,704 + 1,176f(x_1) + 1,033f(x_2) \quad (4.3)$$

dengan $Y_{1,t}^{1*} = \frac{Y_t - \min(Y_t)}{\max(Y_t) - \min(Y_t)}$

Berikut merupakan persamaan masing-masing *neuron* pada *hidden layer*.

$$\begin{aligned}
 f(x_1) = & (1 + \exp(-(-1,670 + 1,757Y_{1,t-1}^{1*} - 1,029Y_{1,t-23}^{1*} \\
 & - 0,144Y_{1,t-24}^{1*} + 1,049Y_{1,t-25}^{1*} - 0,093Y_{1,t-26}^{1*} \\
 & - 0,133Y_{1,t-44}^{1*} + 0,237Y_{1,t-48}^{1*} + 0,400Y_{1,t-49}^{1*} \\
 & + 0,354Y_{1,t-71}^{1*} - 0,760Y_{1,t-72}^{1*} + 0,667Y_{1,t-73}^{1*} \\
 & - 0,093Y_{1,t-74}^{1*} - 0,218Y_{1,t-92}^{1*} - 0,888Y_{1,t-336}^{1*} \\
 & + 0,118Y_{1,t-337}^{1*} - 0,136Y_{1,t-384}^{1*} + 0,248Y_{1,t-385}^{1*})))^{-1}
 \end{aligned} \quad (4.4)$$

$$\begin{aligned}
 f(x_2) = & (1 + \exp(-(-0,0003 + 2,061Y_{1,t-1}^{1*} + 0,823Y_{1,t-23}^{1*} \\
 & + 0,065Y_{1,t-24}^{1*} - 0,732Y_{1,t-25}^{1*} + 0,052Y_{1,t-26}^{1*} \\
 & + 0,289Y_{1,t-44}^{1*} - 0,022Y_{1,t-48}^{1*} - 0,402Y_{1,t-49}^{1*} \\
 & - 0,148Y_{1,t-71}^{1*} + 0,449Y_{1,t-72}^{1*} - 0,450Y_{1,t-73}^{1*} \\
 & + 0,081Y_{1,t-74}^{1*} + 0,337Y_{1,t-92}^{1*} + 1,019Y_{1,t-336}^{1*} \\
 & - 0,319Y_{1,t-337}^{1*} + 0,329Y_{1,t-384}^{1*} - 0,327Y_{1,t-385}^{1*})))^{-1}
 \end{aligned} \quad (4.5)$$

Perhitungan hasil ramalan satu tahap kedepan dapat dilakukan dengan melakukan perhitungan $f(x_1)$ dan $f(x_2)$ pada persamaan (4.4) dan (4.5) Setelah didapatkan nilai $f(x_1)$ dan $f(x_2)$ maka dihitung nilai ramalannya. Peramalan satu tahap kedepan untuk data *out-of-sample* dari variabel CO SUF 1 digunakan *lag* 1, 23, 24, 25, 26, 44, 48, 49, 71, 72, 73, 74, 92, 336, 337, 384 dan 385 sebagai *input* sesuai dengan model pada Gambar 4.16. Dilakukan standarisasi pada *input* FFNN dengan nilai minimum sebesar 0 dan nilai maksimum sebesar 6,116. Perhitungan secara manual dijelaskan oleh persamaan sebagai berikut:

$$\begin{aligned} f(x_1) &= (1 + \exp(-(-1,670 + 1,757(0,211) - \dots \\ &\quad - 0,136(0,304) + 0,248(0,295))))^{-1} \quad (4.6) \\ &= 0,149 \end{aligned}$$


$$\begin{aligned} f(x_2) &= (1 + \exp(-(-0,0003 + 2,061(0,211) + \dots \\ &\quad + 0,329(0,304) - 0,327(0,295))))^{-1} \quad (4.7) \\ &= 0,699 \end{aligned}$$

$$\begin{aligned} \hat{Y}_{1,t}^* &= -0,704 + 1,176(0,149) + 1,033(0,699) \quad (4.8) \\ &= 0,193 \end{aligned}$$

Setelah dilakukan perhitungan maka hasil peramalan dikonversikan kembali dalam bentuk $Y_{1,t}^1$ dan didapatkan nilai sebesar 1,183. Nilai ini mendekati hasil ramalan satu tahap kedepan variabel CO SUF 1 menggunakan *software R* sebesar 1,323. Perbedaan nilai ini disebabkan oleh perbedaan jumlah angka dibelakang koma yang digunakan yang mengakibatkan perbedaan hasil.

Gambar 4.17 menunjukkan hasil ramalan CO SUF 1 dengan FFNN. Pada data *in-sample* telah mengikuti pola data aktual. Sedangkan hasil ramalan pada data *out-of-sample* mengikuti pola data aktual, tetapi masih terdapat jarak antara data ramalan dan data

aktual masih terdapat jarak. Pada periode ke 5 hasil ramalan pada data *out-of-sample* hampir sama dengan data aktual.



Gambar 4.17 Perbandingan Data Aktual dan Ramalan CO SUF 1 Menggunakan FFNN pada Data *In-Sample* (a) dan *Out-of-Sample* (b)

Penentuan arsitektur FFNN pada parameter kualitas udara lain dan di SUF lain Kota Surabaya dilakukan dengan cara yang sama dengan penentuan arsitektur FFNN pada variabel CO SUF 1. Berikut merupakan arsitektur FFNN optimum pada semua parameter kualitas udara di tiga stasiun SUF Kota Surabaya.

Tabel 4.14 Arsitektur FFNN Optimum

Variabel	Input (Lag)	Jumlah Neuron di Hidden Layer
CO SUF 1	1, 23 , 24 , 25 , 26, 44, 48, 49, 71, 72, 73, 74, 92, 336, 337, 384, 385	2
CO SUF 6	1, 2, 14, 15, 17, 18,, 42, 43, 46, 47, 48, 49, 50	3
CO SUF 7	1, 48, 49	3
NO ₂ SUF 1	1, 6, 47, 48, 49, 95, 96, 97	4
NO ₂ SUF 6	1, 47, 48, 49, 96	5
NO ₂ SUF 7	1, 8, 47, 48, 49, 95, 96, 336, 337, 383, 384, 385, 431, 432	5
O ₃ SUF 1	1, 2, 4, 5, 6, 7, 43, 44, 45, 47, 48, 49, 50, 52, 53, 92, 93, 95, 96, 97	3
O ₃ SUF 6	1, 2, 3, 45, 46, 47, 48, 49, 50, 51, 94, 95, 96, 97, 336, 383, 384, 385, 431, 432	1
O ₃ SUF 7	1, 48, 49, 336, 337, 384, 385	4
PM ₁₀ SUF 1	1	2
PM ₁₀ SUF 6	1, 2, 6, 7	2
PM ₁₀ SUF 7	1, 7, 8, 44, 45, 48, 49, 93, 96, 97	3
SO ₂ SUF 1	1, 2, 47, 94	3
SO ₂ SUF 6	1, 5, 6, 7, 8, 47, 48, 49, 53, 95, 96, 97, 336 ,337 ,383 ,384 ,385 ,431 ,432 , 433	1
SO ₂ SUF 7	1, 48, 49, 96, 97, 336, 337, 384, 385, 432	2

Berdasarkan Tabel 4.14 dapat diketahui bahwa jumlah *neuron* pada *hidden layer* untuk masing-masing variabel berbeda-beda. Terdapat 2 variabel dengan 1 *neuron*, 4 variabel dengan 2


neuron, 5 variabel dengan 3 *neuron*, 2 variabel dengan 4 *neuron* dan 2 variabel dengan 5 *neuron*.

4.2.4. Pemodelan Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya dengan LSTM

Pemodelan parameter kualitas udara di 3 stasiun SUF di Kota Surabaya dengan metode *machine learning* selain menggunakan FFNN juga digunakan metode LSTM. LSTM juga merupakan salah satu bentuk *neural network*. Salah satu komponen terpenting dalam pembentukan jaringan LSTM adalah *input* yang digunakan. Perbedaan dalam *input* FFNN dengan LSTM adalah dimensi *input* harus diubah. Pada data yang digunakan pada FFNN dimensi dari data yang digunakan adalah dua dimensi, tetapi dalam LSTM harus digunakan data tiga dimensi. Cara penambahan dimensi *input* dalam LSTM yaitu dengan menambahkan satu dimensi yang memiliki ukuran satu. Sehingga *input* yang digunakan menjadi tiga dimensi.

Penentuan *input* pada jaringan LSTM ini sama dengan FFNN. Untuk variabel CO SUF 1 didapatkan 17 *lag* yang digunakan sebagai *input* pada model LSTM dari CO SUF 1 yaitu *lag* 1, 23, 24, 25, 26, 44, 48, 49, 71, 72, 73, 74, 92, 336, 337, 384 dan 385. Dalam menghasilkan *neuron* optimum dicobakan 5 *neuron* dan digunakan satu *hidden layer*. Selain itu digunakan *adam optimization* untuk memperbarui bobot dari jaringan LSTM. Sel LSTM di *hidden layer* memiliki empat gerbang yaitu *forget gate* dengan fungsi aktivasi *sigmoid*, *input gate* dengan fungsi aktivasi *tanh*, *modulation input gate* dengan fungsi aktivasi *sigmoid* dan *output gate* dengan fungsi aktivasi *sigmoid*. Hasil dari proses tersebut didapatkan nilai akurasi model berupa RMSE, RMSEP, sMAPE dan sMAPEP yang dibandingkan antara data *in-sample* dan data *out-of-sample*.

Dari Tabel 4.15 diketahui bahwa nilai RMSE, sMAPE, RMSEP dan sMAPEP nilainya naik turun dan tidak dipengaruhi oleh jumlah *neuron*. Dalam penentuan jumlah *neuron* optimum dalam arsitektur LSTM dipilih nilai RMSEP dan sMAPEP terkecil.



Gambar 4.18 Arsitektur LSTM CO SUF 1

Pada variabel CO SUF 1 *neuron* optimum berdasarkan nilai RMSEP dan sMAPEP sebanyak 1 unit. Nilai RMSEP dan sMAPE pada jaringan LSTM dengan 1 *neuron* lebih kecil dibandingkan

dengan jumlah *neuron* yang lain. Pemilihan *neuron* di LSTM sama dengan FFNN yaitu didasarkan dari dua pemilihan kriteria yaitu RMSEP dan sMAPEP. Arsitektur LSTM pada CO SUF 1 dengan 1 *neuron* dan satu *hidden layer* ditunjukkan pada Gambar 4.18.

Tabel 4.15 Perbandingan Nilai Akurasi Model LSTM CO SUF 1 pada Data *In-Sample* dan *Out-of-Sample*

Jumlah <i>Neuron</i>	RMSE	RMSEP	sMAPE	sMAPEP
1	0,201	0,238	18,939	14,628
2	0,219	0,291	21,679	15,651
3	0,202	0,245	22,882	15,433
4	0,193	0,238	18,237	15,525
5	0,198	0,261	19,354	15,889

Berdasarkan arsitektur jaringan LSTM pada Gambar 4.18 berikut merupakan persamaan dari model LSTM pada CO SUF 1 sebagai berikut.

$$Y_{1,t}^* = 1,018 + 0,113h_{1,t} \quad (4.9)$$

$$\text{dengan } Y_{1,t}^{1*} = \frac{Y_t - \min(Y_t)}{\max(Y_t) - \min(Y_t)}$$

Berikut merupakan persamaan masing-masing *neuron* pada *hidden layer*.

$$F_{1,t} = \sigma(-0,176h_{1,t-1} + 0,348 + 1,740Y_{1,t-1}^{1*} + \dots - 0,081Y_{1,t-384}^{1*} - 0,118Y_{1,t-385}^{1*}) \quad (4.10)$$

$$\hat{C}_{1,t} = \tanh(-0,904h_{1,t-1} + 1,000 - 0,119Y_{1,t-1}^{1*} + \dots - 0,063Y_{1,t-384}^{1*} - 0,379Y_{1,t-385}^{1*}) \quad (4.11)$$

$$U_{1,t} = \sigma(0,022h_{1,t-1} - 0,297 + 1,944Y_{1,t-1}^{1*} + \dots + 0,142Y_{1,t-384}^{1*} - 0,098Y_{1,t-385}^{1*}) \quad (4.12)$$

$$C_{1,t} = F_{1,t}C_{1,t-1} + \hat{C}_{1,t}U_{1,t} \quad (4.13)$$

$$O_{1,t} = \sigma(-0,389h_{1,t-1} + 0,881 + 1,026Y_{1,t-1}^{1*} + \dots + 0,179Y_{1,t-384}^{1*} + 0,208Y_{1,t-385}^{1*}) \quad (4.14)$$

$$h_{1,t} = O_{1,t} \tanh(C_{1,t}) \quad (4.15)$$

Perhitungan hasil ramalan satu tahap kedepan dapat dilakukan dengan melakukan perhitungan nilai masing-masing tiap *input* di masing-masing *neuron* pada persamaan (4.10). Peramalan satu tahap kedepan untuk data *out-of-sample* dari variabel CO SUF 1 digunakan *lag* 1, 23, 24, 25, 26, 44, 48, 49, 71, 72, 73, 74, 92, 336, 337, 384 dan 385 sebagai *input* sesuai dengan model pada Gambar 4.16. Dilakukan standarisasi pada *input* LSTM dengan nilai minimum sebesar 0 dan nilai maksimum sebesar 6,116. Perhitungan secara manual dijelaskan oleh persamaan sebagai berikut:

$$F_{1,t} = \sigma(-0,176(0) + 0,348 + 1,740(0,211) + \dots - 0,081(0,304) - 0,118(0,295)) = 0,901 \quad (4.16)$$

$$\hat{C}_{1,t} = \tanh(-0,904(0) + 1,000 - 0,119(0,211) + \dots - 0,063(0,304) - 0,379(0,295)) = 1 \quad (4.17)$$

$$U_{1,t} = \sigma(0,022(0) - 0,297 + 1,944(0,211) + \dots + 0,142(0,304) - 0,098(0,295)) = 0,136 \quad (4.18)$$

$$C_{1,t} = (0,901)(0) + (1)(0,136) = 0,136 \quad (4.19)$$


$$O_{1,t} = \sigma(-0,389(0) + 0,881 + 1,026(0,211) + \dots + 0,179(0,304) + 0,208(0,295)) = 0,999 \quad (4.20)$$

$$\begin{aligned} h_{1,t} &= 0,999 \tanh(0,136) \\ &= 0,135 \end{aligned} \quad (4.21)$$


$$\begin{aligned} Y_{1,t}^{1*} &= 1,018 + 0,113(0,135) \\ &= 0,251 \end{aligned} \quad (4.22)$$

Setelah dilakukan perhitungan maka hasil peramalan menggunakan LSTM dikonversikan kembali dalam bentuk $Y_{1,t}^1$ dan didapatkan nilai sebesar 1,533. Nilai ini mendekati hasil ramalan satu tahap ke depan variabel CO SUF 1 menggunakan *software Python* sebesar 1,220. Perbedaan nilai ini disebabkan oleh perbedaan jumlah angka dibelakang koma yang digunakan yang mengakibatkan perbedaan hasil.

Gambar 4.19 menunjukkan hasil ramalan CO SUF 1 dengan LSTM. Pada data *in-sample* telah mengikuti pola data aktual. Sedangkan hasil ramalan pada data *out-of-sample* mengikuti pola data aktual, tetapi masih terdapat jarak antara data ramalan dan data aktual masih terdapat jarak. Pada data *out-of-sample* ramalan di periode ke 2, 5, 7 dan 10 mendekati nilai aktualnya.



Gambar 4.19 Perbandingan Data Aktual dan Ramalan CO SUF 1 Menggunakan LSTM pada Data *In-Sample* (a) dan *Out-of-Sample* (b)



Gambar 4.19 Perbandingan Data Aktual dan Ramalan CO SUF 1 Menggunakan LSTM pada Data *In-Sample* (a) dan *Out-of-Sample* (b) (Lanjutan)

Penentuan arsitektur LSTM pada parameter kualitas udara lain dan di SUF lain Kota Surabaya dilakukan dengan cara yang sama dengan penentuan arsitektur LSTM CO SUF 1. Berikut merupakan arsitektur LSTM optimum pada semua parameter kualitas udara di tiga stasiun SUF Kota Surabaya.

Tabel 4.16 Arsitektur LSTM Optimum

Variabel	<i>Input (Lag)</i>	Jumlah Neuron di <i>Hidden Layer</i>
CO SUF 1	1, 23 , 24 , 25 , 26, 44, 48, 49, 71, 72, 73, 74, 92, 336, 337, 384, 385	1
CO SUF 6	1, 2, 14, 15, 17, 18,, 42, 43, 46, 47, 48, 49, 50	2
CO SUF 7	1, 48, 49	2
NO ₂ SUF 1	1, 6, 47, 48, 49, 95, 96, 97	2
NO ₂ SUF 6	1, 47, 48, 49, 96	5
NO ₂ SUF 7	1, 8, 47, 48, 49, 95, 96, 336, 337, 383, 384, 385, 431, 432	5
O ₃ SUF 1	1, 2, 4, 5, 6, 7, 43, 44, 45, 47, 48, 49, 50, 52, 53, 92, 93, 95, 96, 97	1

Tabel 4.16 Arsitektur LSTM Optimum (Lanjutan)


Variabel	Input (Lag)	Jumlah Neuron di Hidden Layer
O ₃ SUF 6	1, 2, 3, 45, 46, 47, 48, 49, 50, 51, 94, 95, 96, 97, 336, 383, 384, 385, 431, 432	4
O ₃ SUF 7	1, 48, 49, 336, 337, 384, 385	3
PM ₁₀ SUF 1	1	2
PM ₁₀ SUF 6	1, 2, 6, 7	2
PM ₁₀ SUF 7	1, 7, 8, 44, 45, 48, 49, 93, 96, 97	3
SO ₂ SUF 1	1, 2, 47, 94	5
SO ₂ SUF 6	1, 5, 6, 7, 8, 47, 48, 49, 53, 95, 96, 97, 336, 337, 383, 384, 385, 431, 432, 433	2
SO ₂ SUF 7	1, 48, 49, 96, 97, 336, 337, 384, 385, 432	3

Berdasarkan Tabel 4.16 dapat diketahui bahwa jumlah *neuron* pada *hidden layer* untuk masing-masing variabel berbeda-beda. Terdapat 2 variabel dengan 1 *neuron*, 6 variabel dengan 2 *neuron*, 3 variabel dengan 3 *neuron*, 1 variabel dengan 4 *neuron* dan 3 variabel dengan 5 *neuron*. *Neuron* yang paling banyak digunakan adalah 2 *neuron*.

4.2.5. Pemodelan Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya dengan *Time Series Regression* dengan AR Error

Pemodelan parameter kualitas udara di 3 stasiun SUF di Kota Surabaya dengan *time series regression* menghasilkan residual yang masih belum *white noise*. Sehingga residual masih dapat dimodelkan. Salah satu metode yang digunakan dalam memodelkan residual dari *time series regression* pada penelitian ini menggunakan AR. Diduga masih terdapat korelasi antara residual dengan *lag* 1 dan *lag* musiman yaitu *lag* 48 dan 336. Hal

ini dikarenakan data parameter kualitas udara di 3 stasiun SUF Kota Surabaya memiliki pola *double seasonal*.



Gambar 4.20 Plot Antara Residual Model *Time Series Regression* dari CO SUF 1 dengan *Lag 1* (a), *Lag 48* (b) dan *Lag 336* (c)

Dari Gambar 4.20 diketahui bahwa plot antara residual model *time series regression* CO SUF 1 dengan *lag 1* membentuk pola linier positif yang kuat. Sehingga terdapat korelasi antara residual model *time series regression* CO SUF 1 dengan *lag 1*, hal ini ditunjukkan dengan nilai korelasi yang tinggi yaitu 0,891. Sedangkan plot antara residual model *time series regression* CO SUF 1 dengan *lag 48* dan *336* berbentuk corong, hubungan linier yang terbentuk tidak sekuat *lag 1*. Hal ini dikarenakan terdapat banyak titik pada plot yang cenderung menyebar. Nilai korelasi antara residual model *time series regression* CO SUF 1 dengan *lag 48* dan *336* yaitu 0,525 dan 0,427. Sehingga dalam menentukan orde dari model AR akan dicobakan beberapa model yaitu AR (1), AR (1)⁴⁸, AR (1)³³⁶, AR (1)(1)⁴⁸, AR (1)(1)³³⁶ dan AR (1)(1)⁴⁸(1)³³⁶. Setelah residual dimodelkan dengan beberapa model dugaan AR akan dibentuk model *time series regression* dengan AR error. Dari beberapa model dugaan AR di residual model *time series regression* akan dipilih model AR terbaik berdasarkan nilai RMSEP dan sMAPEP.

Tabel 4.17 Perbandingan Nilai Akurasi TSR dengan AR *Error* CO SUF 1 pada Data *In-Sample* dan *Out-of-Sample*

Model AR	RMSE	RMSEP	sMAPE	sMAPEP
AR(1)	0,189	0,279	17,136	14,598
AR(1) ⁴⁸	0,357	0,459	35,081	27,469
AR(1) ³³⁶	0,381	0,457	38,640	28,358
AR(1)(1) ⁴⁸	0,190	0,280	17,133	14,770
AR(1)(1)³³⁶	0,190	0,278	17,128	14,578
AR(1)(1) ⁴⁸ (1) ³³⁶	0,190	0,279	17,125	14,744

Berdasarkan nilai RMSEP dan sMAPEP model AR terbaik yang digunakan untuk memodelkan residual dari model *time series regression* CO SUF 1 Kota Surabaya adalah AR (1)(1)³³⁶. Hal ini dikarenakan nilai RMSEP dan sMAPEP dari model ini lebih kecil dibandingkan model dugaan lain. Pada variabel CO SUF 1 di Kota Surabaya ini pengaruh *lag* 1 pada model AR saat memodelkan residual *time series regression* cukup besar, bisa dilihat saat *lag* 1 tidak ada dalam model AR maka nilai RMSE, RMSEP, sMAPE dan sMAPEP menjadi sangat besar. Ini terjadi karena korelasi yang cukup besar antara residual model *time series regression* dengan *lag* 1, ditunjukkan dengan Gambar 4.20.

Tabel 4.18 Hasil Pengujian Asumsi Residual *White Noise* Model AR dari Residual *Time Series Regression* CO SUF 1

<i>Lag</i>	<i>Chi-Square</i>	Df	<i>P-Value</i>
6	117,51	4	0,00
12	185,68	10	0,00
18	241,32	16	0,00
24	336,13	22	0,00
30	440,27	28	0,00
36	485,27	34	0,00
42	561,30	40	0,00
48	908,17	46	0,00


Pengujian *white noise* pada model AR dari residual model *time series regression* variabel CO di SUF 1 dapat dilakukan dengan melihat nilai *Ljung Box*. Berdasarkan nilai *Ljung Box* diketahui bahwa model belum *white noise*. Selain itu dari pengujian normalitas residual masih belum normal, karena *p-value* kurang dari 0,01. Hal ini dikarenakan banyak data yang *outlier*. Sehingga residual dari model *time series regression* dengan AR *error* ini masih belum *white noise*.

Model AR dari residual model TSR pada variabel CO di SUF 1 ditunjukkan Persamaan (4.22). Model persamaan ini akan dijumlahkan dengan model *time series regression* sehingga dapat digunakan untuk meramalkan CO SUF 1 di Kota Surabaya yang ditunjukkan oleh Gambar 4.21.


$$(1-0,890B)(1-0,011B^{336})\alpha_{1,t}^1 = \varepsilon_{1,t}^1 \quad (4.23)$$

Sehingga didapatkan

$$\alpha_{1,t}^1 = 0,890\alpha_{1,t-1}^1 + 0,011\alpha_{1,t-336}^1 - 0,009\alpha_{1,t-337}^1 + \varepsilon_{1,t}^1 \quad (4.24)$$



Gambar 4.21 Perbandingan Data Aktual dan Ramalan CO SUF 1 Menggunakan *Time Series Regression* dengan AR *Error* pada Data *In-Sample* (a) dan *Out-of-Sample* (b)



Gambar 4.21 Perbandingan Data Aktual dan Ramalan CO SUF 1 Menggunakan *Time Series Regression* dengan *AR Error* pada Data *In-Sample* (a) dan *Out-of-Sample* (b) (Lanjutan)

Hasil ramalan CO SUF 1 menggunakan *time series regression* dengan *AR error* pada data *in-sample* telah mengikuti pola data aktual. Sedangkan hasil ramalan pada data *out-of-sample* mengikuti pola data aktual. Hasil ramalan menggunakan *time series regression* dengan *AR error* ini lebih baik dibandingkan hanya menggunakan *time series regression*.

Pemodelan untuk residual model *time series regression* dari parameter kualitas udara yang lain yaitu CO, NO₂, O₃, PM₁₀ dan SO₂ pada 3 stasiun SUF dengan AR dilakukan dengan cara yang sama seperti pemodelan residual model *time series regression* CO di SUF 1 yaitu dengan membandingkan beberapa model dugaan AR. Model AR dari masing-masing parameter ditunjukkan oleh Tabel 4.19. Berdasarkan model *time series regression* dengan *AR error* terbaik, semua parameter kualitas udara di tiga stasiun SUF Kota Surabaya nilai residualnya masih belum *white noise* dan berdistribusi normal. Dari semua model AR terbaik di residual model *time series regression* yang terbentuk pada masing-masing parameter kualitas udara terdapat orde AR non musiman 1. Artinya residual dari model *time series regression* sangat dipengaruhi oleh *lag 1* dari residual tersebut.

Tabel 4.19 Model AR Terbaik dari Residual Masing-Masing Model *Time Series Regression* dari Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya


Variabel	Model ARIMA	Residual White Noise	Distribusi Normal
CO SUF 1	AR(1)(1) ³³⁶	Tidak	Tidak
CO SUF 6	AR(1)(1) ³³⁶	Tidak	Tidak
CO SUF 7	AR(1)(1) ⁴⁸ (1) ³³⁶	Tidak	Tidak
NO ₂ SUF 1	AR(1)(1) ³³⁶	Tidak	Tidak
NO ₂ SUF 6	AR(1)(1) ⁴⁸ (1) ³³⁶	Tidak	Tidak
NO ₂ SUF 7	AR(1)(1) ³³⁶	Tidak	Tidak
O ₃ SUF 1	AR(1)	Tidak	Tidak
O ₃ SUF 6	AR(1)(1) ⁴⁸	Tidak	Tidak
O ₃ SUF 7	AR(1)(1) ³³⁶	Tidak	Tidak
PM ₁₀ SUF 1	AR(1)	Tidak	Tidak
PM ₁₀ SUF 6	AR(1)	Tidak	Tidak
PM ₁₀ SUF 7	AR(1)	Tidak	Tidak
SO ₂ SUF 1	AR(1)(1) ³³⁶	Tidak	Tidak
SO ₂ SUF 6	AR(1)(1) ³³⁶	Tidak	Tidak
SO ₂ SUF 7	AR(1)(1) ⁴⁸ (1) ³³⁶	Tidak	Tidak

4.2.6. Pemodelan Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya dengan *Time Series Regression* dengan *ARMA Error*

Pemodelan residual dari model *time series regression* menggunakan AR menghasilkan residual yang masih belum *white noise*. Pada model AR hanya menggunakan *lag* 1, *lag* 48 dan *lag* 336 saja dari residual model *time series regression*. Pada penelitian ini residual dari *time series regression* selain dimodelkan dengan AR juga dimodelkan dengan ARMA, diharapkan dapat menghasilkan residual yang *white noise* dan hasil ramalan yang lebih baik.

Dugaan awal model ARMA untuk variabel CO di SUF 1 adalah ARMA (1,0)(1,0)⁴⁸(1,0)³³⁶. Model ini merupakan model dugaan awal pada semua parameter kualitas udara di tiga stasiun SUF Kota Surabaya. Identifikasi order dari ARMA dilakukan dengan melihat plot ACF dan PACF dari data. Gambar 4.15 merupakan plot ACF dan PACF dari residual model *time series*

regression CO di SUF 1 Kota Surabaya. Setelah didapatkan model ARMA untuk CO di SUF 1 maka dilakukan pengujian asumsi residual.



Gambar 4.22 Plot ACF (a) dan PACF (b) Residual Model *Time Series Regression* CO SUF 1

Residual dari model ARMA $(1,0)(1,0)^{48}(1,0)^{336}$ pada parameter kualitas udara CO di SUF 1 masih belum *white noise*. Oleh karena itu dilakukan kembali pemodelan dengan memasukkan orde AR non musiman. Orde AR non musiman yang digunakan dibatasi hingga *lag* 48. Orde AR ditentukan berdasarkan *lag* PACF

yang signifikan. Beberapa *lag* pada PACF yang signifikan adalah *lag* 1, 2, 7, 14, 19, 28, 40 dan 44. Sehingga model ARMA baru tahap kedua yang didapatkan adalah ARMA([1,2,7,14,19,28,40, 44],0)(1,0)⁴⁸(1,0)³³⁶. Pada model tahap kedua ini dihasilkan model yang hampir *white noise*.

Digunakan nilai $\alpha=10\%$ pada pemodelan ARMA dalam penelitian ini. Dari model tahap kedua dari variabel CO di SUF 1 terdapat beberapa parameter yang tidak signifikan yaitu *lag* musiman 336. Sehingga parameter yang tidak signifikan ini dieliminasi sehingga didapatkan model ARMA([1,2,7,14,19,28, 40,44],0)(1,0)⁴⁸. Setelah dilakukan eliminasi *lag* musiman 336 model ARMA yang didapatkan masih belum *white noise*. Sehingga dimasukan orde MA non musiman berdasarkan plot ACF. Orde MA non musiman yang dimasukan merupakan beberapa *lag* signifikan pada plot ACF yaitu *lag* 4, 10, 25, 26, 36, 43, 44, 45, 46 dan 47. Model ARMA tahap keempat yang didapatkan yaitu ARMA ([1,2,7,14,19,28,40,44],[4,10,25,26,36,43,44,45,46,47])(1, 0)⁴⁸. Setelah memasukan orde MA non musiman maka didapatkan model ARMA dari CO SUF 1 sudah *white noise*.

Tabel 4.20 Hasil Pengujian Asumsi Residual *White Noise* Model ARMA Residual Model *Time Series Regression* CO SUF 1

<i>Lag</i>	<i>Chi-Square</i>	Df	<i>P-Value</i>
24	18,40	5	0,00
30	19,57	11	0,05
36	23,26	17	0,14
42	23,88	23	0,41
48	24,71	29	0,69

Pengujian *white noise* pada model ARMA CO di SUF 1 dapat dilakukan dengan melihat nilai *Ljung Box* dan nilai autokorelasinya. Berdasarkan nilai *Ljung Box* diketahui bahwa model sudah *white noise* karena nilainya hingga *lag* 30, 36, 42 dan 48 tidak signifikan tetapi hingga *lag* 24 tidak *white noise*. Karena sudah tidak signifikan maka tidak terdapat autokorelasi. Dikarenakan pada pengujian *Ljung Box* hingga *lag* 24 tidak *white*

noise, sehingga selain digunakan nilai *Ljung Box* juga melihat nilai autokorelasi, karena data yang digunakan cukup besar yaitu 16982 data. Sehingga jika hanya menggunakan *Ljung Box* hasilnya kurang bagus. Jika nilai autokorelasinya berada diluar interval -0,015 hingga 0,015 maka *lag* tersebut masih terdapat autokorelasi. Berdasarkan Tabel 4.21 diketahui bahwa nilai autokorelasi hingga *lag* 48 masih berada diantara -0,015 hingga 0,015 sehingga residual dari model ARMA $([1,2,7,14,19,28,40,44],[4,10,25,26,36,43,44,45,46,47])(1,0)^{48}$ pada residual model *time series regression* variabel CO SUF 1 sudah *white noise*. Sehingga sudah tidak terdapat autokorelasi diantar *lag-lag* nya. Tetapi dari pengujian normalitas residual masih belum normal, karena *p-value* kurang dari 0,01. Hal ini dikarenakan banyak data yang *outlier*.

Tabel 4.21 Nilai Autokorelasi Residual Model ARMA dari Residual *Time Series Regression* CO SUF 1

Lag	Autokorelasi					
6	0,001	-0,007	-0,002	0,001	0,013	0,012
12	0,014	0,004	-0,007	0,004	-0,002	0,002
18	0,006	0,002	0,004	0,005	0,003	0,006
24	0,013	0,002	-0,000	-0,001	-0,007	-0,008
30	0,001	0,001	0,001	0,007	-0,002	0,003
36	0,000	-0,010	0,006	0,003	-0,007	0,005
42	-0,002	0,003	0,001	-0,001	0,005	0,000
48	-0,000	0,001	-0,000	0,005	0,005	0,000

Estimasi parameter model ARMA dilakukan dengan menggunakan *conditional least square*. Nilai estimasi parameter model ARMA terbaik dari residual model *time series regression* variabel CO di SUF 1 Kota Surabaya ditunjukkan pada Tabel 4.22.

Tabel 4.22 Estimasi Parameter Model ARMA dari Residual Model *Time Series Regression* CO SUF 1

Parameter	Estimasi	SE	T-Value	P-Value
θ_1	-0,024	0,008	-2,940	0,003
θ_2	-0,031	0,008	-3,940	0,000
θ_3	-0,016	0,008	-2,030	0,042
θ_4	0,015	0,008	1,980	0,047
θ_5	0,030	0,008	3,950	0,000
θ_6	0,024	0,008	3,000	0,002
θ_7	0,106	0,010	10,310	0,000
θ_8	0,106	0,009	11,100	0,000
θ_9	0,089	0,09	10,140	0,000
θ_{10}	-0,005	0,008	-5,980	0,000
ϕ_1	0,850	0,008	111,060	0,000
ϕ_2	-0,068	0,008	-8,43	0,000
ϕ_3	0,028	0,005	5,560	0,000
ϕ_4	0,013	0,005	2,880	0,004
ϕ_5	0,018	0,005	3,770	0,000
ϕ_6	0,016	0,004	3,650	0,000
ϕ_7	0,010	0,005	2,090	0,037
ϕ_8	0,121	0,008	15,190	0,000
Φ_1	-0,044	0,008	-5,430	0,000


Berdasarkan Tabel 4.22 dapat dituliskan model ARMA dari residual model *time series regression* variabel CO di SUF 1 di Persamaan (4.15). Model Persamaan (4.24) ini dijumlahkan dengan model *time series regression* sehingga dapat digunakan untuk meramalkan CO SUF 1 di Kota Surabaya yang ditunjukkan oleh Gambar 4.23.

$$\begin{aligned}
& (1 - 0,850B + 0,068B^2 - 0,028B^7 - 0,013B^{14} \\
& - 0,018B^{19} - 0,016B^{28} - 0,010B^{40} - 0,121B^{44}) \quad (4.25) \\
& (1 + 0,044B^{48})a_{1,t}^1 = \\
& \quad (1 + 0,024B^4 + 0,031B^{10} + 0,016B^{25} - 0,015B^{26} \\
& \quad - 0,030B^{36} - 0,024B^{43} - 0,106B^{44} - 0,106B^{45} \\
& \quad - 0,089B^{46} + 0,005B^{47})\varepsilon_{1,t}^1
\end{aligned}$$

Sehingga didapatkan model ARMA dari residual *time series regression* CO SUF 1 sebagai berikut.

$$\begin{aligned}
a_{1,t}^1 &= 0,851a_{1,t-1}^1 - 0,068a_{1,t-2}^1 + 0,0028a_{1,t-7}^1 \\
& + \dots + 0,001a_{1,t-76}^1 + 0,001a_{1,t-88}^1 \\
& + 0,001a_{1,t-92}^1 + \varepsilon_{1,t}^1 + 0,024\varepsilon_{1,t-4}^1 \quad (4.26) \\
& + 0,031\varepsilon_{1,t-10}^1 + 0,016\varepsilon_{1,t-25}^1 + \dots \\
& - 0,106\varepsilon_{1,t-45}^1 - 0,089\varepsilon_{1,t-46}^1 \\
& + 0,049\varepsilon_{1,t-47}^1
\end{aligned}$$

Berdasarkan Gambar 4.23 hasil ramalan CO SUF 1 menggunakan *time series regression* dengan ARMA *Error* pada data *in-sample* telah mengikuti pola data aktual. Sedangkan hasil ramalan pada data *out-of-sample* mengikuti pola data aktual, tetapi masih terdapat jarak antara data ramalan dan data aktual masih terdapat jarak. Pada periode 2, 5, 7 dan 10 hasil ramalan di *out-of-sample* hampir sama dengan data aktual. Hasil ramalan dengan memodelkan residual *time series regression* CO SUF 1 menggunakan ARMA ini lebih baik bila dibandingkan menggunakan AR saja.



Gambar 4.23 Perbandingan Data Aktual dan Ramalan CO SUF 1 Menggunakan *Time Series Regression* dengan ARMA Error pada Data *In-Sample* (a) dan *Out-of-Sample* (b)

Pemodelan untuk residual model *time series regression* dari parameter kualitas udara yang lain yaitu CO, NO₂, O₃, PM₁₀ dan SO₂ pada 3 stasiun SUF dengan ARMA dilakukan dengan cara yang sama seperti pemodelan residual model *time series regression* CO di SUF 1. Model ARMA dari masing-masing residual model *time series regression* ditunjukkan oleh Tabel 4.23.

Tabel 4.23 Model ARMA Terbaik dari Residual Masing-Masing Model *Time Series Regression* dari Parameter Kualitas Udara di 3 Stasiun SUF Kota Surabaya

Variabel	Model ARMA	Residual <i>White Noise</i>	Distribusi Normal
CO SUF 1	ARMA([1,2,7,14,19,28,40,44],[4,10,25,26,36,43,44,45,46,47])(1,0) ⁴⁸	Ya	Tidak
CO SUF 6	ARMA([1,2,4,5,6,7,8,9,10,12,15,18,19,23,24,35,39,40,43,46,47],[29,42,43,46,47])(1,0) ³³⁶	Ya	Tidak
CO SUF 7	ARMA([1,9,19,21,28,29,45,47],[7,24,37,41,47])(1,0) ⁴⁸ (1,0) ³³⁶	Ya	Tidak
NO ₂ SUF 1	ARMA([1,2,4,9,10,21,23,34,45,47],[6,7,12,14,16,18,23,25,27,32,39,45,46,47])(1,0) ⁴⁸	Ya	Tidak
NO ₂ SUF 6	ARMA([1,2,3,33,39,44,47],[7,8,10,11,12,17,45,46,47])(1,0) ⁴⁸	Ya	Tidak
NO ₂ SUF 7	ARMA([1,2,3,6,20,34,46],[3,6,7,34,35,36,37,43,46,47])(1,0) ⁴⁸ (1,0) ³³⁶	Ya	Tidak
O ₃ SUF 1	ARMA(1,[1,2,3,4,5,6,7,8,11,13,20,22,23,26,30,35,37,38,40,43,44,45,47])(1,0) ⁴⁸ (1,0) ³³⁶	Tidak	Tidak
O ₃ SUF 6	ARMA([1,3,6,38,42,47],[1,2,5,10,11,37,47])(1,0) ⁴⁸	Ya	Tidak
O ₃ SUF 7	ARMA([1,2,10,42,44,45,46,47],[6,38,47])(1,0) ⁴⁸ (1,0) ³³⁶	Ya	Tidak

Tabel 4.23 Model ARMA Terbaik dari Residual Masing-Masing Model *Time Series Regression* dari Parameter Kualitas Udara di 3 Stasiun SUF Kota Surabaya (Lanjutan)


Variabel	Model ARMA	Residual <i>White Noise</i>	Distribusi Normal
PM ₁₀ SUF 1	ARMA([1,5,6,12,13,14,16,17,18,19,21,22,23,24,26,31,33,35,40],[8,11,37,38,39,40,41,42,43,44,45])(1,0) ⁴⁸	Ya	Tidak
PM ₁₀ SUF 6	ARMA([1,2,3,12,15,16,17,45,46],[3,4,12,16,18,31])(1,0) ³³⁶	Ya	Tidak
PM ₁₀ SUF 7	ARMA([1,6,7,10,11,12,13,41],[1,24,45])(1,0) ⁴⁸	Ya	Tidak
SO ₂ SUF 1	ARMA([3,6,14,15,19,21,27,40,44,46,47],[1,2,3,4,5,7,8,9,10,11,12,13,45,46,47])(1,0) ⁴⁸	Ya	Tidak
SO ₂ SUF 6	ARMA([1,2,7,17,36,39,43,45,46,47],[3,4,5,6,38,46,47])(1,0) ⁴⁸	Ya	Tidak
SO ₂ SUF 7	ARMA([1,2,3,4,5,6,7,21,39,44,47],[7,14,43])(1,0) ⁴⁸	Ya	Tidak

Berdasarkan Tabel 4.23 diperoleh model ARMA terbaik dari residual masing-masing model *time series regression*. Diketahui bahwa seluruh model ARMA terbaik pada residual model *time series regression* telah *white noise* kecuali pada variabel O₃ SUF 1. Dari semua model ARMA terbaik yang didapatkan residualnya masih belum berdistribusi normal. Hal ini dikarenakan terdapat banyak data yang *outlier*.

4.2.7. Pemodelan Parameter Kualitas Udara di 3 Stasiun SUF Kota Surabaya dengan Hibrida *Time Series Regression* dan FFNN

Pemodelan parameter kualitas udara di 3 stasiun SUF di Kota Surabaya menggunakan *time series regression* menghasilkan residual yang masih belum *white noise* sehingga masih dapat dimodelkan. Sebelumnya residual dari *time series regression* dimodelkan secara linier dengan AR dan ARMA. Selain itu dalam penelitian ini residual juga dimodelkan secara non linier dengan *machine learning* sehingga didapatkan model hibrida. Salah satu metode yang digunakan adalah FFNN.

Penelitian ini menggunakan satu *hidden layer* dan dicobakan *neuron* sebanyak satu hingga lima. Penentuan *input* jaringan didasarkan pada *lag* orde AR dari residual *time series regression* yang dimodelkan dengan ARMA di sub bab 4.2.6. Juga dilakukan *feature selection* untuk memilih *lag* AR dari model ARMA. Berikut merupakan *feature selection lag* untuk *input* FFNN residual model *time series regression* CO SUF 1.



Gambar 4.24 *Feature Selection Input Neural Network Residual Model Time Series Regression* CO SUF 1

Feature selection dilakukan dengan memilih *lag* yang memiliki korelasi dengan data awal lebih dari ± 0.5 . Artinya *lag* yang digunakan memiliki korelasi diluar interval $-0,5$ hingga $0,5$.


Berdasarkan Gambar 4.24 dari 17 lag AR dari model ARMA terbaik residual *time series regression* CO SUF 1, didapatkan 6 lag yang digunakan sebagai *input* pada model FFNN dari CO SUF 1 yaitu lag 1, 2, 7, 48, 49 dan 50. Pada residual *time series regression* CO di SUF 1 didapatkan jumlah *neuron* optimum sebanyak 4 *neuron*. Dalam menghasilkan *neuron* optimum dicobakan 5 *neuron*. Selain itu juga digunakan fungsi aktivasi sigmoid pada *hidden layer* dan fungsi aktivasi linier pada *output layer*. Hasil pemodelan residual dengan FFNN ini akan dijumlahkan dengan pemodelan menggunakan *time series regression*. Hasil dari proses tersebut didapatkan nilai akurasi model berupa RMSE, RMSEP, sMAPE dan sMAPEP yang dibandingkan antara data *in-sample* dan data *out-of-sample*.

Berdasarkan Tabel 4.24 diketahui bahwa nilai RMSE nilainya selalu turun seiring dengan bertambahnya jumlah *neuron*. Tetapi nilai RMSEP dan sMAPEP nilainya naik turun dan tidak dipengaruhi oleh jumlah *neuron*. Sehingga dalam penentuan jumlah *neuron* optimum dalam arsitektur FFNN dipilih nilai RMSEP dan sMAPEP terkecil.

Tabel 4.24 Perbandingan Nilai Akurasi Model Hibrida *Time Series Regression* dan FFNN CO SUF 1 pada Data *In-Sample* dan *Out-of-Sample*

Jumlah <i>Neuron</i>	RMSE	RMSEP	sMAPE	sMAPEP
1	0,187	0,277	16,760	14,456
2	0,183	0,262	16,712	13,677
3	0,182	0,264	16,743	13,582
4	0,182	0,260	16,792	13,529
5	0,179	0,262	16,751	14,019

Pada variabel CO SUF 1 berdasarkan Tabel 4.24, *neuron* optimum berdasarkan nilai RMSEP dan sMAPEP sebanyak 4 unit. Pemilihan *neuron* didasarkan dari dua pemilihan kriteria yaitu RMSEP dan sMAPEP. Arsitektur FFNN dari model hibrida CO SUF 1 dengan 4 *neuron* dan satu *hidden layer* ditunjukkan pada Gambar 4.25.



Gambar 4.25 Arsitektur FFNN dari Model Hibrida CO SUF 1

Berdasarkan arsitektur jaringan FFNN pada Gambar 4.25 diperoleh persamaan sebagai berikut. Persamaan berikut merupakan komponen nonlinier dari model hibrida *time series regression* dengan FFNN.

$$N_{1t}^* = 0,170 - 0,777f(x_1) + 1,275f(x_2) - 0,643f(x_3) - 0,467f(x_4) \quad (4.27)$$

$$\text{dengan } N_{1,t}^{1*} = \frac{N_t - \min(N_t)}{\max(N_t) - \min(N_t)}$$

Berikut merupakan persamaan masing-masing *neuron* pada *hidden layer*.


$$\begin{aligned} f(x_1) = & (1 + \exp(-(-1,280 + 0,192N_{1,t-1}^{1*} - 0,154N_{1,t-2}^{1*} \\ & - 2,001N_{1,t-7}^{1*} + 0,361N_{1,t-48}^{1*} - 0,156N_{1,t-49}^{1*} \\ & + 1,498N_{1,t-50}^{1*})))^{-1} \end{aligned} \quad (4.28)$$

$$\begin{aligned} f(x_2) = & (1 + \exp(-(-0,403 + 0,324N_{1,t-1}^{1*} + 1,222N_{1,t-2}^{1*} \\ & + 0,449N_{1,t-7}^{1*} - 1,655N_{1,t-48}^{1*} - 0,434N_{1,t-49}^{1*} \\ & + 2,113N_{1,t-50}^{1*})))^{-1} \end{aligned} \quad (4.29)$$

$$\begin{aligned} f(x_3) = & (1 + \exp(-(-1,029 - 6,408N_{1,t-1}^{1*} + 3,952N_{1,t-2}^{1*} \\ & + 2,714N_{1,t-7}^{1*} - 3,928N_{1,t-48}^{1*} - 1,124N_{1,t-49}^{1*} \\ & + 3,238N_{1,t-50}^{1*})))^{-1} \end{aligned} \quad (4.30)$$

$$\begin{aligned} f(x_4) = & (1 + \exp(-(-2,253 + 5,486N_{1,t-1}^{1*} - 8,341N_{1,t-2}^{1*} \\ & - 2,959N_{1,t-7}^{1*} - 5,846N_{1,t-48}^{1*} + 1,982N_{1,t-49}^{1*} \\ & + 1,249N_{1,t-50}^{1*})))^{-1} \end{aligned} \quad (4.31)$$

Gambar 4.26 menunjukkan hasil ramalan CO SUF 1 dengan hibrida *time series regression* dan FFNN. Pada data *in-sample* telah mengikuti pola data aktual. Sedangkan hasil ramalan pada data *out-of-sample* mengikuti pola data aktual, tetapi masih terdapat jarak antara data ramalan dan data aktual masih terdapat jarak. Pada periode 2, 5, 6, 7 dan 10 hasil ramalan di *out-of-sample* hampir sama dengan data aktual.



Gambar 4.26 Perbandingan Data Aktual dan Ramalan CO SUF 1 Menggunakan Hibrida *Time Series Regression* dan FFNN pada Data *In-Sample* (a) dan *Out-of-Sample* (b)

Penentuan arsitektur FFNN untuk model hibrida pada parameter kualitas udara lain di SUF lain Kota Surabaya dilakukan dengan cara yang sama dengan penentuan arsitektur model hibrida *time series regression* dan FFNN CO SUF 1. Berikut merupakan arsitektur model hibrida *time series regression* dan FFNN optimum pada semua parameter kualitas udara di 3 stasiun SUF Kota Surabaya.

Tabel 4.25 Arsitektur Model Hibrida *Time Series Regression* dan FFNN Optimum

Variabel	Input (Lag)	Jumlah Neuron di Hidden Layer
CO SUF 1	1, 2, 7, 48, 49, 50	4
CO SUF 6	1, 2, 4, 5, 6, 7, 8, 9, 10, 12, 15, 18, 19, 23, 34, 35, 39, 40, 43, 47	4
CO SUF 7	1, 9, 47, 48, 49	2
NO ₂ SUF 1	1, 2, 4, 47, 48	3
NO ₂ SUF 6	1, 2, 3	2
NO ₂ SUF 7	1, 2, 3, 6, 46, 48, 49, 50, 51, 94	4
O ₃ SUF 1	1, 48, 49, 336, 337, 384, 385	4
O ₃ SUF 6	1, 3	3
O ₃ SUF 7	1, 2	5
PM ₁₀ SUF 1	1, 5, 6	3
PM ₁₀ SUF 6	1, 2, 3, 12	3
PM ₁₀ SUF 7	1, 6, 7	5
SO ₂ SUF 1	1, 47	3
SO ₂ SUF 6	1, 2, 7, 39, 43, 45, 46, 47, 48, 49, 50, 91, 93, 94, 95	4
SO ₂ SUF 7	1, 2, 3, 4, 5	4

Dari Tabel 4.25 dapat diketahui bahwa jumlah *neuron* pada *hidden layer* model FFNN untuk masing-masing variabel berbeda-beda. Terdapat 2 variabel dengan 2 *neuron*, 5 variabel dengan 3 *neuron*, 6 variabel dengan 4 *neuron* dan 2 variabel dengan 5 *neuron*.

4.2.8. Pemodelan Parameter Kualitas Udara di 3 Stasiun SUF Kota Surabaya dengan Hibrida *Time Series Regression* dan LSTM


Pemodelan residual dari model *time series regression* secara non linier selain menggunakan FFNN juga digunakan LSTM. Penentuan *input* pada jaringan LSTM di model hibrida ini sama dengan model hibrida *time series regression* dan FFNN. Untuk residual model *time series regression* CO SUF 1 didapatkan 6 *lag* yang digunakan sebagai *input* pada model LSTM yaitu *lag* 1, 2, 7, 48, 49 dan 50. Dalam menghasilkan *neuron* optimum dicobakan 5 *neuron* dan digunakan satu *hidden layer*. Selain itu digunakan *adam optimization* untuk memperbarui bobot dari jaringan LSTM. Sel LSTM di *hidden layer* memiliki empat gerbang yaitu *forget gate* dengan fungsi aktivasi *sigmoid*, *input gate* dengan fungsi aktivasi *tanh*, *modulation input gate* dengan fungsi aktivasi *sigmoid* dan *output gate* dengan fungsi aktivasi *sigmoid*. Hasil pemodelan residual menggunakan LSTM ini akan dijumlahkan dengan pemodelan menggunakan *time series regression*. Hasil dari proses tersebut didapatkan nilai akurasi model berupa RMSE, RMSEP, sMAPE dan sMAPEP yang dibandingkan antara data *in-sample* dan data *out-of-sample*.

Tabel 4.26 Perbandingan Nilai Akurasi Model Hibrida *Time Series Regression* dan LSTM CO SUF 1 pada Data *In-Sample* dan *Out-of-Sample*

Jumlah <i>Neuron</i>	RMSE	RMSEP	sMAPE	sMAPEP
1	0,187	0,284	16,943	14,552
2	0,192	0,258	19,515	15,023
3	0,186	0,273	17,223	14,561
4	0,187	0,267	17,249	14,930
5	0,186	0,267	17,259	14,492

Dari Tabel 4.26 diketahui bahwa nilai RMSE, sMAPE, RMSEP dan sMAPEP nilainya naik turun dan tidak dipengaruhi oleh jumlah *neuron*. Dalam penentuan jumlah *neuron* optimum

dalam arsitektur LSTM di model hibrida ini dipilih nilai RMSEP dan sMAPEP terkecil.



Gambar 4.27 Arsitektur LSTM dari Model Hibrida CO SUF 1

Pada residual model *time series regression* CO SUF 1 *neuron* optimum berdasarkan nilai RMSEP sebanyak 2 unit dan berdasarkan nilai sMAPE sebanyak 5 unit. Dipilih *neuron* sebanyak 5 unit karena nilai sMAPEP dari 2 unit ke 5 unit turun sebesar 3,53% sedangkan nilai RMSEP hanya turun sebesar 3,35%. Pemilihan *neuron* di LSTM sama dengan FFNN yaitu didasarkan dari dua pemilihan kriteria yaitu RMSEP dan sMAPEP. Arsitektur LSTM dari model hibrida CO SUF 1 dengan 5 *neuron* dan satu *hidden layer* ditunjukkan pada Gambar 4.27.

Berdasarkan arsitektur jaringan LSTM pada Gambar 4.27 berikut merupakan persamaan dari model LSTM pada CO SUF 1 sebagai berikut.

$$N_{1,t}^{1*} = 0,066 + 1,036h_{1,t} - 0,488h_{2,t} + 0,842h_{3,t} + 0,043h_{4,t} - 0,267h_{5,t} \quad (4.32)$$

$$\text{dengan } N_{1,t}^{1*} = \frac{N_t - \min(N_t)}{\max(N_t) - \min(N_t)}$$

Berikut merupakan persamaan *neuron* 1 pada *hidden layer*. Untuk persamaan pada *neuron* 2 hingga 5 sama yang membedakan nilai estimasi parameternya. Nilai estimasi parameter untuk semua *neuron* model LSTM ada di Lampiran 10

$$\begin{aligned} F_{1,t} = & \sigma(-0,195h_{1,t-1} + 0,210h_{2,t-1} - 0,680h_{3,t-1} \\ & + 0,039h_{4,t-1} - 0,142h_{5,t-1} + 0,110 + 0,868N_{1,t-1}^{1*} \\ & + \dots - 0,445N_{1,t-50}^{1*}) \end{aligned} \quad (4.33)$$

$$\begin{aligned} \hat{C}_{1,t} = & \tanh(-0,118h_{1,t-1} - 0,176h_{2,t-1} + 0,023h_{3,t-1} \\ & + 0,342h_{4,t-1} + 0,154h_{5,t-1} + 0,285 + 1,112N_{1,t-1}^{1*} \\ & + \dots - 0,017N_{1,t-50}^{1*}) \end{aligned} \quad (4.34)$$

$$\begin{aligned} U_{1,t} = & \sigma(-0,209h_{1,t-1} + 0,133h_{2,t-1} - 0,008h_{3,t-1} \\ & + 0,089h_{4,t-1} + 0,077h_{5,t-1} - 0,054 + 0,535N_{1,t-1}^{1*} \\ & + \dots + 0,093N_{1,t-50}^{1*}) \end{aligned} \quad (4.35)$$


$$C_{1,t} = F_{1,t}C_{1,t-1} + \hat{C}_{1,t}U_{1,t} \quad (4.36)$$

$$\begin{aligned} O_{1,t} = & \sigma(-0,074h_{1,t-1} + 0,193h_{2,t-1} - 0,094h_{3,t-1} \\ & - 0,211h_{4,t-1} + 0,274h_{5,t-1} - 0,801 - 0,099N_{1,t-1}^{1*} \\ & + \dots - 0,876N_{1,t-50}^{1*}) \end{aligned} \quad (4.37)$$

$$h_{1,t} = O_{1,t} \tanh(C_{1,t}) \quad (4.38)$$

Gambar 4.28 menunjukkan hasil ramalan CO SUF 1 dengan LSTM. Pada data *in-sample* telah mengikuti pola data aktual. Sedangkan hasil ramalan pada data *out-of-sample* mengikuti pola data aktual, tetapi masih terdapat jarak antara data ramalan dan data

aktual. Ramalan pada periode 2, 5, 6, 7 dan 10 pada data *out-of-sample* hampir sama dengan data aktual.



Gambar 4.28 Perbandingan Data Aktual dan Ramalan CO SUF 1 Menggunakan Hibrida *Time Series Regression* dan LSTM pada Data *In-Sample* (a) dan *Out-of-Sample* (b)

Penentuan arsitektur LSTM pada parameter kualitas udara lain dan di SUF lain Kota Surabaya dilakukan dengan cara yang sama dengan penentuan arsitektur LSTM CO SUF 1. Berikut merupakan arsitektur LSTM optimum pada semua parameter kualitas udara di 3 stasiun SUF Kota Surabaya.

Tabel 4.27 Arsitektur Model Hibrida *Time Series Regression* dan LSTM Optimum

Variabel	Input (Lag)	Jumlah Neuron di Hidden Layer
CO SUF 1	1, 2, 7, 48, 49, 50	5
CO SUF 6	1, 2, 4, 5, 6, 7, 8, 9, 10, 12, 15, 18, 19, 23, 34, 35, 39, 40, 43, 47	1
CO SUF 7	1, 9, 47, 48, 49	3
NO ₂ SUF 1	1, 2, 4, 47, 48	3
NO ₂ SUF 6	1, 2, 3	3
NO ₂ SUF 7	1, 2, 3, 6, 46, 48, 49, 50, 51, 94	2
O ₃ SUF 1	1, 48, 49, 336, 337, 384, 385	1
O ₃ SUF 6	1, 3	2
O ₃ SUF 7	1, 2	5
PM ₁₀ SUF 1	1, 5, 6	4
PM ₁₀ SUF 6	1, 2, 3, 12	5
PM ₁₀ SUF 7	1, 6, 7	5
SO ₂ SUF 1	1, 47	3
SO ₂ SUF 6	1, 2, 7, 39, 43, 45, 46, 47, 48, 49, 50, 91, 93, 94, 95	1
SO ₂ SUF 7	1, 2, 3, 4, 5	1

Berdasarkan Tabel 4.25 dapat diketahui bahwa jumlah *neuron* pada *hidden layer* untuk masing-masing variabel berbeda-beda. Terdapat 4 variabel dengan 1 *neuron*, 2 variabel dengan 2 *neuron*, 4 variabel dengan 3 *neuron*, 1 variabel dengan 4 *neuron* dan 4 variabel dengan 5 *neuron*.

4.3. Perbandingan Keباikan Model

Setelah diperoleh model terbaik setiap metode pada lima parameter kualitas udara di tiga stasiun SUF, maka dilakukan perbandingan pada tujuh metode yang digunakan dalam penelitian ini. Selanjutnya dipilih satu metode terbaik berdasarkan nilai kesalahan peramalan terkecil pada data *out-of-sample*. Berikut

merupakan perbandingan akurasi tiap metode pada lima parameter kualitas udara di tiga stasiun SUF.

Tabel 4.28 Perbandingan Nilai Akurasi Setiap Model pada Data *In-Sample* dan *Out-of-Sample*

Variabel	Metode	<i>In-Sample</i>		<i>Out-of-Sample</i>	
		RMSE	RMSEP	sMAPE	sMAPEP
CO SUF1	TSR	0,417	0,586	44,682	34,801
	ARIMA	0,253	0,342	19,268	20,174
	FFNN	0,191	0,225	16,703	14,773
	LSTM	0,201	0,238	18,939	14,628
	TSR dengan AR Error	0,190	0,279	17,128	14,578
	TSR dengan ARMA Error	0,184	0,268	16,597	15,097
	Hibrida TSR dan FFNN	0,182	0,260	16,792	13,529
	Hibrida TSR dan LSTM	0,186	0,267	17,260	14,493
CO SUF6	TSR	1,068	1,173	73,658	46,598
	ARIMA	2,877	0,474	46,934	12,607
	FFNN	0,568	0,521	44,183	13,117
	LSTM	0,613	0,430	55,824	9,754
	TSR dengan AR Error	0,674	0,672	50,306	15,951
	TSR dengan ARMA Error	0,554	0,474	45,233	12,607
	Hibrida TSR dan FFNN	0,525	0,469	45,242	12,580
	Hibrida TSR dan LSTM	0,606	0,400	52,107	10,431

Tabel 4.28 Perbandingan Nilai Akurasi Setiap Model pada Data *In-Sample* dan *Out-of-Sample* (Lanjutan)

Variabel	Metode	<i>In-Sample</i>		<i>Out-of-Sample</i>	
		RMSE	RMSEP	sMAPE	sMAPEP
CO SUF7	TSR	0,919	1,125	73,233	200
	ARIMA	0,487	0,016	45,256	200
	FFNN	0,433	0,038	50,63	200
	LSTM	0,443	0,054	50,725	200
	TSR dengan AR Error	0,418	0,132	46,764	200
	TSR dengan ARMA Error	0,409	0,202	42,485	200
	Hibrida TSR dan FFNN	0,408	0,091	42,900	200
	Hibrida TSR dan LSTM	0,435	0,006	39,992	200
NO ₂ SUF1	TSR	13,548	7,044	48,573	56,408
	ARIMA	8,369	5,240	26,189	46,799
	FFNN	6,536	3,890	21,854	37,595
	LSTM	6,713	3,619	22,116	40,097
	TSR dengan AR Error	6,619	4,648	22,732	41,940
	TSR dengan ARMA Error	6,385	4,362	22,190	41,436
	Hibrida TSR dan FFNN	6,338	4,525	21,946	43,946
	Hibrida TSR dan LSTM	6,456	4,418	22,950	43,992

Tabel 4.28 Perbandingan Nilai Akurasi Setiap Model pada Data *In-Sample* dan *Out-of-Sample* (Lanjutan)

Variabel	Metode	RMSE	RMSEP	sMAPE	sMAPEP
NO ₂ SUF6	TSR	12,002	13,300	65,187	60,197
	ARIMA	12,785	11,559	45,377	41,073
	FFNN	5,603	8,050	37,817	32,151
	LSTM	5,726	8,428	37,857	34,084
	TSR dengan AR Error	5,446	7,683	37,931	28,803
	TSR dengan ARMA Error	5,315	7,616	36,867	31,505
	Hibrida TSR dan FFNN	5,311	6,667	37,500	26,625
	Hibrida TSR dan LSTM	5,393	7,149	37,000	27,758
NO ₂ SUF7	TSR	17,068	10,854	46,043	22,048
	ARIMA	8,647	6,976	15,354	14,048
	FFNN	7,554	7,384	14,552	14,340
	LSTM	7,994	6,771	15,067	12,774
	TSR dengan AR Error	7,933	5,894	17,352	11,276
	TSR dengan ARMA Error	7,652	7,085	15,733	14,380
	Hibrida TSR dan FFNN	7,452	6,944	14,941	13,327
	Hibrida TSR dan LSTM	7,737	6,987	16,704	13,881

Tabel 4.28 Perbandingan Nilai Akurasi Setiap Model pada Data *In-Sample* dan *Out-of-Sample* (Lanjutan)

Variabel	Metode	RMSE	RMSEP	sMAPE	sMAPEP
O ₃ SUF1	TSR	26,649	33,708	43,011	161,294
	ARIMA	7,779	3,811	13,033	40,733
	FFNN	6,111	3,206	10,518	58,239
	LSTM	7,096	4,106	14,862	61,969
	TSR dengan AR Error	7,733	4,209	12,051	58,154
	TSR dengan ARMA Error	7,023	5,557	12,520	66,682
	Hibrida TSR dan FFNN	7,188	4,454	12,053	62,888
	Hibrida TSR dan LSTM	7,729	4,128	14,288	63,662
O ₃ SUF6	TSR	12,395	13,944	45,344	78,959
	ARIMA	5,925	5,587	17,969	37,474
	FFNN	4,990	5,902	15,424	37,565
	LSTM	5,118	5,759	16,278	36,386
	TSR dengan AR Error	5,053	5,935	15,670	35,947
	TSR dengan ARMA Error	4,917	6,190	15,413	37,671
	Hibrida TSR dan FFNN	5,022	6,102	15,601	36,557
	Hibrida TSR dan LSTM	5,099	5,897	16,726	35,995

Tabel 4.28 Perbandingan Nilai Akurasi Setiap Model pada Data *In-Sample* dan *Out-of-Sample* (Lanjutan)

Variabel	Metode	RMSE	RMSEP	sMAPE	sMAPEP
O ₃ SUF7	TSR	11,596	4,768	43,389	38,783
	ARIMA	187,203	4,576	19,883	26,532
	FFNN	6,124	3,065	19,353	26,185
	LSTM	6,509	3,221	25,470	27,451
	TSR dengan AR Error	6,018	2,334	18,556	17,723
	TSR dengan ARMA Error	5,912	2,446	18,187	14,339
	Hibrida TSR dan FFNN	5,718	2,537	18,239	16,909
	Hibrida TSR dan LSTM	6,003	2,246	21,190	15,013
PM ₁₀ SUF1	TSR	26,047	17,770	57,208	117,714
	ARIMA	14,217	2,217	18,396	8,715
	FFNN	11,505	2,650	16,769	7,807
	LSTM	11,541	2,559	20,354	7,884
	TSR dengan AR Error	11,377	2,977	20,133	10,408
	TSR dengan ARMA Error	11,037	4,670	21,046	15,435
	Hibrida TSR dan FFNN	11,153	2,922	20,086	9,872
	Hibrida TSR dan LSTM	11,360	2,891	22,425	9,578

Tabel 4.28 Perbandingan Nilai Akurasi Setiap Model pada Data *In-Sample* dan *Out-of-Sample* (Lanjutan)

Variabel	Metode	RMSE	RMSEP	sMAPE	sMAPEP
PM ₁₀ SUF6	TSR	13,554	4,061	56,207	32,727
	ARIMA	3,554	2,439	14,576	17,688
	FFNN	3,222	0,479	11,786	3,162
	LSTM	3,348	0,487	12,464	3,152
	TSR dengan AR	3,506	0,437	12,666	3,127
	TSR dengan ARMA Error	3,247	0,599	12,083	4,619
	Hibrida TSR dan FFNN	2,643	0,396	12,263	2,727
	Hibrida TSR dan LSTM	3,348	0,561	13,902	4,844
PM ₁₀ SUF7	TSR	37,828	22,478	40,119	53,153
	ARIMA	16,747	2,907	13,782	7,752
	FFNN	13,715	1,245	9,885	3,247
	LSTM	14,558	1,534	10,336	4,066
	TSR dengan AR Error	14,578	2,959	12,019	9,375
	TSR dengan ARMA Error	14,299	4,253	11,851	13,194
	Hibrida TSR dan FFNN	14,153	0,207	11,684	0,741
	Hibrida TSR dan LSTM	14,412	2,198	13,163	7,814

Tabel 4.28 Perbandingan Nilai Akurasi Setiap Model pada Data *In-Sample* dan *Out-of-Sample* (Lanjutan)

Variabel	Metode	RMSE	RMSEP	sMAPE	sMAPEP
SO ₂ SUF1	TSR	22,792	10,031	56,325	56,230
	ARIMA	16,573	10,148	32,167	82,336
	FFNN	13,724	4,898	30,418	43,149
	LSTM	14,260	4,990	34,901	31,610
	TSR dengan AR Error	16,806	5,180	38,437	31,649
	TSR dengan ARMA Error	14,314	9,860	33,874	85,504
	Hibrida TSR dan FFNN	13,728	6,344	31,904	54,898
	Hibrida TSR dan LSTM	14,380	5,868	39,360	51,777
SO ₂ SUF6	TSR	13,930	8,371	50,420	58,988
	ARIMA	6,132	3,567	17,051	26,747
	FFNN	5,474	3,270	17,419	22,316
	LSTM	5,487	3,187	18,497	22,032
	TSR dengan AR Error	5,699	2,997	19,862	20,930
	TSR dengan ARMA Error	5,487	2,942	17,430	19,693
	Hibrida TSR dan FFNN	5,040	2,995	16,505	19,921
	Hibrida TSR dan LSTM	5,399	2,808	19,361	18,668


Tabel 4.28 Perbandingan Nilai Akurasi Setiap Model pada Data *In-Sample* dan *Out-of-Sample* (Lanjutan)

Variabel	Metode	RMSE	RMSEP	sMAPE	sMAPEP
SO ₂ SUF7	TSR	6,857	7,341	26,171	41,042
	ARIMA	3,420	1,963	8,972	10,196
	FFNN	3,159	1,886	9,200	9,157
	LSTM	3,207	1,872	9,225	10,451
	TSR dengan AR Error	3,090	1,971	9,540	9,632
	TSR dengan ARMA Error	3,012	1,774	9,189	9,572
	Hibrida TSR dan FFNN	2,946	1,798	9,276	8,523
	Hibrida TSR dan LSTM	3,048	1,833	9,421	9,486

Dari Tabel 4.26 diketahui bahwa model terbaik untuk peramalan lima parameter kualitas udara di tiga stasiun SUF Kota Surabaya adalah ARIMA, FFNN, LSTM, *time series regression* dengan AR error, *time series regression* dengan ARMA error, hibrida *time series regression* dan FFNN, dan hibrida *time series regression* dan LSTM. Frekuensi metode terbaik dari lima parameter kualitas udara di tiga stasiun SUF ditunjukkan Gambar 4.29.


Dari 8 metode yang digunakan diketahui bahwa hanya metode *time series regression* yang tidak menjadi metode terbaik di lima parameter kualitas udara di tiga stasiun SUF. Metode ARIMA digunakan untuk meramalkan variabel O₃ SUF 1, O₃ SUF 6 dan PM₁₀ SUF 1. Metode FFNN digunakan untuk meramalkan variabel CO SUF 1. Metode LSTM digunakan untuk meramalkan variabel CO SUF 6, NO₂ SUF 1 dan SO₂ SUF 1. Metode *time series regression* dengan AR error digunakan untuk meramalkan variabel NO₂ SUF 7. Metode *time series regression* dengan ARMA error

digunakan untuk meramalkan SO_2 SUF 7. Metode hibrida *time series regression* dan FFNN digunakan untuk meramalkan variabel NO_2 SUF 6, PM_{10} SUF 6 dan PM_{10} SUF 7. Metode hibrida *time series regression* dan LSTM digunakan untuk meramalkan variabel CO SUF 7, O_3 SUF 7 dan SO_2 SUF 6. Dari 6 metode terbaik yang digunakan untuk meramalkan lima parameter kualitas udara di tiga stasiun SUF Kota Surabaya tidak ada metode yang paling baik. Terdapat 4 metode yang masing-masing metode digunakan di 3 variabel yaitu ARIMA, LSTM, hibrida *time series regression* dan FFNN, dan hibrida *time series regression* dan LSTM.




Gambar 4.29 Frekuensi Metode Terbaik

Untuk mengetahui ramalan dengan metode terbaik mampu meramalkan sampai beberapa periode kedepan dilakukan uji deteksi RMSE *adaptive* pada kelima parameter kualitas udara di tiga stasiun SUF Kota Surabaya.



Gambar 4.30 RMSE *Adaptive* Parameter Kualitas Udara CO SUF 1 (a), SUF 6 (b) dan SUF 7 (c)


Metode terbaik yang digunakan untuk meramalkan CO SUF 1 adalah FFNN. Berdasarkan Gambar 4.30 pola RMSE secara umum mengalami penurunan hingga periode kelima. Dengan menggunakan batas nilai maksimum RMSE sebesar 0,29 maka metode FFNN baik digunakan untuk meramalkan CO SUF 1 hingga 10 periode kedepan (5 jam kedepan). Metode terbaik yang digunakan untuk meramalkan CO SUF 6 adalah LSTM. Pola RMSE secara umum mengalami penurunan hingga periode kesepuluh. Jika digunakan batas nilai RMSE maksimum 1,15 maka metode LSTM baik digunakan meramalkan CO SUF 6 hingga 10 periode kedepan (5 jam kedepan). Metode terbaik yang digunakan untuk meramalkan CO SUF 7 adalah hibrida TSR dan LSTM. Secara umum pola RMSE naik hingga periode keenam. Jika digunakan batas nilai RMSE maksimum 0,005 maka metode hibrida TSR dan LSTM baik digunakan untuk meramalkan CO SUF 7 hingga 5 periode kedepan (2 jam 30 menit kedepan).



Gambar 4.31 RMSE *Adaptive* Parameter Kualitas Udara NO₂ SUF 1 (a), SUF 6 (b) dan SUF 7 (c)

Dari Gambar 4.31 metode terbaik yang digunakan untuk meramalkan NO₂ SUF 1 adalah LSTM. Pola RMSE secara umum mengalami kenaikan signifikan hingga periode ketiga. Dengan menggunakan batas nilai maksimum RMSE sebesar 2,5 maka metode LSTM baik digunakan untuk meramalkan NO₂ SUF 1 hingga 1 periode kedepan (30 menit kedepan). Metode terbaik yang digunakan untuk meramalkan NO₂ SUF 6 adalah hibrida TSR dan FFNN. Pola RMSE secara umum mengalami kenaikan hingga periode kedua tetapi setelah itu mengalami penurunan hingga periode kesepuluh. Jika digunakan batas nilai RMSE maksimum 12,75 maka metode hibrida TSR dan FFNN baik digunakan meramalkan NO₂ SUF 6 hingga 10 periode kedepan (5 jam kedepan). Metode terbaik yang digunakan untuk meramalkan NO₂ SUF 7 adalah TSR dengan AR error. Secara umum pola RMSE turun hingga periode ketiga dan setelah itu mengalami kenaikan. Jika digunakan batas nilai RMSE maksimum 3,5 maka metode


TSR dengan AR error baik digunakan untuk meramalkan NO_2 SUF 7 hingga 3 periode kedepan (1 jam 30 menit kedepan).



Gambar 4.32 RMSE *Adaptive* Parameter Kualitas Udara O₃ SUF 1 (a), SUF 6 (b) dan SUF 7 (c)

ARIMA merupakan metode terbaik yang digunakan untuk meramalkan O₃ SUF 1. Berdasarkan Gambar 4.32 pola RMSE secara umum mengalami penurunan hingga periode kesepuluh. Dengan menggunakan batas nilai maksimum RMSE sebesar 8 maka metode ARIMA baik digunakan untuk meramalkan O₃ SUF 1 hingga 10 periode kedepan (5 jam kedepan). Metode terbaik yang digunakan untuk meramalkan O₃ SUF 6 adalah ARIMA. Pola RMSE secara umum mengalami kenaikan signifikan hingga periode kedua tetapi setelah itu mengalami penurunan hingga periode kesepuluh. Jika digunakan batas nilai RMSE maksimum 5 maka metode ARIMA baik digunakan meramalkan O₃ SUF 6 hingga 1 periode kedepan (30 menit kedepan). Metode terbaik yang digunakan untuk meramalkan O₃ SUF 7 adalah hibrida TSR dan LSTM. Secara umum pola RMSE naik turun hingga periode


kelima dan setelah itu mengalami kenaikan signifikan hingga periode keenam. Jika digunakan batas nilai RMSE maksimum 2,25 maka metode hibrida TSR dan LSTM baik digunakan untuk meramalkan O_3 SUF 7 hingga 5 periode kedepan (2 jam 30 menit kedepan).



Gambar 4.33 RMSE *Adaptive* Parameter Kualitas Udara PM_{10} SUF 1 (a), SUF 6 (b) dan SUF 7 (c)

Metode terbaik yang digunakan untuk meramalkan PM_{10} SUF 1 adalah ARIMA. Dari Gambar 4.33 pola RMSE secara umum mengalami kenaikan hingga periode kedua dan setelah itu mengalami penurunan hingga periode kesepuluh. Dengan menggunakan batas nilai maksimum RMSE sebesar 3,5 maka metode ARIMA baik digunakan untuk meramalkan PM_{10} SUF 1 hingga 10 periode kedepan (5 jam kedepan). Metode terbaik yang digunakan untuk meramalkan PM_{10} SUF 6 adalah hibrida TSR dan FFNN. Pola RMSE secara umum naik turun hingga periode kelima dan setelah itu mengalami penurunan signifikan. Jika digunakan batas nilai RMSE maksimum 0,56 maka metode hibrida TSR dan

FFNN baik digunakan meramalkan PM_{10} SUF 6 hingga 10 periode kedepan (5 jam kedepan). Metode terbaik yang digunakan untuk meramalkan PM_{10} SUF 7 adalah hibrida TSR dan FFNN. Secara umum pola RMSE turun signifikan hingga periode kedua dan setelah itu naik turun hingga periode kesepuluh. Jika digunakan batas nilai RMSE maksimum 4,7 maka metode hibrida TSR dan FFNN baik digunakan untuk meramalkan PM_{10} SUF 7 hingga 10 periode kedepan (5 jam kedepan).



Gambar 4.34 RMSE *Adaptive* Parameter Kualitas Udara SO₂ SUF 1 (a), SUF 6 (b) dan SUF 7 (c)

Berdasarkan Gambar 4.34 LSTM merupakan metode terbaik yang digunakan untuk meramalkan SO₂ SUF 1. Pola RMSE secara umum mengalami kenaikan signifikan hingga periode kedua. Dengan menggunakan batas nilai maksimum RMSE sebesar 4 maka metode LSTM baik digunakan untuk meramalkan SO₂ SUF 1 hingga 1 periode kedepan (30 menit kedepan). Metode terbaik yang digunakan untuk meramalkan SO₂ SUF 6 adalah hibrida TSR dan LSTM. Pola RMSE secara umum naik hingga periode kelima


tetapi setelah itu mengalami penurunan hingga periode sepuluh. Jika digunakan batas nilai RMSE maksimum 2 maka metode hibrida TSR dan LSTM baik digunakan meramalkan SO_2 SUF 6 hingga 2 periode kedepan (1 jam kedepan). Metode terbaik yang digunakan untuk meramalkan SO_2 SUF 7 adalah TSR dengan ARMA error. Secara umum pola RMSE turun hingga periode kesepuluh. Jika digunakan batas nilai RMSE maksimum 4,4 maka metode TSR dengan ARMA error baik digunakan untuk meramalkan SO_2 SUF 7 hingga 10 periode kedepan (5 jam kedepan).

4.4. Peramalan Lima Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya


Peramalan lima parameter kualitas udara di tiga stasiun SUF Kota Surabaya pada data *in-sample*, data *out-of-sample* dan ramalan pukul 00.30 hingga 19.00 di tanggal 21 Desember 2018 dilakukan menggunakan metode terbaik yang telah diperoleh. Sehingga metode yang digunakan untuk masing-masing parameter kualitas udara di tiga stasiun SUF Kota Surabaya akan berbeda.

1. Hasil Peramalan Parameter Kualitas Udara CO

Hasil peramalan CO SUF 1 pukul 00.30 hingga 19.00 di tanggal 21 Desember 2018 menunjukkan kadar CO di SUF 1 naik turun. Pada SUF 6 kadar CO terus mengalami kenaikan dan pada SUF 7 kadar CO stasioner dan tertinggi ketika pukul 07.00. Hasil ramalan pada data *out-of-sample* telah mengikuti data aktual.




Gambar 4.35 Hasil Peramalan CO pada Data *In-Sample* di SUF 1 (a), SUF 6 (c) dan SUF 7 (e) serta Data *Out-of-Sample* di SUF 1 (b), SUF 6 (d) dan SUF 7 (f)




Gambar 4.35 Hasil Peramalan CO pada Data *In-Sample* di SUF 1 (a), SUF 6 (c) dan SUF 7 (e) serta Data *Out-of-Sample* di SUF 1 (b), SUF 6 (d) dan SUF 7 (f) (Lanjutan)

2. Hasil Peramalan Parameter Kualitas Udara NO_2

Berikut merupakan hasil ramalan NO_2 di tiga stasiun SUF Kota Surabaya.



Gambar 4.36 Hasil Peramalan NO_2 pada Data *In-Sample* di SUF 1 (a), SUF 6 (c) dan SUF 7 (e) serta Data *Out-of-Sample* di SUF 1 (b), SUF 6 (d) dan SUF 7 (f)




Gambar 4.36 Hasil Peramalan NO₂ pada Data *In-Sample* di SUF 1 (a), SUF 6 (c) dan SUF 7 (e) serta Data *Out-of-Sample* di SUF 1 (b), SUF 6 (d) dan SUF 7 (f) (Lanjutan)

Hasil ramalan NO₂ di tiga stasiun SUF pada data *out-of-sample* telah mengikuti data aktual. Hasil ramalan NO₂ di SUF 1 pukul 00.30 hingga 19.00 di tanggal 21 Desember 2018 menunjukkan kadar NO₂ di SUF 1 tertinggi pada pukul 12.00. Pada SUF 6 kadar NO₂ tertinggi pada pukul 07.30 dan pada SUF 7 kadar NO₂ tertinggi ketika pukul 16.00

3. Hasil Peramalan Parameter Kualitas Udara O₃


Hasil ramalan O₃ di SUF 1, SUF 6 dan SUF 7 pukul 00.30 hingga 19.00 di tanggal 21 Desember 2018 menunjukkan kadar O₃ tertinggi terjadi sekitar pukul 12.00. Pada SUF 7 kadar O₃ menurun setelah pukul 12.00 tetapi pada pukul 17.00 kadarnya menjadi tinggi kembali. Hasil ramalan O₃ di tiga stasiun SUF pada data *out-of-sample* telah mengikuti data aktual.



Gambar 4.37 Hasil Peramalan O_3 pada Data *In-Sample* di SUF 1 (a), SUF 6 (c) dan SUF 7 (e) serta Data *Out-of-Sample* di SUF 1 (b), SUF 6 (d) dan SUF 7 (f)

4. Hasil Peramalan Parameter Kualitas Udara PM_{10}


Hasil ramalan PM_{10} di SUF 1, pukul 00.30 hingga 19.00 di tanggal 21 Desember 2018 menunjukkan kadar PM_{10} tertinggi terjadi sekitar pukul 08.30. Sedangkan kadar PM_{10} di SUF 6 tertinggi sekitar pukul 09.30 dan di SUF 7 tertinggi sekitar pukul 11.30. Hasil ramalan PM_{10} pada data *out-of-sample* telah mengikuti data aktual.



Gambar 4.38 Hasil Peramalan PM_{10} pada Data *In-Sample* di SUF 1 (a), SUF 6 (c) dan SUF 7 (e) serta Data *Out-of-Sample* di SUF 1 (b), SUF 6 (d) dan SUF 7 (f)

5. Hasil Peramalan Parameter Kualitas Udara SO_2

Hasil ramalan SO_2 di SUF 6 dan SUF 7 pukul 00.30 hingga 19.00 di tanggal 21 Desember 2018 menunjukkan kadar SO_2 tertinggi terjadi sekitar pukul 08.00. Sedangkan kadar SO_2 di SUF 1 tertinggi sekitar pukul 01.30 dan setelah itu kadarnya cenderung menurun. Hasil ramalan SO_2 di tiga stasiun SUF pada data *out-of-sample* telah mengikuti data aktual.



Gambar 4.39 Hasil Peramalan SO₂ pada Data *In-Sample* di SUF 1 (a), SUF 6 (c) dan SUF 7 (e) serta Data *Out-of-Sample* di SUF 1 (b), SUF 6 (d) dan SUF 7 (f)

4.5. Penentuan Nilai ISPU di Kota Surabaya


Setelah dilakukan peramalan masing-masing parameter kualitas udara di tiga stasiun SUF Kota Surabaya maka selanjutnya dilakukan perhitungan nilai Indeks Standar Pencemar Udara (ISPU). ISPU ini digunakan untuk melihat kualitas udara di suatu wilayah. Perhitungan ISPU ini dilakukan berdasarkan persamaan (2.55). Berikut merupakan perhitungan ISPU parameter kualitas

udara CO pukul 19.30 tanggal 20 Desember 2018 dengan kadar CO sebesar 1,32.

$$I = \frac{(50-0)}{(5-0)}(1,32-0)+0$$

$$= 13,23$$
(4.38)

Nilai ISPU untuk CO di SUF 1 pukul 19.30 tanggal 20 Desember 2018 adalah sebesar 13,23. Nilai ISPU ini menunjukkan kualitas udara masih dalam kondisi baik. Untuk perhitungan ISPU parameter kualitas lain di tiga stasiun SUF Kota Surabaya periode pukul 19.30 tanggal 20 Desember 2018 hingga pukul 19.00 tanggal 21 Desember 2018 terdapat di Lampiran 14. Dalam penentuan nilai ISPU di suatu wilayah dihitung terlebih dahulu nilai ISPU semua parameter kualitas udara di semua stasiun SUF kemudian dicari nilai ISPU tertinggi. Nilai ISPU tertinggi ini menjadi nilai ISPU yang ditetapkan di wilayah tersebut. Berikut merupakan ramalan nilai ISPU Kota Surabaya periode pukul 19.30 tanggal 20 Desember 2018 hingga pukul 19.00 tanggal 21 Desember 2018.



Gambar 4.40 Ramalan Nilai ISPU Kota Surabaya

Dari Gambar 4.40 diketahui bahwa ramalan nilai ISPU Kota Surabaya pukul 19.30 tanggal 20 Desember 2018 hingga pukul

03.00 tanggal 21 Desember 2018 masih berada dalam kondisi baik. Artinya kualitas udara di Kota Surabaya di waktu tersebut masih sehat. Pada periode tersebut parameter kualitas udara yang dominan cukup beragam yaitu PM_{10} di SUF 1, PM_{10} di SUF 7, CO di SUF 6 dan SO_2 di SUF 1. Setelah pukul 03.00 hingga pukul 19.00 nilai ISPU di Kota Surabaya berada dalam kategori sedang, hal ini dikarenakan masyarakat Surabaya sudah memulai aktivitas. Artinya kualitas udara di Kota Surabaya pada periode ini memburuk tetapi masih dalam kategori aman karena nilai ISPU masih kurang dari 100. Parameter kualitas udara yang dominan adalah PM_{10} di SUF 7. Nilai ramalan ISPU tertinggi terjadi pada pukul 11.30.

BAB V

KESIMPULAN DAN SARAN

5.1. Kesimpulan

Berdasarkan analisis dan pembahasan yang telah dilakukan pada bab 4, maka diperoleh kesimpulan sebagai berikut.

1. Lima parameter kualitas udara yaitu CO, NO₂, O₃, PM₁₀ dan SO₂ di tiga stasiun SUF Kota Surabaya memiliki pola *double seasonal* yaitu musiman harian per setengah jam dan musiman mingguan per hari. Pada pola musiman harian parameter kualitas udara CO, NO₂, PM₁₀ dan SO₂ cenderung meningkat pada jam berangkat kerja yaitu sekitar pukul 08.00 dan pulang kerja yaitu sekitar pukul 17.00 sedangkan O₃ cenderung meningkat ketika siang hari yaitu sekitar pukul 12.00. Pada pola musiman mingguan konsentrasi lima parameter kualitas udara cenderung rendah ketika hari minggu.
2. Berdasarkan kriteria RMSEP dan sMAPEP pada data *out-of-sample* didapatkan metode terbaik untuk peramalan lima parameter kualitas udara di tiga stasiun SUF. Metode ARIMA digunakan untuk meramalkan variabel O₃ SUF 1, O₃ SUF 6 dan PM₁₀ SUF 1. Metode FFNN digunakan untuk meramalkan variabel CO SUF 1. Metode LSTM digunakan untuk meramalkan variabel CO SUF 6, NO₂ SUF 1 dan SO₂ SUF 1. Metode *time series regression* dengan *AR error* digunakan untuk meramalkan variabel NO₂ SUF 7. Metode *time series regression* dengan *ARMA error* digunakan untuk meramalkan SO₂ SUF 7. Metode hibrida *time series regression* dan FFNN digunakan untuk meramalkan variabel NO₂ SUF 6, PM₁₀ SUF 6 dan PM₁₀ SUF 7. Metode hibrida *time series regression* dan LSTM digunakan untuk meramalkan variabel CO SUF 7, O₃ SUF 7 dan SO₂ SUF 6. Dari 8 metode yang digunakan tidak terdapat metode yang paling dominan.
3. Hasil ramalan lima parameter kualitas udara di tiga stasiun SUF secara umum tinggi pada jam berangkat kerja yaitu sekitar

pukul 08.00 untuk CO, NO₂, PM₁₀ dan SO₂ sedangkan untuk O₃ tinggi pada saat siang hari yaitu sekitar pukul 12.00.

4. Hasil ramalan nilai ISPU di Kota Surabaya menunjukkan bahwa pukul 19.30 hingga pukul 03.00 kualitas udara di Kota Surabaya masih baik. Pada pukul 03.00 hingga pukul 19.00 kualitas udara menjadi sedang. Parameter kualitas udara yang paling dominan adalah PM₁₀ di SUF 7.

5.2. Saran

Berdasarkan kesimpulan yang diperoleh, dapat dirumuskan saran sebagai pertimbangan penelitian selanjutnya adalah sebagai berikut.

1. Terdapat banyak *outlier* pada data, penanganan data *outlier* perlu dipertimbangkan untuk meningkatkan akurasi peramalan.
2. Data yang lengkap dapat meningkatkan akurasi peramalan, sehingga perlu untuk memperbaiki pengumpulan dan manajemen data.
3. Pemerintah Kota Surabaya dapat membuat kebijakan-kebijakan untuk menangani pencemaran udara pada hari dan jam dengan konsentrasi pencemar tinggi.

DAFTAR PUSTAKA

- Alamsyah, M. (2018). *Statistik Daerah Kota Surabaya 2018*. Surabaya: Badan Pusat Statistik Kota Surabaya.
- Amann, M., Klimont, Z., & Wagner, F. (2013). Regional and Global Emissions of Air Pollutants: Recent Trends and Future Scenarios. *Annual Review of Environment and Resources*, Vol. 38, 31-55.
- Amstrong, J. S. (2007). Significance Tests Harm Progress in Forecasting. *International Journal of Forecasting*, Vol. 23, 321-327.
- Ayu, D. K., Susilaningrum, D., & Suhartono. (2016). Pemodelan Produksi Minyak Bumi di PT. "Z" Menggunakan Metode ARIMA, FFNN, dan Hybrid ARIMA-FFNN. *Jurnal Sains dan Seni ITS*, Vol. 5 (2), 444-449.
- Azzouni, A., & Pujjole, G. (2017). A Long-Short Term Memory Recurrent Neural Network Framework for Network Traffic Matrix Prediction. *arXiv preprint arXiv:1705.05690*.
- Cheng, Y., Zhang, H., Liu, Z., Chen, L., & Wang, P. (2019). Hybrid Algorithm for Short-Term Forecasting of PM_{2.5} in China. *Atmospheric Environment*, Vol. 200, 264-279.
- Chong, E., & Zak, S. H. (2001). *An Introduction to Optimize*. Canada: John Wiley & Son.
- Chrisdayanti, B., & Suharsono, A. (2015). Peramalan Kandungan Partikular Matter (PM₁₀) dalam Udara Ambien Kota Surabaya Menggunakan Double Seasonal ARIMA. *Jurnal Sains dan Seni ITS*, Vol. 4 (2), 242-247.
- Clean Air Initiative for Asian Cities. (2010). *Air Quality in Asia: Status and Trends 2010 Edition*. Manila: CAI-Asia Center.

- Cryer, J. D., & Chan, K. S. (2008). *Time Series Analysis With Applications in R, Second Edition*. New York: Springer.
- Dahlan, E. N. (1989). Dampak Pencemaran Udara Terhadap Kesehatan Manusia dan Beberapa Komponen Sumber Daya Alam. *Media Konservasi*, Vol. 2, 39-44.
- Daniel, W. W. (1990). *Applied Nonparametric Statistics, Second Edition*. Boston: PWSKent Publishing Company.
- Dinas Lingkungan Hidup Kota Surabaya. (2017). *Informasi Kinerja Pengelolaan Lingkungan Hidup Daerah Tahun 2016*. Surabaya: Dinas Lingkungan Hidup.
- Hanke, J. E., & Wichern, D. W. (2005). *Bussines Forecasting Eight Edition*. New Jersey: Pearson Praticce Hall.
- Hochreiter, S., & Schmiduber, J. (1997). Long Short-Term Memory. *Neural Computation*, Vol. 9 (8), 1735-1780.
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice 2nd Edition*. Melbourne: OTexts.
- Iskandar, A. (2006). *Perkiraan Penggunaan Bahan Bakar Minyak (BBM) untuk Transportasi Darat*. Jakarta: Badan Litbang Perhubungan Departemen Perhubungan RI Jakarta.
- Kim, J., Kim, H., Huh, S., Lee, J., & Choi, K. (2018). Deep Neural Networks with Weighted Spikes. *Neurocomputing*, Vol. 311, 373-386.
- Kostenko, A. V., & Hyndman, R. J. (2008). *Forecasting Without Significance Test?*
- Kusuma, Y. (2010). *Pengaruh Bahan Bakar pada Aktivitas Transportasi terhadap Pencemaran Udara*. Bandung: Jurusan Teknik Sipil Politeknik Negeri Bandung.
- Lee, T. H., White, H., & Granger, C. J. (1993). Testing for Neglected Nonlinearity in Time Series Models: A

- Comparison of Neural Network Methods and Alternative Tests. *Journal of Econometrics*, Vol. 56, 269-290.
- Lewis, N. D. (2016). *Deep Learning Made Easy with R*. Australia: NigelfLewis.
- Li, Y., & Cao, H. (2018). Prediction for Tourism Flow Based on LSTM Neural Network. *Procedia Computer Science*, Vol. 129, 277-283.
- Ma, X., Tao, Z., Wang, Y., Yu, H., & Wang, Y. (2015). Long Short-Term Memory Neural Network for Traffic Speed Prediction Using Remote Microwave Sensor Data. *Transportation Research Part C: Emerging Technologies*, Vol. 54, 187-197.
- Makridakis, S., & Hibbon, M. (2000). The M3-Competition Result, Conclusions and Implications . *International Journal of Forecasting*, Vol. 16, 451-676.
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). The M4 Competition: Results, Findings, Conclusion and Way Forward. *International Journal of Forecasting*, Vol. 34, 802-808.
- Mukono. (1997). *Pencemaran Udara dan Pengaruhnya Terhadap Gangguan Saluran Pernapasan*. Surabaya: Airlangga University Press.
- Nahdliyah, N. (2019). *Model Multivariat Generalized Space Time Autoregressive (MGSTAR) untuk Monitoring Kualitas Udara di Surabaya*. Surabaya: Tugas Akhir Departemen Statistika ITS.
- Nakama, T. (2011). Comparisons of Single and Multiple Hidden Layer Neural Networks. *Proceedings of the 8th International Conference on Advances in Neural Network*, 270-279.

- Priyambodo. (2018). Analisis Korelasi Jumlah Kendaraan dan Pengaruhnya terhadap PDRB di Provinsi Jawa Timur. *Warta Perhubungan 2018*, 59-65.
- Robles , R. A., Ortega, J. C., Fu, J. S., Reed, G. D., Chow, J. C., Watson, J. G., & Herrera, J. A. (2008). A Hybrid ARIMA and Artificial Neural Network Model to Forecast Particulate Matter in Urban Areas: The Case of Temuco, Chile. *Journal Atmosphere Environment*, Vol. 42, 8331-8440.
- Shumway, R. H., & Stoffer, D. S. (2006). *Time Series Analysis and Its Application with R Examples*. Pittsburg: Springer.
- Simanjutak, A. G. (2007). Pencemaran Udara. *Buletin Limbah*, Vol. 11 (1), 89.
- Suhartono. (2007). *Feed Forward Neural Network untuk Pemodelan Runtun Waktu*. Yogyakarta: Disertasi Doktoral Universitas Gajah Mada.
- Tallon, L. A., Manjourides, J., Pun, V. C., Salhi, C., & Suh, H. (2017). Cognitive Impacts of Ambient Air Pollution in The National Social Health and Aging Project (NSHAP) Cohort. *Environmental International*, Vol. 104, 102-109.
- Tealab, A. (2018). Time Series Forecasting using Artificial Neural Networks Methodologies: A Systematic Review. *Future Computing and Informatics Journal*, Vol. 3 (2), 334-340.
- Wardhana, A. (2004). *Dampak Pencemaran Lingkungan*. Yogyakarta: Andi.
- Wei, W. W. S. (2006). *Time Series Analysis Univariate and Multivariate Methods (2nd ed)*. United States of America: Pearson Education, Inc.

- Zhang, G. P. (2003). Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*, Vol. 50, 159-175.
- Zheng, F., & Zhong, S. (2011). Time Series Forecasting Using a Hybrid RBF Neural Network and AR Model Based on Binomial Smoothing. *World Academy of Science Engineering and Technology*, Vol. 75, 1471-1475.

(Halaman ini sengaja dikosongkan)

LAMPIRAN

Lampiran 1. Data Lima Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya

SUF 1

t	Jam	Bulan	Tahun	Hari	CO	NO ₂	O ₃	PM ₁₀	SO ₂
1	00:30:00	Januari	2018	Senin	1.19	57.23	12.66	17.00	30.22
2	01:00:00	Januari	2018	Senin	1.43	58.50	13.74	19.86	25.83
3	01:30:00	Januari	2018	Senin	1.18	54.71	12.59	26.27	24.54
16992	23:00:00	Desember	2018	Kamis	1.86	10.98	2.65	20.00	14.69
16993	23:30:00	Desember	2018	Kamis	2.04	2.46	1.89	20.00	22.20
16994	00:00:00	Desember	2018	Kamis	1.78	1.82	1.62	20.00	27.98

SUF 6

t	Jam	Bulan	Tahun	Hari	CO	NO ₂	O ₃	PM ₁₀	SO ₂
1	00:30:00	Januari	2018	Senin	1.87	33.66	4.53	14.00	8.66
2	01:00:00	Januari	2018	Senin	2.13	37.57	4.06	13.57	9.71
3	01:30:00	Januari	2018	Senin	2.04	37.03	4.25	13.00	10.13
16992	23:00:00	Desember	2018	Kamis	3.22	24.66	10.00	10.00	10.41
16993	23:30:00	Desember	2018	Kamis	3.05	24.34	8.21	10.00	8.41
16994	00:00:00	Desember	2018	Kamis	3.12	28.76	5.76	10.00	9.20

SUF 7

t	Jam	Bulan	Tahun	Hari	CO	NO ₂	O ₃	PM ₁₀	SO ₂
1	00:30:00	Januari	2018	Senin	0.77	19.10	7.80	74.73	6.15
2	01:00:00	Januari	2018	Senin	0.72	24.44	7.70	78.00	6.77
3	01:30:00	Januari	2018	Senin	1.19	27.90	5.63	78.40	7.05
16992	23:00:00	Desember	2018	Kamis	0.00	45.14	6.65	28.66	15.38
16993	23:30:00	Desember	2018	Kamis	0.00	52.51	5.72	29.00	15.68
16994	00:00:00	Desember	2018	Kamis	0.00	48.95	5.55	29.71	17.55

Lampiran 2. *Output Time Series Regression* pada Lima Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya

CO SUF 6

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
Tren	0,000069						
00:30	0,31	0,73	0,62	0,61	0,53	0,49	0,71
01:00	0,38	0,53	0,61	0,53	0,63	0,48	0,64
01:30	0,22	0,55	0,53	0,51	0,32	0,47	0,97
02:00	0,28	0,39	0,52	0,39	0,35	0,42	0,88
02:30	0,20	0,45	0,51	0,33	0,34	0,34	0,73
03:00	0,22	0,37	0,54	0,36	0,31	0,30	0,61
03:30	0,08	0,42	0,49	0,40	0,26	0,30	0,58
04:00	0,21	0,14	0,54	0,37	0,25	0,40	0,48
04:30	0,12	0,37	0,44	0,45	0,26	0,32	0,47
05:00	0,14	0,34	0,52	0,43	0,28	0,38	0,46
05:30	0,24	0,42	0,51	0,40	0,45	0,36	0,48
06:00	0,47	0,39	0,57	0,51	0,41	0,43	0,53
06:30	0,43	0,70	0,83	0,67	0,62	0,69	0,68
07:00	0,81	0,91	0,89	0,97	0,79	0,79	0,57
07:30	0,75	0,91	0,95	1,06	0,78	0,85	0,57
08:00	0,56	0,91	0,75	0,77	0,64	0,65	0,24
08:30	0,36	0,60	0,51	0,64	0,55	0,15	0,44
09:00	0,22	0,48	0,45	0,41	0,22	0,58	0,27
09:30	0,27	0,04	0,09	0,34	0,13	0,17	0,14
10:00	0,13	0,08	0,04	0,38	0,12	0,26	0,05
10:30	0,04	0,04	-0,19	0,43	0,06	-0,05	0,13
11:00	-0,05	0,48	0,22	0,16	-0,02	0,18	-0,20
11:30	-0,16	-0,04	0,17	0,24	0,00	-0,13	0,19

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
12:00	-0,09	0,00	0,14	0,33	-0,01	0,17	-0,12
12:30	0,21	0,09	0,06	0,16	0,06	0,01	0,11
13:00	0,25	0,02	-0,09	0,02	0,00	0,11	-0,19
13:30	-0,04	0,12	0,06	0,33	0,03	-0,02	0,19
14:00	0,31	0,13	0,09	-0,04	-0,03	0,32	-0,12
14:30	0,04	0,34	0,25	0,39	0,09	0,15	0,22
15:00	0,00	0,26	0,30	0,15	0,30	0,21	0,03
15:30	-0,04	0,35	0,34	0,26	0,30	-0,07	0,20
16:00	0,25	0,33	0,24	0,49	0,30	0,16	-0,04
16:30	0,30	0,34	0,33	0,34	0,26	0,33	0,24
17:00	0,23	0,42	0,46	0,41	0,31	0,31	0,00
17:30	0,28	0,56	0,52	0,52	0,30	0,39	0,14
18:00	0,33	0,57	0,56	0,39	0,33	0,38	0,30
18:30	0,33	0,62	0,61	0,43	0,40	0,59	0,20
19:00	0,38	0,74	0,72	0,54	0,33	0,29	0,20
19:30	0,43	0,68	0,67	0,59	0,35	0,60	0,22
20:00	0,60	0,88	0,70	0,69	0,38	0,66	0,25
20:30	0,85	0,84	0,65	0,72	0,38	0,83	0,34
21:00	0,86	0,81	0,62	0,80	0,56	0,74	0,45
21:30	0,80	0,78	0,67	0,83	0,52	0,69	0,35
22:00	0,61	0,78	0,68	0,85	0,58	0,63	0,39
22:30	0,52	0,83	0,71	0,76	0,54	0,79	0,28
23:00	0,55	0,80	0,64	0,75	0,56	0,60	0,44
23:30	0,65	0,85	0,55	0,65	0,53	0,70	0,31
00:00	0,48	0,78	0,65	0,69	0,50	0,59	0,50

CO SUF 7

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
Tren	-0,000051						
00:30	1,45	1,58	1,57	1,72	1,71	1,65	1,93
01:00	1,44	1,46	1,48	1,69	1,62	1,63	1,91
01:30	1,39	1,41	1,42	1,62	1,63	1,63	1,78
02:00	1,34	1,41	1,39	1,57	1,55	1,58	1,65
02:30	1,31	1,37	1,40	1,52	1,49	1,52	1,65
03:00	1,29	1,33	1,36	1,44	1,46	1,47	1,56
03:30	1,29	1,27	1,33	1,45	1,46	1,45	1,51
04:00	1,25	1,29	1,33	1,39	1,43	1,42	1,49
04:30	1,27	1,31	1,34	1,38	1,46	1,41	1,46
05:00	1,29	1,40	1,35	1,47	1,48	1,44	1,48
05:30	1,40	1,47	1,45	1,53	1,56	1,55	1,55
06:00	1,75	1,83	1,82	1,89	1,94	1,80	1,71
06:30	2,40	2,38	2,41	2,54	2,42	2,12	1,95
07:00	3,12	3,23	3,22	3,38	3,09	2,71	2,06
07:30	3,05	2,97	2,98	3,14	2,91	2,70	2,09
08:00	2,83	2,80	2,68	2,72	2,68	2,57	1,96
08:30	2,57	2,48	2,27	2,51	2,37	2,27	1,74
09:00	2,24	2,09	2,09	2,18	2,02	2,00	1,61
09:30	1,98	1,80	1,84	1,90	1,80	1,81	1,46
10:00	1,79	1,60	1,64	1,59	1,55	1,65	1,43
10:30	1,61	1,51	1,52	1,47	1,41	1,54	1,30
11:00	1,45	1,34	1,40	1,37	1,37	1,44	1,24
11:30	1,35	1,19	1,35	1,27	1,35	1,43	1,17
12:00	1,25	1,14	1,33	1,20	1,27	1,23	1,07
12:30	1,18	1,13	1,17	1,20	1,15	1,18	1,01

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
13:00	1,19	1,15	1,20	1,16	1,08	1,18	0,97
13:30	1,15	1,12	1,17	1,14	1,16	1,15	0,93
14:00	1,11	1,08	1,25	1,11	1,18	1,23	0,94
14:30	1,09	1,10	1,18	1,14	1,15	1,17	0,93
15:00	1,33	1,25	1,25	1,26	1,17	1,15	0,89
15:30	1,21	1,23	1,24	1,25	1,20	1,15	0,85
16:00	1,29	1,38	1,38	1,44	1,21	1,17	0,88
16:30	1,35	1,58	1,34	1,51	1,32	1,21	1,04
17:00	1,85	1,82	1,34	2,14	1,75	1,59	1,16
17:30	1,65	1,81	1,81	1,75	1,62	1,57	1,22
18:00	1,87	1,88	2,00	1,91	1,65	1,54	1,27
18:30	1,93	1,90	2,05	1,82	1,71	1,55	1,26
19:00	1,98	2,13	2,02	1,89	1,70	1,75	1,42
19:30	2,01	2,12	2,00	1,91	1,73	1,87	1,58
20:00	2,02	2,10	2,06	1,97	1,76	1,91	1,57
20:30	2,04	2,23	2,12	1,99	1,80	1,98	1,63
21:00	1,88	2,25	2,14	2,07	1,93	1,99	1,69
21:30	1,88	2,07	2,05	1,99	1,98	2,01	1,57
22:00	1,80	2,01	1,94	2,12	2,01	1,95	1,58
22:30	1,69	1,91	1,95	2,08	1,96	1,99	1,57
23:00	1,78	1,89	1,87	2,01	1,92	2,01	1,56
23:30	1,69	1,79	1,87	1,96	1,81	1,91	1,57
00:00	1,67	1,70	1,79	1,78	1,69	1,94	1,47

NO₂ SUF 1

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
Tren	-0,001169						
00:30	28,1	30,26	31,02	30,21	32,39	32,19	36,03
01:00	27,48	30,25	32,6	32,35	32,19	30,77	34,15
01:30	29,65	30,32	31,56	32,89	30,23	31,47	36,22
02:00	30,34	29,42	28,89	32,62	27,48	33,71	35,97
02:30	30,94	29,41	30,62	31,71	29,9	33,5	34,71
03:00	30,68	30,51	33,11	31,73	29,79	32,64	32,97
03:30	30,94	29,44	35,83	32,25	31,41	31,36	31,83
04:00	32,09	30,32	35,11	32,54	32,28	31,19	32,15
04:30	32,19	32,42	33,81	34,34	33,55	31,2	32,68
05:00	32,35	31,74	33,95	35,59	34,01	32,27	32,15
05:30	32,52	31,16	34,79	35,4	33,87	31,93	31,98
06:00	33,53	31,39	33,79	35,71	33,63	32,1	32,64
06:30	33,58	31,65	35,28	35,35	33,09	32,51	32,36
07:00	35,98	35,23	37,16	36,79	35,73	39,01	33,65
07:30	43,37	42,18	40,72	44,9	44,09	46,09	37,48
08:00	46,57	45,74	45,57	48,96	49,14	48,79	37,44
08:30	43,7	44,23	46,15	47,89	43,77	48,31	33,99
09:00	39,04	36,44	39,24	41,08	38,58	42,5	28,76
09:30	33,62	30,79	36,16	34,63	32,67	34,37	25,39
10:00	31,52	28,11	32,91	30,28	28,48	29,95	23,55
10:30	28,2	26,08	30,85	27,5	25,59	26,58	22,18
11:00	26,36	25,26	28,26	26,54	24,51	24,34	21,72
11:30	25,27	24,93	26,37	26,29	25,2	24,51	21,45
12:00	24,24	24,94	25,63	23,75	24,23	23,52	20,41
12:30	23,16	24,09	23,72	23,74	22,15	22,13	19,8

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
13:00	23,63	23,47	23,27	24,42	20,58	22,34	19,16
13:30	24,23	22,94	24,44	23,61	22,82	21,2	20,21
14:00	24,86	23,46	24,91	25,58	22,61	23,29	20,73
14:30	25,26	25,14	26,64	25,87	24,37	24,19	19,9
15:00	26,01	25,99	26,13	26,75	25,14	24,39	19,66
15:30	27,97	26,83	27,03	27,86	24,55	24,78	20,99
16:00	29,59	29,03	28,26	28,07	26,64	26,33	21,1
16:30	29,21	29,96	30,55	29,9	27,17	28,69	22,94
17:00	33,06	32,13	32,32	31,84	30,39	31,49	24,83
17:30	33,94	32,96	35,51	35,41	34,66	32,35	27,23
18:00	38,16	38,64	38,6	36,98	37,26	35,44	29,52
18:30	37,59	39,72	37,39	37,45	36,68	35,42	28,35
19:00	37,38	38,36	38,14	37,01	38,02	36,26	30,87
19:30	36,5	40,94	37,12	38,32	39,8	37,35	33,93
20:00	36,12	37,35	35,81	37,88	37,24	38,43	33,45
20:30	34,74	37,36	36,24	35,14	35,59	38,89	32,54
21:00	34,93	36,29	36,51	32,43	35,41	39,87	32,09
21:30	33,44	35,67	35,37	34,96	33,09	38,49	32,27
22:00	33,48	34,64	35,61	35,08	34,82	39,76	32,92
22:30	34,13	34,7	35,81	36,2	34,9	39,38	33,31
23:00	33,33	34,1	34,49	34,67	33,79	38,88	32,98
23:30	32,43	31,87	32,45	34,21	33,17	39,5	30,93
00:00	30,61	31,96	31,39	32,23	32,13	37,26	29,29

NO₂ SUF 6

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
Tren	-0,000128						
00:30	14,33	17,08	19,47	18,56	16,79	16,05	18,6
01:00	13,66	17,3	21,7	19,33	17,89	15,66	22,35
01:30	15,02	17,87	22,75	19,15	18,54	19,24	23,22
02:00	17,59	19,5	22,83	20,16	18,85	22,19	22,43
02:30	18,54	23,31	22,73	18,64	20,8	22,09	22,83
03:00	20,56	23,82	22,09	18,68	22,12	23,43	22,72
03:30	21,44	22,75	22,39	20,26	23	24,7	21,86
04:00	21,86	21,51	23,06	21,12	24,37	25,1	21,6
04:30	21,4	22,41	23,44	21,98	24,71	24,9	21,37
05:00	22,22	22,86	23,03	23,81	25,62	23,91	21,83
05:30	22,62	23,24	25,16	24,25	25,74	25,15	22,11
06:00	24,29	24,7	26,34	25,96	27,24	25,52	22,96
06:30	26,41	25,64	29,16	28,22	29,86	28,45	24,15
07:00	31,23	32,7	33,78	33,83	33,93	34,04	26,59
07:30	38,79	38,95	37,82	37,85	36,62	38,09	27,75
08:00	36,35	40,85	35,4	35,41	35,38	35,21	25,29
08:30	27,98	30,61	29,08	30,23	28,83	26,29	22,5
09:00	22,88	21,13	21,56	21,58	19	18,83	16,01
09:30	17,15	15,87	17,3	15,41	13,38	13,85	11,54
10:00	14,51	12,95	13,9	13,28	10,66	11,2	9,7
10:30	12,84	10,18	10,64	10,67	8,51	9,9	8,37
11:00	12,23	9,24	9,17	9,63	7,42	9,01	7,05
11:30	9,33	8,6	8,07	8,03	7,18	8,11	6,62
12:00	7,3	7,37	6,49	7,3	5,62	7,66	5,83
12:30	7,07	6,59	5,58	6,77	4,86	6,64	5,49

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
13:00	7,29	6,27	5,65	6,28	4,7	5,9	5
13:30	7,69	6,3	5,36	5,82	5,17	5,9	4,65
14:00	7,29	7,94	7,06	7,01	7,42	6,1	5,82
14:30	7,73	8,41	8,84	7,98	7,61	7	5,77
15:00	7,58	8,61	8,13	9,21	8,22	7,63	4,48
15:30	8,94	9,01	8,45	9,53	7,44	8,03	5,23
16:00	8,9	7,63	8,23	10,18	8,11	7,09	5,32
16:30	9,18	7,92	8,7	10,5	7,01	7,69	5,13
17:00	9,03	8,68	9,38	9	7,47	8,64	5,5
17:30	10,23	9,53	9,57	10,3	9,45	10,06	6,13
18:00	11,89	11,17	12,11	12,81	10,74	11,09	7,37
18:30	11,87	11,92	12,56	12,36	12,04	12,7	7,52
19:00	13,18	13,54	13,06	12,8	12,29	11,75	8,41
19:30	14,13	14,25	12,69	13,24	14,45	13,1	9,92
20:00	15,71	15,29	13,3	14,13	13,16	13,76	11,26
20:30	15,61	16,49	13,59	15,68	12,25	13,63	11,62
21:00	15,89	16,32	14,92	15,11	13,03	13,81	10,81
21:30	16,4	16,54	14,39	14,84	14,15	14,56	11,02
22:00	16,05	15,45	15,85	15,8	13,78	14,69	11,96
22:30	16,39	16,09	16,55	15,03	13,86	14,33	11,51
23:00	16,24	16,64	15,99	15,13	14,25	16,47	12,3
23:30	15,49	17,69	15,75	15,6	14,92	17,17	14,84
00:00	16	18,93	16,24	16,21	15,87	18,89	12,7

NO₂ SUF 7

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
Tren	0,000109						
00:30	24,63	27,08	28,91	28,68	25,3	27	28,36
01:00	24,79	24,17	26,59	26,95	23,83	25,64	26,42
01:30	23,84	22,6	24,38	25,53	22,38	23,94	24,51
02:00	22,73	21,35	22,67	23,56	21,54	23,23	22,93
02:30	21,01	21,18	21,39	22,98	20,99	22,74	22
03:00	19,68	20,27	20,73	20,68	21,18	22,34	21,14
03:30	18,75	18,82	21,09	21,93	21,9	21,06	21,26
04:00	19,04	18,63	20,46	22,24	20,78	20,1	21,26
04:30	18,53	19,55	19,96	21,76	20,94	20,37	20,67
05:00	18,93	19,42	19,88	21,42	21,49	20,08	20,03
05:30	19,29	19,17	19,73	21,51	21,16	20,73	19,62
06:00	20,67	19,65	20,51	22,45	21,42	21,9	20,96
06:30	22,25	20,95	22,28	24,25	23,1	23,68	21,58
07:00	28,03	25,6	28,05	28,58	27,34	28,47	23,95
07:30	33,58	32,34	35,91	35,53	34,53	35,57	26,92
08:00	36,71	39,89	37,11	38,93	39,59	39,98	28,97
08:30	36,77	39,24	36,71	40,89	39,07	40,25	28,99
09:00	35,98	34,16	36,37	40,54	37,25	37,15	27,52
09:30	33,9	34,1	37,26	38,15	35,85	34,54	25,56
10:00	34,35	33,3	36,07	35,21	33,82	34,87	23,52
10:30	33,79	34,23	33,68	34,07	34,08	35,26	21,97
11:00	31,28	31,91	32,77	32,97	34,85	33,39	21,01
11:30	32,32	32,03	33,75	33,76	33,81	34,41	19,6
12:00	36,12	30,78	35,66	32,25	34,1	30,73	19,49
12:30	35,97	30,88	33,89	35,65	32,4	30,67	18,85

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
13:00	34,25	31,37	34,73	34,55	30,62	30,61	19,1
13:30	31,98	29,34	34,14	32,75	30,55	28,38	19,38
14:00	30,78	28,79	34,41	32,3	32,23	29,03	19,09
14:30	31,5	30,74	36,08	34,57	34,67	32,02	18,99
15:00	33,68	32,11	34,69	37,54	37,28	32,49	19,7
15:30	34,12	35,39	38,88	40,04	41,53	32,36	19,28
16:00	41,22	41,7	45,06	41,25	45,96	34,62	25,66
16:30	48,4	40,26	46,4	47,78	43,52	35,04	30,4
17:00	32,81	38,93	39,13	33,41	35,86	30,8	29,91
17:30	44,5	44,81	47,24	46,94	47,26	41,87	30,83
18:00	47,21	45,53	48,97	49,13	47,77	44,13	32,78
18:30	45,97	45,4	47,69	48,46	46,21	42,97	33,47
19:00	44,51	44,92	47,03	48,08	46,02	42,26	35,56
19:30	41,84	43,48	44,73	46,17	43,97	39,78	34,79
20:00	40,52	42,67	43,72	44,72	42,57	36,85	34,18
20:30	37,58	41,25	41,34	42,12	41,83	37,42	32,59
21:00	36,98	39,96	40,41	39,72	40,28	36,2	32,64
21:30	36,41	38,53	38,7	37,41	39,09	35,56	31,94
22:00	35,77	38,33	36,88	35,96	37,59	34,9	30,34
22:30	34,06	37,22	36,89	34,82	35,95	34,92	30,31
23:00	33,22	34,03	35,4	32,49	33,1	32,95	29,42
23:30	31,24	32,26	32,7	30,25	31,42	32,15	27,66
00:00	28,47	30,66	30,49	28,23	29,61	30,2	25,9

O₃ SUF 1

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
Tren	0,00114						
00:30	16,34	15,62	18,39	18,58	16,58	17,69	16,26
01:00	16,24	17,07	16,93	18,47	16,7	17,47	16,33
01:30	17,69	13,49	17,45	18,15	16,42	16,99	13,19
02:00	14,11	15,95	17,55	17,9	16,42	13,37	15,16
02:30	15,77	16,17	16,79	17,81	13,81	14,81	12,49
03:00	15,76	15,07	15,11	15,4	10,73	11,88	14,95
03:30	15,04	14,53	12,85	14,66	14,34	13,66	15,32
04:00	13,89	12,74	12,51	15,6	13,52	13,79	14,49
04:30	13,93	11,47	14,45	14,62	13,44	13,31	13,47
05:00	11,31	13,23	11,39	13,79	13,19	12,23	13,57
05:30	13,04	12,72	13,1	14,02	12,3	11,97	11,44
06:00	12,79	12,71	13,09	13,66	12,04	10,45	12,91
06:30	12,96	13,14	12,9	14,24	10,9	12,84	13,25
07:00	13,4	13,65	14,04	13,01	13,86	13,94	14,96
07:30	15,19	16,04	14,54	15,43	15,97	16,34	17,59
08:00	20,25	18,95	19,67	21,97	20,88	20,68	22,6
08:30	26,34	26,81	27,73	28,04	28,25	26,91	29,97
09:00	32,35	36,06	36,51	36,35	34,38	37,58	34,99
09:30	40,58	42,23	44,38	41,85	41,43	45,59	39,5
10:00	43,64	45,17	49,06	47,77	43,74	49,1	44,67
10:30	44,71	46,54	50,53	48,27	45,55	51,61	47,44
11:00	47,86	48,11	53,16	47,51	44,43	49,72	49,23
11:30	46,03	51,05	50,43	45,37	43,71	47,05	49,22
12:00	47,48	49,68	48,4	45,3	43,25	44,8	48,28
12:30	45,82	48,28	48,81	43,25	42,4	42,64	48,65

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
13:00	43,2	46,06	46,96	43,28	40,33	43,61	45,82
13:30	39,53	43,78	44,09	42,07	40,74	41,93	44,71
14:00	37	41,93	42,97	39,9	37,33	40,92	40,51
14:30	35,07	40,53	41,57	36,78	35,67	38,15	40,66
15:00	33,99	39,13	40,61	34,29	35,58	37,73	39,49
15:30	33,52	39,51	38,27	35,43	34,97	36,63	38,2
16:00	33,66	37,41	39,13	33,81	34,15	35,85	37,15
16:30	32,83	35,86	36,94	32,85	33,23	34,47	36
17:00	30,89	33,49	35,21	31,05	32,07	33,51	33,58
17:30	29,82	32,85	32,95	28,42	29,89	32,04	31,76
18:00	27,14	30,07	30,03	26,35	27,31	29,31	30,43
18:30	26,23	27,63	27,46	24,54	25,47	27,57	29,27
19:00	23,98	26,9	26,65	21,98	23,45	25,28	26,79
19:30	23,05	25,67	24,75	21,18	22,05	22,93	24,99
20:00	22,57	23,68	23,75	20,7	21,06	21,25	23,89
20:30	21,94	22,7	23,36	20,71	19,84	20,21	21,96
21:00	20,79	21,72	22,89	20,29	18,5	19,01	21,27
21:30	19,96	20,41	22,13	18,09	17,58	18,23	20,88
22:00	19,17	19,86	21,04	17,06	17,39	17,66	19,53
22:30	19,74	19,45	20,59	16,47	16,88	17,15	18,88
23:00	19,3	19,2	19,4	16,77	17,42	17,33	19,11
23:30	18,21	19,73	19,13	16,29	17,32	16,88	18,56
00:00	15,73	19,13	16,62	16,53	17,42	16,97	18,3

O₃ SUF 6

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
Tren	0,00079						
00:30	6,56	6,86	6,03	5,99	6,43	5,27	3,63
01:00	6,7	5,29	5,28	5,02	5,69	4,88	3,1
01:30	4,8	4,63	3,91	5,22	4,4	3,91	1,98
02:00	3,61	4,1	2,62	5,01	3,96	2,41	1,44
02:30	2,74	2,28	1,75	4,37	3,18	2,07	1,28
03:00	1,85	2	2	4,4	2,25	1,12	1,19
03:30	1,32	2,17	1,49	3,39	1,75	0,4	1,42
04:00	0,7	1,94	0,9	2,02	1,05	0,23	0,33
04:30	0,03	0,64	0,67	1,29	0,89	0,21	0,04
05:00	-0,27	-0,12	0,68	0,81	0,62	0,28	-0,36
05:30	-0,96	0	0,23	-0,04	0,84	0,07	-0,44
06:00	-0,66	-0,61	-0,26	-0,36	0,22	-0,08	-1,19
06:30	-0,85	-0,82	-0,05	-0,37	-0,12	-0,96	-0,71
07:00	-0,42	-0,57	0,81	0,18	0,39	0,05	-0,03
07:30	2,05	1,71	3,34	2,92	2,36	2	2,92
08:00	7,14	6,54	8,13	7,86	8,18	7,65	7,38
08:30	13,66	15,95	16,12	16,86	17,02	16,12	14,44
09:00	23,4	24,01	26,57	27,14	25,81	27,05	22,74
09:30	31,07	33,05	35,94	34,71	33,39	34,07	31,09
10:00	37,61	38,33	41,75	40,41	37,73	40,12	36,56
10:30	41,76	42,12	46,65	43,54	39,65	42,94	41,65
11:00	44,47	45,16	48,59	45,59	40,08	44,02	44,79
11:30	47,6	46,79	48,63	44,11	42,08	44,76	46,65
12:00	47,33	48,77	47,34	42,86	43,32	44,3	48,24
12:30	46,3	47,95	47,01	43,69	42,32	46,66	46,25

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
13:00	43,03	48,27	45,95	44,81	42,52	45,31	43,9
13:30	39,75	45,87	44,06	43,52	41,18	42,9	42,11
14:00	38,11	43,41	41,24	39,71	37,65	38,88	38,84
14:30	37,07	41,47	39,93	36,17	35,51	36,29	36,52
15:00	34,24	41,37	39,03	34,14	34,11	36,96	35,32
15:30	31,43	38,1	37,89	34,33	33,2	35,54	35,29
16:00	30,98	37,47	38,36	32,06	31,85	34,78	33,73
16:30	31,44	36,46	37,23	29,88	31,5	32,53	32,92
17:00	29,91	33,45	33,86	28,48	30,73	30,97	31,22
17:30	27,38	30,48	29,92	26,29	28,22	29,15	29,04
18:00	23,73	26,37	26,92	23,01	24,08	25,29	25,83
18:30	21,51	24,06	23,65	21,18	20,45	20,93	23,42
19:00	18,33	21,42	22,22	18,46	18,57	19,5	21,46
19:30	16,91	20,29	19,67	16,8	16,35	16,25	19,58
20:00	15,6	17,84	17,54	14,75	15,63	14,34	17,21
20:30	13,36	15,71	16,21	13,2	14,44	12,82	16,05
21:00	11,85	14,61	14,87	11,06	12,47	12,18	15,09
21:30	11,83	13,8	13,91	10,18	10,77	11,22	13,64
22:00	10,87	12,44	12,56	9,22	10,94	9,45	12,51
22:30	10,21	11,62	11,34	9,72	9,62	9,07	11,66
23:00	9,35	10,23	9,76	8,55	8,4	7,83	10,58
23:30	8,12	8,68	8,77	7,64	7,47	6,24	8,46
00:00	7,86	7,37	7,41	7,26	6,16	4,91	7,17

O₃ SUF 7

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
Tren	0,000683						
00:30	2,45	1,47	1,03	1,02	1,65	0,72	0,78
01:00	1,61	1,62	0,93	1,2	1,92	1,08	0,95
01:30	1,47	1,68	1,04	1,37	2,24	1,29	1,23
02:00	1,38	1,38	1,21	1,77	2,26	0,81	1,39
02:30	1,36	1,12	1,52	1,32	1,36	0,54	0,93
03:00	1,16	1,12	1,33	0,87	1	0,12	0,54
03:30	0,85	0,82	0,89	0,62	0,5	0,09	0,29
04:00	0,65	0,55	0,95	0,29	0,5	-0,11	0,09
04:30	0,47	0,07	0,77	0,02	0,15	-0,25	0,08
05:00	0,13	-0,09	0,48	-0,25	-0,06	-0,07	0,25
05:30	0,01	-0,12	0,29	-0,56	-0,28	-0,28	0,32
06:00	-0,13	-0,18	0,1	-0,59	-0,42	-0,55	-0,1
06:30	-0,03	0,1	0,12	-0,31	-0,21	-0,37	0,2
07:00	0,36	0,34	0,95	0,12	0,51	0,42	1,26
07:30	1,84	1,88	2,77	2,1	2,18	2,03	3,28
08:00	5,52	4,91	6,48	5,46	6,11	5,91	7,07
08:30	11,36	10,66	12,55	11,23	12,82	11,99	12,89
09:00	19,03	19,54	20,84	19,6	20,64	20,03	20,05
09:30	27,99	27,76	28,96	28,76	29,59	30,31	28,87
10:00	34,41	32,3	36,42	34,77	35,98	36,24	36,07
10:30	39,91	35,24	43,52	37,04	39,93	39,63	42,34
11:00	43,45	36,81	45,57	36,88	40,98	38,32	44,3
11:30	39,98	37,04	46,87	35,98	38,55	37,23	43,74
12:00	37,57	37,89	43,93	35,8	38,18	35,22	44,08
12:30	35,99	38,34	40,81	32,25	35,83	32,18	41,87

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
13:00	35,35	36,52	39,12	32,94	35,57	30,25	39,32
13:30	34,98	34,47	38,85	33,84	34,43	31,46	39,04
14:00	31,11	33,82	34,86	32,45	32,94	28,8	37,42
14:30	28,05	31,11	31,34	28,67	28,93	27,29	35
15:00	24,43	28,45	30,11	24,5	24,55	26,02	31,82
15:30	22,41	25,76	23,9	21,05	20,48	24,55	30,42
16:00	19,8	21,75	20,36	18,58	18,11	20,99	26,72
16:30	15,95	16,91	18,13	15,88	13,53	17,35	22,28
17:00	22,33	26,44	14,35	35,64	38,75	39,74	47,22
17:30	10,99	11,58	11,91	11,58	10,23	10,93	15,18
18:00	8,18	10,06	14,41	7,01	8	9,55	13,73
18:30	6,55	8,47	8,23	5,72	6,57	7,53	11,6
19:00	5,45	7,27	6,24	3,94	4,5	6,13	9,47
19:30	4,99	5,64	5,82	3,19	3,47	5,87	8,22
20:00	4,64	4,62	4,3	2,5	2,98	5,23	6,69
20:30	4,59	3,5	3,58	2,43	2,15	4,53	5,53
21:00	3,42	2,91	2,88	2,15	1,67	3,83	4,53
21:30	2,54	3,19	2,45	1,54	1,25	3,02	3,52
22:00	1,99	2,49	1,93	1,24	1,22	2,36	2,96
22:30	2,16	1,67	1,43	0,98	1,03	1,47	1,97
23:00	1,58	1,84	1,5	1,02	1,16	0,93	1,77
23:30	1,4	1,58	1,28	0,96	1,06	0,7	2,09
00:00	1,52	1,49	1,11	0,87	0,65	0,56	2,42

PM₁₀ SUF 1

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
Tren	0,000683						
00:30	2,45	1,47	1,03	1,02	1,65	0,72	0,78
01:00	1,61	1,62	0,93	1,2	1,92	1,08	0,95
01:30	1,47	1,68	1,04	1,37	2,24	1,29	1,23
02:00	1,38	1,38	1,21	1,77	2,26	0,81	1,39
02:30	1,36	1,12	1,52	1,32	1,36	0,54	0,93
03:00	1,16	1,12	1,33	0,87	1	0,12	0,54
03:30	0,85	0,82	0,89	0,62	0,5	0,09	0,29
04:00	0,65	0,55	0,95	0,29	0,5	-0,11	0,09
04:30	0,47	0,07	0,77	0,02	0,15	-0,25	0,08
05:00	0,13	-0,09	0,48	-0,25	-0,06	-0,07	0,25
05:30	0,01	-0,12	0,29	-0,56	-0,28	-0,28	0,32
06:00	-0,13	-0,18	0,1	-0,59	-0,42	-0,55	-0,1
06:30	-0,03	0,1	0,12	-0,31	-0,21	-0,37	0,2
07:00	0,36	0,34	0,95	0,12	0,51	0,42	1,26
07:30	1,84	1,88	2,77	2,1	2,18	2,03	3,28
08:00	5,52	4,91	6,48	5,46	6,11	5,91	7,07
08:30	11,36	10,66	12,55	11,23	12,82	11,99	12,89
09:00	19,03	19,54	20,84	19,6	20,64	20,03	20,05
09:30	27,99	27,76	28,96	28,76	29,59	30,31	28,87
10:00	34,41	32,3	36,42	34,77	35,98	36,24	36,07
10:30	39,91	35,24	43,52	37,04	39,93	39,63	42,34
11:00	43,45	36,81	45,57	36,88	40,98	38,32	44,3
11:30	39,98	37,04	46,87	35,98	38,55	37,23	43,74
12:00	37,57	37,89	43,93	35,8	38,18	35,22	44,08
12:30	35,99	38,34	40,81	32,25	35,83	32,18	41,87

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
13:00	35,35	36,52	39,12	32,94	35,57	30,25	39,32
13:30	34,98	34,47	38,85	33,84	34,43	31,46	39,04
14:00	31,11	33,82	34,86	32,45	32,94	28,8	37,42
14:30	28,05	31,11	31,34	28,67	28,93	27,29	35
15:00	24,43	28,45	30,11	24,5	24,55	26,02	31,82
15:30	22,41	25,76	23,9	21,05	20,48	24,55	30,42
16:00	19,8	21,75	20,36	18,58	18,11	20,99	26,72
16:30	15,95	16,91	18,13	15,88	13,53	17,35	22,28
17:00	22,33	26,44	14,35	35,64	38,75	39,74	47,22
17:30	10,99	11,58	11,91	11,58	10,23	10,93	15,18
18:00	8,18	10,06	14,41	7,01	8	9,55	13,73
18:30	6,55	8,47	8,23	5,72	6,57	7,53	11,6
19:00	5,45	7,27	6,24	3,94	4,5	6,13	9,47
19:30	4,99	5,64	5,82	3,19	3,47	5,87	8,22
20:00	4,64	4,62	4,3	2,5	2,98	5,23	6,69
20:30	4,59	3,5	3,58	2,43	2,15	4,53	5,53
21:00	3,42	2,91	2,88	2,15	1,67	3,83	4,53
21:30	2,54	3,19	2,45	1,54	1,25	3,02	3,52
22:00	1,99	2,49	1,93	1,24	1,22	2,36	2,96
22:30	2,16	1,67	1,43	0,98	1,03	1,47	1,97
23:00	1,58	1,84	1,5	1,02	1,16	0,93	1,77
23:30	1,4	1,58	1,28	0,96	1,06	0,7	2,09
00:00	1,52	1,49	1,11	0,87	0,65	0,56	2,42

PM₁₀ SUF 6

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
Tren	0,000064						
00:30	12	11,99	9,73	11,42	13,26	9,66	14,49
01:00	12,05	11,99	9,73	11,59	13,39	9,49	14,02
01:30	12,28	12,33	9,77	11,18	13,07	9,38	13,79
02:00	12,65	12,23	9,67	11,28	13,15	9,43	14,07
02:30	12,7	12,11	9,92	11,32	12,94	9,56	14,13
03:00	12,92	12,21	10,44	11,66	12,82	9,74	13,7
03:30	13,27	12,13	10,95	11,88	11,94	9,78	13,29
04:00	13,5	12,45	10,83	12,42	11,71	10,21	13,57
04:30	13,69	12,53	10,42	12,31	11,75	10,35	13,73
05:00	14,27	11,66	10,54	12,39	12,71	10,12	13,27
05:30	14,56	12,35	10,81	12,86	12,99	10,44	12,53
06:00	14,36	12,26	11,28	13,54	13,63	11,43	12,09
06:30	14,16	12,53	11,41	13,74	14,22	11,5	12,69
07:00	13,55	13,08	12,11	13,89	15,22	11,99	12,89
07:30	13,38	13,43	13,02	13,97	15,96	12,72	13,36
08:00	13,78	13,74	13,39	14,84	16,19	13,18	13,32
08:30	13,71	14,25	14,31	15,41	16,41	13,77	14,15
09:00	13,68	14,52	15,42	15,84	16,94	14,51	14,62
09:30	13,73	14,16	16,39	16,33	17,25	14,65	15,1
10:00	13,55	14,02	15,51	15,92	16,72	15,2	15,18
10:30	13,51	14,07	17,17	15,89	16,75	15,31	15,45
11:00	13,21	14,11	21,95	15,88	16,74	15,52	15,42
11:30	12,65	14,28	21	16,16	16,7	15,67	15,44
12:00	12,37	13,85	18,72	16,22	16,87	15,06	15,07
12:30	11,59	13,81	17,94	16,47	16,25	14,94	14,91

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
13:00	10,82	13,59	16,45	16,43	15,47	14,96	14,81
13:30	11,45	12,78	15,68	16,18	14,79	14,79	14,69
14:00	12,07	13,13	14,99	15,83	14,62	13,71	14,85
14:30	12,14	12,97	15,09	15,77	13,65	13,54	13,83
15:00	11,5	11,79	14,5	15,4	12,81	12,57	13,59
15:30	10,95	10,91	14,01	14,7	12,53	12,57	13
16:00	9,68	10,79	13,11	13,96	12,26	12,02	12,8
16:30	9,78	9,93	12,44	13,53	11,78	11,55	11,64
17:00	9,65	9,31	11,22	12,82	11,27	11,42	11,41
17:30	9,53	8,93	10,85	12,63	11,22	11,65	10,56
18:00	9,23	9,87	10,78	12,83	11,09	11,27	10,47
18:30	9,02	8,93	10,59	12,59	10,8	11,05	10,05
19:00	8,66	8,38	10,13	12,34	10,72	11,1	9,95
19:30	8,97	8,22	9,99	12,82	10,43	11,84	9,97
20:00	8,9	8,47	9,94	13,06	10,2	11,92	10,14
20:30	8,92	8,87	10,24	13,33	9,76	12,24	9,98
21:00	10,47	8,82	10,18	13,59	9,59	12,48	10,2
21:30	10,68	8,95	10,52	13,9	9,56	13,33	10,31
22:00	11,41	9,13	10,44	13,43	9,09	13,94	9,89
22:30	11,77	9,69	10,14	13,21	9,35	14,67	10,09
23:00	11,8	9,86	10,41	13,16	9,55	14,73	10,55
23:30	11,83	9,78	10,97	13,29	9,26	14,21	11,11
00:00	12,13	9,57	11,4	13,13	9,58	14,22	11,38

PM₁₀ SUF 7

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
Tren	-0,000075						
00:30	58,47	68,94	71,66	67,37	64,08	63,33	63,53
01:00	61,57	70,81	74,21	70,45	65,63	66,39	66,53
01:30	64,45	73,11	76,35	73,71	67,49	65,48	70,12
02:00	68,03	75,05	79,64	76,54	71,05	68,78	72,63
02:30	69,92	78,03	82,71	76,87	75,7	73,44	74,1
03:00	71,25	81,31	85,71	79,69	78,42	78,98	79,61
03:30	74,2	86,29	86,02	83,15	84,42	83,1	84,65
04:00	81,75	87,16	90,91	83,98	89,52	86,61	89,92
04:30	86,75	90,31	94,06	86,86	93,27	91,03	94,71
05:00	89,92	91,47	94,81	90,68	94,43	94,16	98,79
05:30	92,72	95,38	98,1	92,59	96,8	97,53	100,27
06:00	91,99	99,21	97,41	97,85	101,2	99,84	103,31
06:30	94,06	104,62	101,07	100,73	101,41	106,04	104,2
07:00	97,28	107,68	101,56	107,83	103,65	112,22	108,69
07:30	99,05	108,87	104,66	112,72	109,17	115,27	110,01
08:00	100,8	114,4	107,56	114,04	107,74	112,93	109,74
08:30	104,44	116,25	110,61	116,13	108,09	113,88	110,76
09:00	102,03	118,13	112,73	114,89	112,1	108,64	111,87
09:30	102,41	117,5	110,93	114,52	112,24	108,19	108,77
10:00	100,56	112,96	110,38	109,63	112,82	103,17	109,07
10:30	90,85	117,47	107,92	111,96	111,48	106,28	107,99
11:00	96,58	115,65	103,93	107,17	113,19	115,64	105,7
11:30	94,89	109,62	96,4	103,45	112,46	105,67	101,19
12:00	93,82	105,55	97,29	97,67	106,61	110,88	94,53
12:30	87,18	104,46	95,4	92,75	101,84	105,65	93,63

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
13:00	89,66	99,87	94,46	92,82	101,92	103,04	89,24
13:30	87,24	93,95	85,91	91,46	103,38	99,81	85,06
14:00	89,54	91,92	78,57	87,53	98,83	91,68	78,18
14:30	82,55	92,96	76,12	80,35	93,1	85,7	73,61
15:00	78,96	88,58	75,1	72,03	82,93	77,26	66,8
15:30	76	78,43	65,89	65,76	73,03	71,49	60,01
16:00	67,82	67,56	61,95	60,66	62,27	62,82	52,14
16:30	62,09	54,61	56,24	61,79	58,39	57,58	47,69
17:00	36,47	31,47	37,56	34,64	30,86	28,05	21,11
17:30	49,4	45,25	45,19	44,43	43,02	43,64	37,86
18:00	47,08	44,34	43,01	42,89	42,6	40,82	36,36
18:30	46,8	44,24	43	42,28	43,63	40,18	36,45
19:00	46,48	44,68	43,06	43,12	43,28	40,96	38,1
19:30	46,97	45,99	43,79	44,35	44,9	41,45	39,98
20:00	49,11	47,09	44,75	45,34	45,37	40,48	42,33
20:30	50,84	49,23	46,43	45,74	43,57	42,33	44,08
21:00	52,59	51,56	48,25	47,62	45,83	44,52	45,61
21:30	55,36	55,09	50,43	49,91	47,33	49,84	47,16
22:00	58,7	58,05	52,73	52,52	48,71	51,12	48,74
22:30	62,07	61,32	54,7	54,79	50,2	53,49	50,35
23:00	64,36	64,21	58,05	57,83	53,19	56,38	51,68
23:30	62,55	68,25	60,63	59,92	58,11	59,18	52,95
00:00	66,32	71,06	64,15	61,92	60,79	59,2	55,28

SO₂ SUF 1

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
Tren	-0,000123						
00:30	25,25	22,88	29,04	29,73	25,09	23,05	23,27
01:00	24,88	22,28	23,87	26,92	26,94	24,68	24,52
01:30	22,61	22,87	25,46	27,16	26,2	29,52	28,96
02:00	25,06	24,33	27,29	30,33	25,23	29,46	26,62
02:30	27,48	26,94	31,21	33,29	27,93	29,67	28,79
03:00	29,37	32,86	30,1	27,52	32,82	32,39	31,49
03:30	32,8	31,97	32,57	30,19	36,41	30,77	34,12
04:00	34,19	33,47	33,28	29,28	38,13	33,59	37,01
04:30	31,82	38,11	35,69	30,63	39,85	41,3	33,89
05:00	33,18	34,32	36,13	35,71	41,07	39,84	31,71
05:30	31,5	33,64	39,06	38,79	41,79	41,18	34,69
06:00	35,45	35,23	39,71	42,65	38,71	44,1	33,13
06:30	38,41	37,05	48,33	41,31	40,66	49,71	37,01
07:00	43,32	43,86	46,72	47,55	46,68	54,83	39,24
07:30	47,46	46,16	53,75	50,11	50,99	60,24	43,05
08:00	46,92	46,75	55,18	49,19	52,32	64,15	39,36
08:30	47,11	45,18	52,6	46,99	47,12	58,05	40,47
09:00	38,8	37,34	42,8	41,93	40,8	51,73	37,66
09:30	33,41	34,17	38,32	36,45	35,93	42,5	33,62
10:00	31,53	31,95	39,67	32,6	34,4	37,68	28,29
10:30	28,91	34,02	34,5	33,08	32,79	29,17	27,35
11:00	33,29	28,35	30,98	33,15	26,03	26	25,22
11:30	31,09	28	28,4	27,47	25,26	24,41	30,36
12:00	31,29	25,67	26,7	24,34	24,27	24,08	27,32
12:30	28,76	25,7	24,78	23,76	23,58	26,55	26,08

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
13:00	29,01	22,93	25,13	24,34	26,33	27,69	24,37
13:30	23,68	23,05	24,17	27,32	25,65	25,06	23,12
14:00	23,61	22,87	23,6	27,38	24,02	23,19	22,42
14:30	23,47	23,67	25,88	24,69	22,84	22,76	21,48
15:00	23,74	27,22	33,71	24,55	25,88	22,28	20,85
15:30	22,61	37,35	23,24	23,69	22,67	21,68	21,53
16:00	23,24	23,2	23,94	21,92	22,13	21,65	20,79
16:30	23,82	22,28	22,29	23,57	22,08	21,23	21,52
17:00	21,18	25,06	22,33	22,09	23,12	23,75	24,67
17:30	22	26,92	22,19	23,18	22,75	24,18	23,89
18:00	22,49	22,64	24,59	22,07	23,84	28,04	22,38
18:30	21,92	23,86	23,08	23,71	28,06	23,11	22,24
19:00	22,58	23	22,88	27,42	22,07	21,82	22,25
19:30	22,43	24,24	23,99	22,68	21,99	22,06	22,23
20:00	22,61	23,81	22,34	21,92	21,31	22,51	21,57
20:30	23,59	22,78	21,86	21,43	21,63	22,62	24,54
21:00	21,77	22,61	23,24	20,74	25,01	25,91	24,09
21:30	21,67	23,18	21,55	23,36	27,64	23,96	21,01
22:00	21,79	21,92	22,78	22,61	25,28	23,14	21,09
22:30	22,08	22,33	22,2	23,94	28,13	23,06	21,8
23:00	22,1	22,04	24,14	27,61	21,61	22,26	21,44
23:30	24,81	23,29	27,37	24,59	21,41	23,75	20,91
00:00	24,6	27,61	24,92	23,39	23,45	23,63	20,56

SO₂ SUF 6

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
Tren	0,000314						
00:30	13,12	16,77	14,85	15,31	13,51	15,26	14,59
01:00	13,62	16,38	17,37	16,05	17,07	17,52	17,29
01:30	14,66	17,27	19,34	18,77	18,51	16,18	17,4
02:00	16,96	17,85	20,6	18,76	19,48	18,02	18,23
02:30	18,59	21,3	21,61	19,27	21,35	20,45	20,66
03:00	19,52	23,18	22,67	18,18	22,26	23,89	21,77
03:30	20,85	25,68	23,04	20,4	22,56	27,12	21,75
04:00	21,2	24,2	24,63	21,22	22,56	26,11	22,31
04:30	22,58	23,31	23,86	21,97	22,26	25,37	22,81
05:00	23,36	23,72	23,54	22,42	22,29	25,83	22,78
05:30	24,09	24,39	24,41	23,43	22,69	25,78	22,95
06:00	25,24	26,21	25,36	23,42	24,41	24,14	22,99
06:30	26,54	29,18	26,91	25,26	26,77	25,65	23,55
07:00	27,98	34,01	29,59	29,13	31,08	27,65	27,2
07:30	31,89	35,46	33,08	30	33,47	32,11	30,01
08:00	32,51	35,88	31,86	28,95	33,47	32,15	30,68
08:30	30,23	29,14	27	26,31	28,85	28,79	27,43
09:00	24,84	24,51	22,63	24,03	23,99	24,37	24,36
09:30	20,88	21,2	20,89	19,94	20,74	20,34	19,11
10:00	18,48	18,93	18,46	17,57	18,09	16,74	17,09
10:30	17,14	17,1	16,19	17,29	15,43	15,26	15,44
11:00	15,86	16	15,1	15,38	14,31	14,14	14,47
11:30	14,76	15,08	14,45	13,85	13,72	13,7	13,69
12:00	13,73	14,25	13,27	13,34	13,14	13,1	13,32
12:30	14,33	13,28	12,98	13,07	12,92	12,86	12,82

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
13:00	13,73	13,2	12,66	13,06	12,84	12,32	13,41
13:30	13,56	13,13	12,35	12,88	12,37	12,9	12,89
14:00	12,93	13,51	12,15	12,43	12,84	13	12,65
14:30	13,02	13,59	12,22	12,45	12,39	12,55	12,33
15:00	12,64	13,78	12,17	12,32	12,38	12,06	12,44
15:30	13	13,03	11,9	12,13	12,23	12,7	12
16:00	12,75	16,86	11,8	12,03	12,52	12,49	12,26
16:30	13	12,46	11,98	12,78	12,54	12,28	11,7
17:00	12,83	12,49	11,8	12,62	12,33	11,94	11,89
17:30	12,91	12,49	12,09	12,49	11,8	12,38	11,56
18:00	12,98	12,7	12,04	12,58	12,24	12,33	11,96
18:30	12,58	12,86	11,96	12,57	12,16	12,23	11,86
19:00	12,51	12,5	11,8	12,09	12,09	12,46	11,92
19:30	12,49	11,97	11,79	12,07	12,27	12,14	12,22
20:00	12,27	12,33	11,46	12,46	12,03	12,28	12,05
20:30	12,74	12,72	11,52	12,88	12,39	11,99	11,71
21:00	12,57	13,81	11,55	12,85	12,3	11,71	11,8
21:30	12,88	13,07	11,87	12,47	12,55	11,46	11,52
22:00	13,06	13,14	12,07	12,34	12,35	11,58	11,39
22:30	13,38	13,23	12,05	12,61	13	12,43	11,42
23:00	13,9	13,57	12,55	12,46	13,44	12,81	11,74
23:30	14,36	13,28	13,38	12,51	13,57	12,67	12,45
00:00	15,58	14,14	14,03	13,07	14,26	13,43	12,91

SO₂ SUF 7

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
Tren	0,000722						
00:30	6,86	9,14	8,52	8,52	8,76	8,20	7,94
01:00	7,72	8,92	8,55	8,92	9,58	9,26	8,22
01:30	8,81	9,44	9,15	9,91	10,12	10,02	8,89
02:00	10,34	10,41	9,55	10,02	10,73	10,44	9,66
02:30	10,61	12,06	10,49	10,35	11,35	11,27	10,59
03:00	10,71	12,16	11,03	10,60	11,43	11,83	11,07
03:30	10,97	12,30	12,01	11,86	12,50	12,63	11,64
04:00	11,03	12,12	12,94	11,61	12,84	12,47	11,92
04:30	11,14	12,25	12,99	11,78	13,47	12,92	11,86
05:00	11,83	13,13	12,86	12,49	13,48	13,54	11,50
05:30	12,81	12,36	12,38	12,62	13,38	14,15	11,33
06:00	12,96	13,21	12,64	13,83	13,76	14,82	11,12
06:30	13,99	13,58	13,63	15,09	14,72	16,03	11,00
07:00	16,54	16,23	16,39	19,94	17,46	18,32	12,83
07:30	19,57	21,16	19,70	22,51	20,52	20,83	15,25
08:00	20,71	24,49	19,62	22,93	22,07	21,92	16,39
08:30	18,70	22,89	17,55	19,27	20,56	19,70	17,15
09:00	16,10	17,62	15,62	17,79	16,19	16,20	13,81
09:30	12,24	13,64	13,51	12,91	13,25	12,97	11,43
10:00	10,55	11,49	11,40	10,32	10,98	10,86	9,82
10:30	9,57	10,18	9,93	9,14	9,98	9,82	8,89
11:00	8,45	9,24	8,83	8,37	9,30	8,63	8,23
11:30	7,87	8,35	8,23	7,98	8,80	8,64	7,15
12:00	8,17	7,74	7,90	7,73	8,43	7,79	6,77
12:30	7,92	7,31	7,50	7,57	8,09	7,46	6,69

Jam	Hari						
	Senin	Selasa	Rabu	Kamis	Jumat	Sabtu	Minggu
13:00	8,07	7,04	7,09	7,77	7,72	7,26	6,42
13:30	7,40	6,79	6,95	7,31	7,43	7,16	6,36
14:00	7,35	7,29	6,76	7,15	7,40	7,02	6,17
14:30	6,93	7,32	6,89	7,39	7,49	7,26	6,11
15:00	7,02	7,32	7,09	7,56	7,89	7,18	6,02
15:30	7,09	7,23	7,43	7,53	8,14	7,10	6,02
16:00	8,07	8,06	8,62	8,24	8,94	7,58	6,67
16:30	11,85	8,74	9,44	8,94	11,90	8,49	7,02
17:00	2,50	2,49	1,99	2,74	3,08	2,17	2,69
17:30	7,99	8,04	7,71	8,20	7,95	7,22	6,21
18:00	8,28	7,76	7,74	8,13	8,09	7,12	6,27
18:30	8,45	7,74	7,85	7,96	8,06	7,13	6,50
19:00	8,89	7,85	7,90	8,33	8,14	7,25	6,66
19:30	8,54	7,96	7,55	8,65	7,92	7,09	6,84
20:00	8,57	7,65	7,78	9,01	7,86	6,87	6,48
20:30	7,98	7,73	7,73	9,05	7,93	7,10	6,75
21:00	8,32	7,66	7,95	8,75	7,66	6,94	6,68
21:30	8,44	7,48	7,89	8,79	7,69	7,04	6,67
22:00	8,65	7,63	7,81	8,58	7,75	6,97	6,68
22:30	8,36	8,08	7,93	8,11	7,77	7,05	6,28
23:00	8,33	7,74	8,06	7,87	7,64	6,90	6,39
23:30	8,61	7,40	8,00	7,57	7,50	7,14	6,52
00:00	9,13	7,84	8,01	8,17	8,04	7,84	6,60

Lampiran 3. *Output* ARIMA pada Lima Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya

CO SUF 1

Persamaan Model ARIMA CO SUF 1

$$\begin{aligned}
 Y_{1,t}^{1*} = & Y_{1,t-1}^{1*} - 0,01561Y_{1,t-10}^{1*} + 0,00193Y_{1,t-11}^{1*} + 0,01368Y_{1,t-12}^{1*} \\
 & - 0,01552Y_{1,t-13}^{1*} + 0,01552Y_{1,t-14}^{1*} - 0,01347Y_{1,t-23}^{1*} \\
 & + 0,01347Y_{1,t-24}^{1*} - 0,01540Y_{1,t-25}^{1*} + 0,01540Y_{1,t-26}^{1*} \\
 & + 0,01369Y_{1,t-29}^{1*} - 0,01369Y_{1,t-30}^{1*} - 0,01804Y_{1,t-32}^{1*} \\
 & + 0,01804Y_{1,t-33}^{1*} + 0,01296Y_{1,t-37}^{1*} - 0,01296Y_{1,t-38}^{1*} \\
 & + 0,01405Y_{1,t-43}^{1*} - 0,01405Y_{1,t-44}^{1*} + Y_{1,t-48}^{1*} - Y_{1,t-49}^{1*} \\
 & + 0,01561Y_{1,t-58}^{1*} - 0,00193Y_{1,t-59}^{1*} - 0,01368Y_{1,t-60}^{1*} \\
 & + 0,01552Y_{1,t-61}^{1*} - 0,01552Y_{1,t-62}^{1*} + 0,01347Y_{1,t-71}^{1*} \\
 & - 0,01347Y_{1,t-72}^{1*} + 0,01540Y_{1,t-73}^{1*} - 0,01504Y_{1,t-74}^{1*} \\
 & - 0,01369Y_{1,t-78}^{1*} + 0,01369Y_{1,t-79}^{1*} + 0,01804Y_{1,t-80}^{1*} \\
 & - 0,01804Y_{1,t-81}^{1*} - 0,01296Y_{1,t-85}^{1*} + 0,01296Y_{1,t-86}^{1*} \\
 & - 0,01405Y_{1,t-91}^{1*} + 0,01405Y_{1,t-92}^{1*} + Y_{1,t-336}^{1*} - Y_{1,t-337}^{1*} \\
 & + 0,01561Y_{1,t-346}^{1*} - 0,00193Y_{1,t-347}^{1*} - 0,01368Y_{1,t-348}^{1*} \\
 & + 0,01552Y_{1,t-349}^{1*} - 0,01552Y_{1,t-350}^{1*} + 0,01347Y_{1,t-359}^{1*} \\
 & - 0,01347Y_{1,t-360}^{1*} + 0,01540Y_{1,t-361}^{1*} - 0,01540Y_{1,t-362}^{1*} \\
 & - 0,01369Y_{1,t-365}^{1*} + 0,01369Y_{1,t-366}^{1*} + 0,01804Y_{1,t-368}^{1*} \\
 & - 0,01804Y_{1,t-369}^{1*} - 0,01296Y_{1,t-373}^{1*} + 0,01296Y_{1,t-374}^{1*} \\
 & - 0,01405Y_{1,t-379}^{1*} + 0,01405Y_{1,t-380}^{1*} - Y_{1,t-384}^{1*} + Y_{1,t-385}^{1*} \\
 & - 0,01561Y_{1,t-394}^{1*} + 0,00193Y_{1,t-395}^{1*} + 0,01368Y_{1,t-396}^{1*} \\
 & - 0,01552Y_{1,t-397}^{1*} + 0,01522Y_{1,t-398}^{1*} - 0,01347Y_{1,t-407}^{1*}
 \end{aligned}$$

$$\begin{aligned}
& -0,01552Y_{1,t-397}^{1*} + 0,01522Y_{1,t-398}^{1*} - 0,01347Y_{1,t-407}^{1*} \\
& + 0,01347Y_{1,t-408}^{1*} - 0,01540Y_{1,t-409}^{1*} + 0,01540Y_{1,t-410}^{1*} \\
& + 0,01369Y_{1,t-413}^{1*} - 0,01369Y_{1,t-414}^{1*} - 0,01804Y_{1,t-416}^{1*} \\
& + 0,01804Y_{1,t-417}^{1*} + 0,01296Y_{1,t-421}^{1*} - 0,01296Y_{1,t-422}^{1*} \\
& + 0,01405Y_{1,t-427}^{1*} - 0,01405Y_{1,t-428}^{1*} + a_{1,t}^1 - 0,21251a_{1,t-1}^1 \\
& - 0,14524a_{1,t-2}^1 - 0,09976a_{1,t-3}^1 - 0,06560a_{1,t-4}^1 \\
& - 0,05231a_{1,t-5}^1 - 0,06296a_{1,t-6}^1 - 0,03315a_{1,t-7}^1 \\
& - 0,02290a_{1,t-8}^1 - 0,02212a_{1,t-9}^1 - 0,02364a_{1,t-12}^1 \\
& + 0,01753a_{1,t-46}^1 + 0,09958a_{1,t-47}^1 - 0,85272a_{1,t-48}^1 \\
& + 0,16333a_{1,t-49}^1 + 0,11163a_{1,t-50}^1 + 0,07667a_{1,t-51}^1 \\
& + 0,05042a_{1,t-52}^1 + 0,04020a_{1,t-53}^1 + 0,04839a_{1,t-54}^1 \\
& + 0,02548a_{1,t-55}^1 + 0,01760a_{1,t-56}^1 + 0,01700a_{1,t-57}^1 \\
& + 0,01817a_{1,t-60}^1 - 0,01347a_{1,t-94}^1 - 0,07653a_{1,t-95}^1 \\
& + 0,06468a_{1,t-96}^1 - 0,76645a_{1,t-336}^1 + 0,16288a_{1,t-337}^1 \\
& + 0,11132a_{1,t-338}^1 + 0,07646a_{1,t-339}^1 + 0,05028a_{1,t-340}^1 \\
& + 0,04009a_{1,t-341}^1 + 0,04826a_{1,t-342}^1 + 0,02541a_{1,t-343}^1 \\
& + 0,01755a_{1,t-344}^1 + 0,01695a_{1,t-345}^1 + 0,01812a_{1,t-348}^1 \\
& - 0,01344a_{1,t-382}^1 - 0,07632a_{1,t-383}^1 + 0,65357a_{1,t-384}^1 \\
& - 0,12518a_{1,t-385}^1 - 0,08566a_{1,t-386}^1 - 0,05876a_{1,t-387}^1 \\
& - 0,03864a_{1,t-388}^1 - 0,03801a_{1,t-389}^1 - 0,03709a_{1,t-390}^1 \\
& - 0,01953a_{1,t-391}^1 - 0,01349a_{1,t-392}^1 - 0,01303a_{1,t-393}^1 \\
& - 0,01393a_{1,t-396}^1 + 0,01033a_{1,t-430}^1 + 0,05866a_{1,t-431}^1 \\
& + 0,04958a_{1,t-432}^1
\end{aligned}$$

CO SUF 6

Parameter	Estimate	Standard Error	t Value	Approx Pr > t 	Lag
MA1,1	0.24335	0.0086736	28.06	<.0001	2
MA1,2	0.12211	0.0080027	15.26	<.0001	3
MA1,3	0.07439	0.0079592	9.35	<.0001	4
MA1,4	0.06136	0.0080209	7.65	<.0001	5
MA1,5	0.02960	0.0080211	3.69	0.0002	6
MA1,6	0.03053	0.0079969	3.82	0.0001	7
MA1,7	0.01845	0.0078520	2.35	0.0188	8
MA1,8	0.04657	0.0080154	5.81	<.0001	9
MA1,9	0.02392	0.0078712	3.04	0.0024	11
MA1,10	0.08051	0.01345	5.98	<.0001	14
MA1,11	0.02047	0.0074620	2.74	0.0061	22
MA1,12	-0.01583	0.0073719	-2.15	0.0318	35
MA1,13	0.01428	0.0076570	1.87	0.0621	40
MA1,14	-0.05125	0.0083899	-6.11	<.0001	43
MA2,1	0.78808	0.0051123	154.15	<.0001	48
MA3,1	0.79691	0.0049123	162.23	<.0001	336
AR1,1	-0.52113	0.0075028	-69.46	<.0001	1
AR1,2	0.05526	0.01165	4.74	<.0001	14
AR1,3	0.01617	0.0068465	2.36	0.0182	17
AR1,4	0.01549	0.0073693	2.10	0.0356	42
AR1,5	-0.02892	0.0077739	-3.72	0.0002	46
AR1,6	0.15372	0.0079476	19.34	<.0001	47

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	-0.001	0.001	0.000	0.001	0.000	0.001
12	.	0	.	0.001	0.003	-0.002	-0.011	-0.001	0.012
18	.	0	.	0.002	0.001	-0.006	0.004	-0.001	-0.009
24	10.03	2	0.0066	0.010	-0.002	0.003	0.003	-0.007	-0.003
30	14.42	8	0.0715	0.001	-0.007	-0.008	-0.005	0.011	-0.004
36	20.48	14	0.1158	-0.008	0.013	-0.001	0.009	-0.001	0.007
42	20.91	20	0.4025	-0.000	-0.004	0.000	-0.001	0.001	-0.003
48	26.47	26	0.4376	-0.004	-0.009	0.007	0.005	0.001	0.012

CO SUF 7

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.27208	0.0077413	35.15	<.0001	1
MA1,2	0.11063	0.0080262	13.78	<.0001	2
MA1,3	0.10572	0.0080841	13.08	<.0001	3
MA1,4	0.09475	0.0080932	11.71	<.0001	4
MA1,5	0.05203	0.0081347	6.40	<.0001	5
MA1,6	0.03911	0.0081028	4.83	<.0001	6
MA1,7	0.03792	0.0081306	4.66	<.0001	7
MA1,8	0.06405	0.0079547	8.05	<.0001	8
MA1,9	0.03264	0.0076442	4.27	<.0001	13
MA1,10	0.01884	0.0077803	2.42	0.0155	15
MA1,11	0.01716	0.0077125	2.22	0.0261	16
MA1,12	0.02994	0.0066135	4.53	<.0001	32
MA2,1	0.75917	0.0051515	147.37	<.0001	48

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA3,1	0.77408	0.0050558	153.11	<.0001	336
AR1,1	-0.01842	0.0079832	-2.31	0.0211	11
AR1,2	0.03634	0.0079141	4.59	<.0001	21
AR1,3	-0.01674	0.0078338	-2.14	0.0327	26
AR1,4	0.02581	0.0078289	3.30	0.0010	28
AR1,5	-0.01347	0.0078160	-1.72	0.0849	30
AR1,6	0.02164	0.0078388	2.76	0.0058	39
AR1,7	0.04892	0.0078126	6.26	<.0001	47

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	0.001	0.002	0.001	0.001	0.002	0.004
12	.	0	.	0.004	0.006	-0.005	-0.007	-0.001	-0.002
18	.	0	.	0.005	-0.010	0.003	0.005	-0.005	0.001
24	7.31	3	0.0627	0.005	0.008	-0.000	-0.003	0.003	-0.005
30	9.33	9	0.4075	0.001	-0.001	0.001	-0.000	-0.011	0.000
36	13.36	15	0.5746	-0.006	0.006	-0.000	-0.006	-0.007	0.009
42	19.64	21	0.5440	-0.011	0.003	-0.001	-0.004	-0.015	-0.002
48	24.97	27	0.5763	-0.007	0.008	0.009	0.011	-0.001	0.004

NO₂ SUF 1

Parameter	Estimate	Standard Error	t Value	Approx Pr > t 	Lag
MA1,1	0.18706	0.0077570	24.11	<.0001	1
MA1,2	0.20179	0.0078963	25.56	<.0001	2
MA1,3	0.10849	0.0080605	13.46	<.0001	3
MA1,4	0.09265	0.0080767	11.47	<.0001	4
MA1,5	0.03918	0.0081008	4.84	<.0001	5
MA1,6	0.05084	0.0080859	6.29	<.0001	7
MA1,7	0.02204	0.0080270	2.75	0.0060	8
MA1,8	0.02669	0.0079147	3.37	0.0007	10
MA1,9	0.03041	0.0078437	3.88	0.0001	11
MA1,10	-0.02409	0.0078378	-3.07	0.0021	18
MA1,11	0.02008	0.0078904	2.54	0.0109	19
MA1,12	0.02561	0.0079340	3.23	0.0012	20
MA1,13	-0.02338	0.0078943	-2.96	0.0031	21
MA1,14	0.02408	0.0076855	3.13	0.0017	24
MA1,15	-0.03373	0.0076644	-4.40	<.0001	27
MA1,16	0.02054	0.0075724	2.71	0.0067	29
MA2,1	0.75977	0.0065659	115.71	<.0001	48
MA3,1	0.76767	0.0052992	144.87	<.0001	336
AR1,1	-0.02096	0.0079331	-2.64	0.0082	6
AR1,2	-0.01470	0.0079214	-1.86	0.0635	9
AR1,3	-0.01294	0.0078444	-1.65	0.0991	13
AR1,4	0.01312	0.0077276	1.70	0.0897	33
AR1,5	0.01613	0.0076904	2.10	0.0359	36
AR1,6	0.18894	0.0076296	24.76	<.0001	47
AR1,7	-0.08362	0.0095720	-8.74	<.0001	48

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	-0.000	0.000	0.001	0.001	0.001	-0.004
12	.	0	.	0.001	0.000	-0.002	0.000	-0.001	0.001
18	.	0	.	-0.001	-0.004	0.012	-0.002	-0.011	-0.001
24	.	0	.	-0.002	-0.002	-0.003	0.002	-0.002	-0.003
30	10.50	5	0.0622	0.005	0.004	-0.003	-0.012	-0.008	0.002
36	11.55	11	0.3984	-0.001	-0.006	0.002	0.004	0.001	-0.001
42	15.40	17	0.5664	0.007	0.011	-0.004	0.004	0.004	-0.002
48	26.28	23	0.2880	0.006	-0.005	0.011	-0.010	-0.019	0.002

NO₂ SUF 6

Parameter	Estimate	Standard Error	t Value	Approx Pr > t 	Lag
MA1,1	0.10062	0.0077471	12.99	<.0001	1
MA1,2	0.19634	0.0077955	25.19	<.0001	2
MA1,3	0.13486	0.0079254	17.02	<.0001	3
MA1,4	0.07929	0.0079995	9.91	<.0001	4
MA1,5	0.05655	0.0080097	7.06	<.0001	5
MA1,6	0.04629	0.0080071	5.78	<.0001	6
MA1,7	0.03691	0.0079727	4.63	<.0001	7
MA1,8	0.05215	0.0079752	6.54	<.0001	9
MA1,9	0.03467	0.0078088	4.44	<.0001	11
MA1,10	0.03564	0.0073466	4.85	<.0001	21
MA1,11	0.02149	0.0074065	2.90	0.0037	22
MA1,12	0.02895	0.0077118	3.75	0.0002	45
MA1,13	-0.02494	0.01506	-1.66	0.0978	47

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA2,1	0.77383	0.0064048	120.82	<.0001	48
MA3,1	0.77186	0.0052030	148.35	<.0001	336
AR1,1	-0.01449	0.0079954	-1.81	0.0700	8
AR1,2	-0.01858	0.0078691	-2.36	0.0182	15
AR1,3	-0.01477	0.0078670	-1.88	0.0605	16
AR1,4	-0.02011	0.0078310	-2.57	0.0102	17
AR1,5	0.01708	0.0078035	2.19	0.0286	33
AR1,6	0.01496	0.0077756	1.92	0.0543	35
AR1,7	0.01679	0.0077739	2.16	0.0308	43
AR1,8	0.10456	0.01611	6.49	<.0001	47
AR1,9	-0.05652	0.0098702	-5.73	<.0001	48

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	0.001	0.001	0.002	0.001	0.002	0.004
12	.	0	.	0.004	-0.001	0.003	-0.010	0.005	0.003
18	.	0	.	-0.007	-0.004	0.000	-0.001	0.001	-0.002
24	.	0	.	-0.011	-0.001	0.003	0.003	-0.000	-0.010
30	12.41	6	0.0534	0.009	-0.010	-0.007	0.006	0.003	-0.002
36	17.31	12	0.1385	-0.007	-0.011	-0.001	0.011	0.000	0.001
42	20.53	18	0.3039	0.001	-0.006	-0.001	-0.012	0.002	0.004
48	23.78	24	0.4740	-0.001	0.003	-0.004	-0.012	-0.005	-0.002

NO₂ SUF 7

Parameter	Estimate	Standard Error	t Value	Approx Pr > t 	Lag
MA1,1	0.14510	0.0077368	18.75	<.0001	1
MA1,2	0.16249	0.0078226	20.77	<.0001	2
MA1,3	0.14219	0.0079225	17.95	<.0001	3
MA1,4	0.08117	0.0079926	10.16	<.0001	4
MA1,5	0.07967	0.0079961	9.96	<.0001	5
MA1,6	0.06089	0.0080174	7.60	<.0001	6
MA1,7	0.04768	0.0080140	5.95	<.0001	7
MA1,8	0.03761	0.0079622	4.72	<.0001	9
MA1,9	0.04492	0.0078416	5.73	<.0001	13
MA1,10	0.04358	0.0077582	5.62	<.0001	16
MA1,11	0.02409	0.0076766	3.14	0.0017	22
MA1,12	0.02193	0.0076240	2.88	0.0040	26
MA1,13	0.02884	0.0076157	3.79	0.0002	27
MA1,14	0.02092	0.0075616	2.77	0.0057	33
MA1,15	-0.01905	0.0073312	-2.60	0.0094	38
MA1,16	-0.01584	0.0069711	-2.27	0.0231	46
MA2,1	0.77476	0.0050947	152.07	<.0001	48
MA3,1	0.81285	0.0047276	171.94	<.0001	336
AR1,1	-0.01882	0.0080629	-2.33	0.0196	8
AR1,2	-0.02044	0.0080134	-2.55	0.0108	10
AR1,3	-0.02121	0.0079878	-2.65	0.0079	14
AR1,4	-0.02371	0.0079955	-2.97	0.0030	15
AR1,5	-0.01641	0.0079196	-2.07	0.0383	21
AR1,6	0.01596	0.0079887	2.00	0.0457	29

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,7	0.01876	0.0079198	2.37	0.0178	40
AR1,8	0.01799	0.0078575	2.29	0.0221	47

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	0.001	0.002	0.002	0.002	0.003	0.004
12	.	0	.	0.005	-0.000	0.006	-0.001	-0.011	-0.010
18	.	0	.	0.004	-0.000	0.000	0.006	-0.010	-0.010
24	.	0	.	-0.006	-0.009	0.001	0.001	0.002	-0.002
30	13.58	4	0.0088	-0.005	0.001	0.001	-0.008	0.001	0.001
36	20.44	10	0.0254	0.011	-0.009	-0.001	0.002	-0.005	0.013
42	26.70	16	0.0449	0.009	0.007	0.008	0.001	0.001	0.014
48	31.01	22	0.0959	-0.002	-0.002	0.008	0.011	-0.001	-0.007

O₃ SUF 1

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.11297	0.02603	4.34	<.0001	1
MA1,2	0.16744	0.0086662	19.32	<.0001	2
MA1,3	0.09535	0.0078553	12.14	<.0001	3
MA1,4	0.16719	0.01370	12.21	<.0001	4
MA1,5	0.04816	0.0075245	6.40	<.0001	5
MA1,6	0.11699	0.01280	9.14	<.0001	6
MA1,7	0.04195	0.0077327	5.42	<.0001	7
MA1,8	0.02055	0.0083354	2.46	0.0137	8

Parameter	Estimate	Standard Error	t Value	Approx Pr > t 	Lag
MA1,9	0.05805	0.01004	5.78	<.0001	14
MA1,10	0.01707	0.0066076	2.58	0.0098	25
MA1,11	0.01440	0.0065782	2.19	0.0286	26
MA1,12	0.01269	0.0066734	1.90	0.0572	31
MA1,13	-0.01598	0.0064560	-2.48	0.0133	35
MA1,14	-0.13489	0.01358	-9.93	<.0001	43
MA1,15	-0.10196	0.01238	-8.24	<.0001	44
MA1,16	-0.30712	0.01268	-24.23	<.0001	45
MA1,17	0.11380	0.0091930	12.38	<.0001	46
MA1,18	0.39655	0.01224	32.39	<.0001	47
MA2,1	0.83316	0.0053202	156.60	<.0001	48
MA3,1	0.85135	0.0045120	188.69	<.0001	336
AR1,1	-0.05543	0.02581	-2.15	0.0318	1
AR1,2	0.08298	0.01098	7.56	<.0001	4
AR1,3	0.07084	0.01068	6.64	<.0001	6
AR1,4	0.03644	0.0076374	4.77	<.0001	14
AR1,5	0.01552	0.0053091	2.92	0.0035	38
AR1,6	0.01720	0.0053815	3.20	0.0014	40
AR1,7	-0.10730	0.01082	-9.92	<.0001	43
AR1,8	-0.10917	0.0096244	-11.34	<.0001	44
AR1,9	-0.30058	0.01092	-27.53	<.0001	45
AR1,10	0.60863	0.0097123	62.67	<.0001	47
AR1,11	-0.07804	0.01548	-5.04	<.0001	48

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	-0.009	-0.003	0.005	-0.004	-0.007	0.008
12	.	0	.	0.012	0.009	0.010	-0.003	-0.002	0.001
18	.	0	.	-0.001	0.007	-0.010	-0.005	-0.003	-0.005
24	.	0	.	-0.010	-0.006	0.004	-0.004	-0.013	-0.003
30	.	0	.	-0.005	-0.006	0.008	0.011	-0.005	-0.012
36	28.35	5	<.0001	-0.009	-0.003	-0.005	-0.007	-0.001	0.002
42	30.45	11	0.0013	0.005	0.001	0.001	-0.001	-0.004	-0.009
48	53.44	17	<.0001	-0.008	-0.016	-0.025	-0.018	0.003	0.009

O₃ SUF 6

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.02567	0.0073311	3.50	0.0005	1
MA1,2	0.57586	0.01946	29.59	<.0001	2
MA1,3	0.39732	0.01950	20.37	<.0001	3
MA1,4	-0.04623	0.01911	-2.42	0.0155	46
MA1,5	0.04259	0.01902	2.24	0.0252	47
MA2,1	0.82776	0.0052207	158.55	<.0001	48
MA3,1	0.82972	0.0046365	178.95	<.0001	336
AR1,1	0.39518	0.02007	19.69	<.0001	2
AR1,2	0.27339	0.01861	14.69	<.0001	3
AR1,3	0.04442	0.0077156	5.76	<.0001	5
AR1,4	-0.01394	0.0074157	-1.88	0.0601	26
AR1,5	0.02136	0.0073957	2.89	0.0039	28
AR1,6	0.01906	0.0068139	2.80	0.0052	34

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,7	0.02344	0.0071450	3.28	0.0010	43
AR1,8	0.03096	0.0076669	4.04	<.0001	44
AR1,9	-0.09131	0.01945	-4.69	<.0001	46
AR1,10	0.19736	0.01830	10.79	<.0001	47
AR1,11	-0.05715	0.0084095	-6.80	<.0001	48

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	0.002	0.003	0.000	-0.002	0.003	-0.002
12	.	0	.	-0.002	-0.001	-0.002	0.014	0.004	-0.010
18	.	0	.	-0.003	-0.001	-0.002	-0.015	-0.015	0.005
24	20.30	6	0.0024	0.009	0.003	-0.004	-0.013	0.003	0.009
30	22.48	12	0.0324	0.006	-0.007	0.002	0.002	-0.005	-0.004
36	25.32	18	0.1164	0.002	-0.013	0.001	-0.000	0.000	-0.001
42	33.57	24	0.0925	-0.002	0.014	-0.004	0.004	0.010	0.013
48	35.52	30	0.2243	0.002	-0.004	0.003	0.001	0.001	-0.009

O₃ SUF 7

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.07720	0.0077491	9.96	<.0001	1
MA1,2	0.16206	0.0077414	20.93	<.0001	2
MA1,3	0.11513	0.0078382	14.69	<.0001	3
MA1,4	0.09122	0.0078992	11.55	<.0001	4
MA1,5	0.08966	0.0079156	11.33	<.0001	5
MA1,6	0.05140	0.0079213	6.49	<.0001	6

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,7	0.06004	0.0078984	7.60	<.0001	7
MA1,8	0.03708	0.0079263	4.68	<.0001	8
MA1,9	0.03756	0.0078513	4.78	<.0001	11
MA1,10	0.05059	0.0077933	6.49	<.0001	12
MA1,11	0.05329	0.01800	2.96	0.0031	19
MA1,12	-0.03046	0.0075004	-4.06	<.0001	38
MA1,13	-0.02790	0.0074041	-3.77	0.0002	39
MA1,14	0.02381	0.0085777	2.78	0.0055	48
MA2,1	0.79443	0.0059054	134.53	<.0001	48
MA3,1	0.75125	0.0053934	139.29	<.0001	336
AR1,1	-0.01549	0.0079814	-1.94	0.0523	13
AR1,2	-0.01601	0.0079494	-2.01	0.0440	16
AR1,3	0.03238	0.01891	1.71	0.0869	19
AR1,4	0.02023	0.0081376	2.49	0.0129	24

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	-0.000	0.001	0.002	0.002	0.001	0.002
12	.	0	.	0.004	0.004	0.002	-0.007	0.005	0.004
18	.	0	.	-0.000	-0.004	-0.009	-0.000	0.002	-0.011
24	7.68	4	0.1039	0.000	0.004	0.005	0.002	-0.008	0.000
30	11.84	10	0.2958	0.008	-0.002	-0.007	-0.002	-0.005	-0.010
36	20.76	16	0.1880	0.008	-0.002	-0.012	-0.008	0.013	-0.009
42	25.88	22	0.2567	-0.000	-0.007	-0.010	-0.011	-0.004	0.005
48	30.71	28	0.3303	0.000	0.004	0.007	0.010	0.002	-0.012

PM₁₀ SUF 1

Parameter	Estimate	Standard Error	t Value	Approx Pr > t 	Lag
MA1,1	0.13620	0.0077964	17.47	<.0001	1
MA1,2	0.06068	0.0077786	7.80	<.0001	2
MA1,3	0.11799	0.0077996	15.13	<.0001	3
MA1,4	0.04839	0.0078380	6.17	<.0001	4
MA1,5	0.06392	0.0078530	8.14	<.0001	5
MA1,6	0.07180	0.0078613	9.13	<.0001	6
MA1,7	0.07104	0.0078794	9.02	<.0001	7
MA1,8	0.06673	0.0078997	8.45	<.0001	8
MA1,9	0.05094	0.0079033	6.45	<.0001	9
MA1,10	0.04044	0.0079205	5.11	<.0001	10
MA1,11	0.04140	0.0078755	5.26	<.0001	15
MA1,12	0.02334	0.0078827	2.96	0.0031	16
MA1,13	0.03916	0.0078597	4.98	<.0001	18
MA1,14	0.01895	0.0078759	2.41	0.0162	19
MA1,15	0.02470	0.0078658	3.14	0.0017	22
MA1,16	-0.03721	0.0078261	-4.75	<.0001	23
MA1,17	-0.02871	0.0078746	-3.65	0.0003	24
MA1,18	0.02515	0.0078281	3.21	0.0013	27
MA1,19	0.02127	0.0077955	2.73	0.0064	28
MA1,20	0.03029	0.0078083	3.88	0.0001	32
MA1,21	-0.04089	0.0077421	-5.28	<.0001	35
MA1,22	-0.02736	0.0077523	-3.53	0.0004	40
MA1,23	-0.03901	0.0078004	-5.00	<.0001	46
MA1,24	0.06796	0.01677	4.05	<.0001	47
MA2,1	0.82586	0.0046989	175.76	<.0001	48

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA3,1	0.82258	0.0046794	175.79	<.0001	336
AR1,1	-0.01755	0.0079416	-2.21	0.0272	11
AR1,2	-0.01811	0.0079265	-2.28	0.0224	13
AR1,3	-0.01808	0.0079358	-2.28	0.0227	25
AR1,4	0.01585	0.0079191	2.00	0.0453	33
AR1,5	0.01460	0.0078751	1.85	0.0638	44
AR1,6	0.10372	0.01757	5.90	<.0001	47

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	0.000	-0.001	0.001	0.003	0.002	0.001
12	.	0	.	-0.001	0.000	0.002	0.002	-0.001	-0.002
18	.	0	.	0.002	-0.013	0.003	-0.002	0.012	0.001
24	.	0	.	0.002	-0.011	-0.007	0.001	-0.001	-0.003
30	.	0	.	-0.001	-0.001	-0.003	0.001	-0.010	0.004
36	14.64	4	0.0055	-0.007	-0.002	-0.001	0.012	-0.003	0.001
42	18.97	10	0.0406	-0.003	0.008	0.011	-0.002	-0.007	-0.002
48	20.14	16	0.2142	-0.002	-0.000	-0.001	-0.006	-0.002	-0.006

PM₁₀ SUF 6

Parameter	Estimate	Standard Error	t Value	Approx Pr > t 	Lag
MA1,1	0.33129	0.03348	9.89	<.0001	1
MA1,2	0.18876	0.0089009	21.21	<.0001	2
MA1,3	-0.03181	0.0083140	-3.83	0.0001	4
MA1,4	0.03686	0.0073090	5.04	<.0001	8
MA1,5	0.04902	0.0073342	6.68	<.0001	13
MA1,6	0.07543	0.0085774	8.79	<.0001	15
MA1,7	0.23355	0.0092205	25.33	<.0001	16
MA1,8	0.02493	0.0080654	3.09	0.0020	20
MA1,9	-0.02891	0.0075974	-3.80	0.0001	47
MA2,1	0.77362	0.0060991	126.84	<.0001	48
MA3,1	0.80146	0.0049407	162.21	<.0001	336
AR1,1	0.50455	0.03399	14.84	<.0001	1
AR1,2	-0.03344	0.0072279	-4.63	<.0001	6
AR1,3	-0.01442	0.0078563	-1.84	0.0664	14
AR1,4	0.08096	0.01150	7.04	<.0001	17
AR1,5	0.03069	0.0077873	3.94	<.0001	33
AR1,6	0.01801	0.0078208	2.30	0.0213	45
AR1,7	-0.02169	0.0085421	-2.54	0.0111	46
AR1,8	-0.02910	0.0084656	-3.44	0.0006	48

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	-0.000	0.003	0.001	0.003	-0.005	0.003
12	.	0	.	-0.006	0.007	-0.008	-0.001	0.002	-0.010
18	.	0	.	0.007	-0.004	0.002	0.001	0.002	-0.007
24	9.99	5	0.0756	0.005	0.001	-0.000	-0.008	0.004	-0.009
30	16.56	11	0.1217	0.010	-0.004	0.008	-0.008	-0.004	-0.012
36	19.79	17	0.2849	-0.003	0.009	0.006	-0.006	-0.005	0.003
42	27.20	23	0.2474	-0.001	-0.002	0.014	-0.015	0.003	0.003
48	37.77	29	0.1275	0.015	-0.005	0.001	-0.002	0.008	-0.018

PM₁₀ SUF 7

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.11587	0.0077256	15.00	<.0001	1
MA1,2	0.13332	0.0078172	17.05	<.0001	2
MA1,3	0.05981	0.0078427	7.63	<.0001	3
MA1,4	0.04240	0.0078764	5.38	<.0001	4
MA1,5	0.04196	0.0078535	5.34	<.0001	5
MA1,6	0.05228	0.0078824	6.63	<.0001	6
MA1,7	0.06067	0.0077583	7.82	<.0001	10
MA1,8	0.05426	0.0078014	6.96	<.0001	12
MA1,9	0.04102	0.0078174	5.25	<.0001	14
MA1,10	0.04342	0.0078015	5.57	<.0001	16
MA1,11	0.03861	0.0077341	4.99	<.0001	21
MA1,12	0.02830	0.0078266	3.62	0.0003	22
MA1,13	0.03237	0.0077666	4.17	<.0001	23

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,14	0.03565	0.0078042	4.57	<.0001	24
MA1,15	-0.02085	0.0074272	-2.81	0.0050	41
MA1,16	-0.01867	0.0074589	-2.50	0.0123	47
MA2,1	0.72633	0.0073430	98.91	<.0001	48
MA3,1	0.78467	0.0049957	157.07	<.0001	336
AR1,1	-0.02251	0.0079228	-2.84	0.0045	7
AR1,2	-0.02760	0.0078944	-3.50	0.0005	8
AR1,3	-0.03007	0.0078404	-3.84	0.0001	9
AR1,4	-0.01695	0.0078546	-2.16	0.0310	11
AR1,5	-0.01987	0.0079015	-2.51	0.0119	15
AR1,6	-0.01780	0.0078953	-2.25	0.0242	18
AR1,7	-0.01303	0.0078524	-1.66	0.0971	27
AR1,8	-0.01393	0.0078167	-1.78	0.0747	37
AR1,9	-0.01295	0.0078307	-1.65	0.0981	38
AR1,10	-0.01374	0.0078192	-1.76	0.0790	44
AR1,11	-0.04603	0.01044	-4.41	<.0001	48

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	0.003	0.001	0.004	0.003	0.004	0.004
12	.	0	.	0.001	-0.001	0.000	0.004	-0.001	0.006
18	.	0	.	-0.010	0.006	-0.001	0.008	-0.011	-0.000
24	.	0	.	-0.010	-0.004	0.004	0.005	0.007	0.009
30	15.16	1	<.0001	-0.005	-0.011	-0.001	-0.004	-0.002	-0.006
36	20.19	7	0.0052	0.004	-0.013	-0.005	-0.009	0.000	0.004

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
42	24.78	13	0.0246	-0.001	0.000	-0.011	-0.009	0.004	0.007
48	28.66	19	0.0716	0.003	-0.001	-0.001	-0.011	0.010	-0.002

SO₂ SUF 1

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.21729	0.0077766	27.94	<.0001	2
MA1,2	0.18467	0.0072838	25.35	<.0001	3
MA1,3	0.09988	0.0072498	13.78	<.0001	4
MA1,4	0.07222	0.0073999	9.76	<.0001	5
MA1,5	0.06788	0.0074794	9.08	<.0001	6
MA1,6	0.05688	0.0075389	7.55	<.0001	8
MA1,7	0.04005	0.0072652	5.51	<.0001	9
MA1,8	0.03156	0.0070379	4.48	<.0001	21
MA1,9	-0.02351	0.0067563	-3.48	0.0005	27
MA1,10	-0.09191	0.01702	-5.40	<.0001	43
MA1,11	-0.21339	0.01627	-13.11	<.0001	45
MA1,12	0.05491	0.01402	3.92	<.0001	46
MA1,13	0.31554	0.01493	21.13	<.0001	47
MA2,1	0.79574	0.0052431	151.77	<.0001	48
MA3,1	0.82876	0.0048334	171.47	<.0001	336
AR1,1	-0.23166	0.0064743	-35.78	<.0001	1
AR1,2	-0.02660	0.0060888	-4.37	<.0001	7
AR1,3	-0.01212	0.0058216	-2.08	0.0373	15
AR1,4	-0.01620	0.0061488	-2.63	0.0084	17

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,5	-0.01386	0.0063946	-2.17	0.0302	18
AR1,6	-0.01712	0.0064698	-2.65	0.0082	19
AR1,7	-0.02030	0.0062623	-3.24	0.0012	20
AR1,8	-0.01583	0.0061790	-2.56	0.0104	42
AR1,9	-0.10071	0.01455	-6.92	<.0001	43
AR1,10	-0.07620	0.0074110	-10.28	<.0001	44
AR1,11	-0.22447	0.01355	-16.56	<.0001	45
AR1,12	-0.03055	0.01182	-2.58	0.0098	46
AR1,13	0.55994	0.01053	53.20	<.0001	47

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	-0.003	-0.005	0.008	0.001	-0.012	-0.003
12	.	0	.	-0.011	0.015	0.012	-0.008	-0.005	-0.015
18	.	0	.	-0.005	-0.009	-0.011	-0.009	-0.001	-0.014
24	.	0	.	-0.003	-0.011	-0.003	-0.012	-0.010	0.006
30	33.48	2	<.0001	0.001	-0.003	0.004	0.002	0.000	0.002
36	36.93	8	<.0001	0.004	-0.004	-0.011	-0.002	-0.004	0.006
42	45.70	14	<.0001	-0.004	-0.015	-0.014	0.008	-0.001	-0.005
48	80.03	20	<.0001	-0.021	0.006	-0.021	-0.033	-0.002	-0.007

SO₂ SUF 6

Parameter	Estimate	Standard Error	t Value	Approx Pr > t 	Lag
MA1,1	-0.02457	0.0077129	-3.19	0.0014	1
MA1,2	0.16209	0.0077116	21.02	<.0001	2
MA1,3	0.10279	0.0076446	13.45	<.0001	3
MA1,4	0.05715	0.0076633	7.46	<.0001	4
MA1,5	0.02621	0.0075013	3.49	0.0005	8
MA1,6	0.04201	0.0074651	5.63	<.0001	15
MA1,7	0.03678	0.0074561	4.93	<.0001	16
MA1,8	0.02573	0.0075341	3.42	0.0006	17
MA1,9	0.01197	0.0075647	1.58	0.1136	20
MA1,10	0.02306	0.0074453	3.10	0.0020	21
MA1,11	0.01681	0.0074591	2.25	0.0242	22
MA1,12	-0.01602	0.0074774	-2.14	0.0322	28
MA1,13	0.01133	0.0073910	1.53	0.1255	29
MA1,14	0.02831	0.0074716	3.79	0.0002	30
MA1,15	-0.03025	0.0073945	-4.09	<.0001	36
MA1,16	0.04116	0.0074827	5.50	<.0001	45
MA1,17	0.02291	0.0074483	3.08	0.0021	46
MA1,18	0.24924	0.01607	15.51	<.0001	47
MA2,1	0.84054	0.0049215	170.79	<.0001	48
MA3,1	0.85208	0.0043671	195.11	<.0001	336
AR1,1	-0.01897	0.0065042	-2.92	0.0036	5
AR1,2	-0.02087	0.0065118	-3.21	0.0014	6
AR1,3	-0.01420	0.0064165	-2.21	0.0269	7
AR1,4	-0.02126	0.0063879	-3.33	0.0009	9
AR1,5	-0.02277	0.0064811	-3.51	0.0004	10

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,6	-0.03703	0.0064299	-5.76	<.0001	11
AR1,7	-0.02749	0.0064225	-4.28	<.0001	12
AR1,8	-0.02326	0.0063730	-3.65	0.0003	13
AR1,9	-0.02667	0.0063688	-4.19	<.0001	14
AR1,10	-0.01985	0.0064964	-3.06	0.0022	18
AR1,11	-0.01531	0.0064864	-2.36	0.0183	23
AR1,12	-0.01112	0.0064627	-1.72	0.0852	31
AR1,13	-0.01358	0.0064407	-2.11	0.0351	38
AR1,14	0.56696	0.01386	40.90	<.0001	47
AR1,15	-0.07965	0.0072321	-11.01	<.0001	48

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	-0.007	-0.013	-0.008	-0.008	-0.008	-0.014
12	.	0	.	-0.011	-0.012	-0.013	-0.011	-0.004	-0.007
18	.	0	.	-0.006	-0.012	-0.006	-0.005	-0.003	0.004
24	.	0	.	-0.016	-0.005	-0.011	-0.008	-0.002	0.010
30	.	0	.	-0.001	0.007	-0.001	-0.003	-0.010	-0.004
36	43.42	1	<.0001	-0.006	0.005	-0.008	-0.012	0.001	-0.009
42	53.76	7	<.0001	0.009	-0.014	0.003	0.007	0.006	-0.016
48	86.27	13	<.0001	0.005	-0.012	-0.003	-0.027	-0.029	0.015

SO₂ SUF 7

Parameter	Estimate	Standard Error	t Value	Approx Pr > t 	Lag
MA1,1	-0.02175	0.0077554	-2.80	0.0050	1
MA1,2	0.26726	0.0077511	34.48	<.0001	2
MA1,3	0.12230	0.0080290	15.23	<.0001	3
MA1,4	0.12177	0.0080580	15.11	<.0001	4
MA1,5	0.06237	0.0081087	7.69	<.0001	5
MA1,6	0.06193	0.0081209	7.63	<.0001	6
MA1,7	0.08022	0.0080941	9.91	<.0001	7
MA1,8	0.03417	0.0081116	4.21	<.0001	8
MA1,9	0.03292	0.0079447	4.14	<.0001	9
MA1,10	0.01922	0.0078934	2.43	0.0149	10
MA1,11	0.02902	0.0075466	3.85	0.0001	15
MA1,12	0.03133	0.0074298	4.22	<.0001	18
MA1,13	0.02441	0.0071629	3.41	0.0007	27
MA1,14	0.02445	0.0070004	3.49	0.0005	43
MA1,15	-0.01727	0.0070531	-2.45	0.0143	46
MA2,1	0.76787	0.0066387	115.67	<.0001	48
MA3,1	0.81263	0.0047816	169.95	<.0001	336
AR1,1	-0.01634	0.0079744	-2.05	0.0405	16
AR1,2	0.01887	0.0078754	2.40	0.0166	23
AR1,3	-0.01791	0.0078732	-2.27	0.0229	28
AR1,4	0.01825	0.0078507	2.32	0.0201	38
AR1,5	-0.02548	0.01015	-2.51	0.0120	48

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	0.001	0.001	0.000	0.002	0.001	0.002
12	.	0	.	0.002	0.002	0.003	0.003	0.003	0.012
18	.	0	.	-0.003	-0.003	0.008	0.000	-0.003	0.006
24	10.79	2	0.0045	-0.012	-0.009	-0.001	-0.004	-0.000	0.010
30	17.17	8	0.0284	0.008	-0.013	0.006	0.000	0.003	-0.010
36	19.70	14	0.1400	0.002	-0.001	-0.011	0.004	0.001	0.002
42	25.01	20	0.2012	-0.011	-0.001	0.007	0.002	-0.006	-0.010
48	28.64	26	0.3277	0.004	0.009	0.009	0.007	-0.001	-0.001

Lampiran 4. Uji *White*

Variabel	F	P-Value	Keterangan
CO SUF 1	2,0273154	0,1317205	Linier
	1,8990322	0,1497452	
	0,4086	0,6645865	
	1,1017569	0,3323105	
	2,0452382	0,1293812	
	1,1054352	0,3310906	
	0,0625213	0,9393933	
	1,5654525	0,2090236	
	1,682	0,1860326	
	0,6600268	0,5168507	
CO SUF 6	1,8866084	0,1516168	Linier
	1,7232469	0,1785169	
	2,2339059	0,1071407	
	1,894068	0,1504903	
	0,3279257	0,7204211	
	0,1601911	0,8519822	
	1,7624453	0,1716561	
	0,1793736	0,8357951	
	1,3173755	0,2678647	
	0,1147683	0,8915734	
CO SUF 7	0,2314008	0,7934239	Linier
	0,1897669	0,8271537	
	0,360473	0,6973517	
	0,4312846	0,6496811	
	1,2838767	0,2769884	
	0,5803395	0,5597194	

Variabel	F	P-Value	Keterangan
	0,4683135	0,6260653	
	0,6039112	0,5466811	
	0,6022009	0,5476168	
	0,8524395	0,4263918	
NO ₂ SUF 1	3,0535262	0,0472181	Linier
	0,3089197	0,7342438	
	0,69232	0,5004279	
	1,3718253	0,2536717	
	1,6915369	0,1842672	
	0,2610004	0,7702837	
	1,9610005	0,1407494	
	0,2695864	0,7636986	
	0,9299914	0,3945772	
	2,6083624	0,0736846	
NO ₂ SUF 6	2,0123655	0,133704	Linier
	0,5463355	0,5790781	
	0,1256512	0,8819232	
	0,1555617	0,8559355	
	0,6157694	0,5402371	
	0,1552612	0,8561927	
	0,2542956	0,7754655	
	0,474349	0,6222983	
	0,7849138	0,4561756	
	0,6083599	0,5442546	
NO ₂ SUF 7	0,4437126	0,6416572	Linier
	0,5448356	0,5799472	
	0,097596	0,9070158	
	1,0982994	0,3334613	

Variabel	F	P-Value	Keterangan
	0,152437	0,8586141	
	0,2502978	0,7785718	
	0,8698439	0,4190356	
	0,962795	0,381845	
	0,171495	0,842406	
	0,427606	0,6520753	
O ₃ SUF 1	0,9441223	0,3890413	Linier
	0,7437351	0,4753506	
	1,0493114	0,3502015	
	0,8867847	0,4119973	
	0,7759074	0,4603023	
	0,8800471	0,4147823	
	0,4350863	0,647216	
	1,0109676	0,3638886	
	0,8264438	0,4376203	
	0,2708388	0,7627427	
O ₃ SUF 6	1,7158083	0,1798495	Linier
	0,7433559	0,4755309	
	1,5514757	0,211965	
	1,2937287	0,2742733	
	0,8623684	0,4221795	
	0,2576312	0,7728833	
	0,2821064	0,754197	
	1,4113234	0,243849	
	0,3416625	0,7105929	
	0,8746618	0,4170218	
O ₃ SUF 7	1,1663202	0,3115361	Linier
	2,529288	0,0797458	

Variabel	F	P-Value	Keterangan
	0,3218904	0,724782	
	2,2500901	0,1054212	
	1,5221932	0,2182625	
	2,8928217	0,0554469	
	1,8638868	0,1551005	
	2,627429	0,0722934	
	2,3150494	0,0987925	
	1,687454	0,1850209	
PM ₁₀ SUF 1	1,8652992	0,1548816	Linier
	2,4591049	0,0855419	
	2,7070916	0,0667594	
	0,6737601	0,5098018	
	1,2382616	0,2899139	
	2,6292352	0,072163	
	1,9906218	0,1366424	
	2,162389	0,1150816	
	2,505712	0,0816477	
	1,0305329	0,3568391	
PM ₁₀ SUF 6	2,3665769	0,0938322	Linier
	1,7853089	0,1677767	
	1,97722	0,1384855	
	1,6030085	0,2013205	
	0,4317311	0,6493911	
	1,6349912	0,1949848	
	2,4957791	0,0824625	
	1,7336931	0,1766622	
	1,1260195	0,3243459	
	1,3176975	0,2677785	

Variabel	F	P-Value	Keterangan
PM ₁₀ SUF 7	1,0686695	0,3434883	Linier
	0,7906832	0,4535515	
	0,2732605	0,7608979	
	1,2327451	0,2915174	
	0,8703863	0,4188084	
	0,947826	0,3876032	
	0,7922482	0,4528424	
	0,7516206	0,4716174	
	0,707456	0,4929111	
	1,5220138	0,2183017	
SO ₂ SUF 1	0,0503438	0,9509026	Linier
	0,1858597	0,8303918	
	0,186187	0,8301201	
	0,1286999	0,8792386	
	0,2789264	0,7565991	
	0,1313108	0,876946	
	0,2700174	0,7633695	
	0,1665224	0,8466052	
	0,1746799	0,8397273	
	0,0803995	0,922748	
SO ₂ SUF 6	0,1890006	0,8277878	Linier
	0,0722491	0,9302994	
	0,0958373	0,9086123	
	0,118742	0,8880376	
	0,0935136	0,9107261	
	0,0843315	0,9191269	
	0,1821158	0,8335064	
	0,292798	0,7461766	

Variabel	F	P-Value	Keterangan
	0,0585779	0,9431049	
	0,296453	0,7434544	
SO ₂ SUF 7	1,7840767	0,1679835	Linier
	0,4690996	0,6255734	
	1,9841838	0,1375247	
	2,5063193	0,0815981	
	2,1383965	0,1178754	
	1,3928652	0,2483911	
	0,8111638	0,4443579	
	3,4891433	0,0305489	
	2,7148279	0,0662451	
	0,306145	0,7362839	

Lampiran 5. Perbandingan *Neuron* Optimum pada *Hidden Layer* FFNN


Variabel	Neuron	RMSE	RMSEP	sMAPE	sMAPEP
CO SUF 1	1	0.1923	0.2348	16.7206	15.4543
	2	0.1912	0.2249	16.7034	14.7734
	3	0.1889	0.2475	16.6862	14.1779
	4	0.1882	0.2724	16.6824	15.0659
	5	0.1856	0.2610	16.6722	12.8403
CO SUF 6	1	0.5862	0.5991	49.5677	17.2920
	2	0.5787	0.5504	44.6289	14.5355
	3	0.5680	0.5206	44.1826	13.1173
	4	0.5567	0.5556	48.7912	15.7252
	5	0.5526	0.5911	47.4961	15.5413
CO SUF 7	1	0.4392	0.0617	50.4164	200.0000
	2	0.4375	0.0656	50.4175	200.0000
	3	0.4332	0.0379	50.6026	200.0000
	4	0.4345	0.0450	50.6807	200.0000
	5	0.4327	0.0539	50.5308	200.0000
NO ₂ SUF 1	1	6.6551	3.8723	22.0050	39.0329
	2	6.6434	3.8767	22.0441	39.4807
	3	6.5712	3.9804	21.8760	41.0933
	4	6.5359	3.8903	21.8539	37.5945
	5	6.5314	4.0532	21.6784	40.8155
NO ₂ SUF 6	1	5.6919	8.2066	38.2549	32.4637
	2	5.6492	8.3017	38.0200	33.4767
	3	5.6209	8.1826	37.7722	32.7104
	4	5.6120	8.0646	37.7654	32.3113
	5	5.6034	8.0501	37.8173	32.1508

Variabel	Neuron	RMSE	RMSEP	sMAPE	sMAPEP
NO ₂ SUF 7	1	7.8319	8.1962	14.6979	16.3512
	2	7.7412	7.4758	14.5165	14.5892
	3	7.6430	8.2819	14.2719	15.3923
	4	7.6305	8.7016	14.0557	15.6545
	5	7.5543	7.3836	14.5522	14.3405
O ₃ SUF 1	1	6.7708	4.8900	11.7992	62.3826
	2	6.5994	4.9548	11.4528	49.3248
	3	6.1110	3.2064	10.5175	58.2391
	4				
	5	5.8467	4.9152	10.2985	73.8296
O ₃ SUF 6	1	4.9897	5.9019	15.4239	37.5646
	2	4.9424	6.1356	15.3079	35.3751
	3	4.8324	6.2977	15.6542	40.2455
	4	4.7714	6.2241	14.8108	34.0719
	5				
O ₃ SUF 7	1	6.4379	2.9044	19.8622	24.1305
	2	6.2591	3.1921	19.2221	26.7076
	3	6.2648	3.5810	19.5694	27.9001
	4	6.1244	3.0654	19.3531	26.1847
	5	6.1754	3.2626	19.1130	27.7009
PM ₁₀ SUF 1	1	11.5082	2.7349	16.3321	7.9876
	2	11.5047	2.6497	16.7689	7.8074
	3	11.5046	2.6715	16.6670	7.8298
	4	11.4949	2.6629	16.6615	7.8344
	5	11.5080	2.6990	16.4995	7.9267
PM ₁₀ SUF 6	1	3.2753	0.5013	12.1976	3.3876
	2	2.7730	0.4889	12.0068	3.1315
	3	3.0011	0.4879	11.3781	3.6538


Variabel	Neuron	RMSE	RMSEP	sMAPE	sMAPEP
	4	3.2219	0.4791	11.7863	3.1623
	5	3.2807	0.4912	11.5225	3.4076
PM ₁₀ SUF 7	1	14.4999	1.5083	10.8607	4.2871
	2	14.0880	1.3878	9.9931	3.9888
	3	13.7146	1.2450	9.8852	3.2467
	4	13.7114	1.3185	9.9912	3.3123
	5	13.6176	1.3427	9.6456	3.5052
SO ₂ SUF 1	1	14.7598	7.2539	32.0529	51.0073
	2	14.5530	6.5710	30.8573	55.0455
	3	13.7243	4.8980	30.4179	43.1493
	4	13.3944	6.1648	30.6965	48.8909
	5	13.3955	5.5254	30.1379	47.9129
SO ₂ SUF 6	1	5.4738	3.2701	17.4193	22.3165
	2	5.2601	3.2696	17.2570	22.8045
	3	5.1921	3.3932	16.3797	24.3485
	4	5.1443	3.3143	16.9648	22.4842
	5	5.1099	3.3692	16.1077	23.6497
SO ₂ SUF 7	1	3.2209	1.9265	9.2330	9.9878
	2	3.1593	1.8858	9.1999	9.1567
	3	3.1324	1.9343	9.1369	9.4498
	4	3.1225	1.9711	8.9927	10.5643
	5	3.0694	2.0390	8.6997	10.6439

Lampiran 6. Arsitektur FFNN pada Lima Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya

CO SUF 6




CO SUF 7




Error: 12.654995 Steps: 98317

O₃ SUF 6




O₃ SUF 7




Error: 5.351306 Steps: 558239

PM₁₀ SUF 1




Error: 9.574369 Steps: 40493

PM₁₀ SUF 6




Error: 0.520118 Steps: 118978


PM₁₀ SUF 7




SO₂ SUF 1



SO₂ SUF 6



SO₂ SUF 7



Error: 7.091319, Step: 94999

Lampiran 7. Perbandingan *Neuron Optimum* pada *Hidden Layer* LSTM

Variabel	Neuron	RMSE	RMSEP	sMAPE	sMAPEP
CO SUF 1	1	0.2011	0.2378	18.9390	14.6280
	2	0.2198	0.2905	21.6795	15.6509
	3	0.2023	0.2451	22.8816	15.4328
	4	0.1928	0.2382	18.2371	15.5247
	5	0.1984	0.2613	19.3545	15.8898
CO SUF 6	1	0.5849	0.5494	49.4950	13.7777
	2	0.6128	0.4299	55.8243	9.7543
	3	0.5848	0.5679	51.0374	15.7421
	4	0.5851	0.6591	50.3510	20.7074
	5	0.5862	0.5096	49.1672	12.7804
CO SUF 7	1	0.4408	0.0795	50.6392	200.0000
	2	0.4428	0.0545	50.7246	200.0000
	3				
	4	0.4395	0.1062	50.9963	200.0000
	5	0.4497	0.1703	52.9227	200.0000
NO ₂ SUF 1	1	6.7010	3.7023	21.9006	40.3694
	2	6.7128	3.6192	22.1158	40.0974
	3	6.7231	4.4201	24.2887	43.5732
	4	6.6957	3.7307	21.8984	40.2809
	5	6.6842	3.6781	21.8348	39.8230
NO ₂ SUF 6	1	5.8435	8.7144	33.6407	34.5062
	2	5.7470	8.7345	32.8726	35.4424
	3	5.7663	8.5674	37.8673	33.8794
	4	5.8716	8.7432	33.3691	34.4861
	5	5.7257	8.4275	37.8566	34.0845

Variabel	Neuron	RMSE	RMSEP	sMAPE	sMAPEP
NO ₂ SUF 7	1	7.8486	7.9156	14.3546	15.7209
	2	7.9901	9.3203	17.3495	18.3214
	3	7.9105	7.7490	15.9471	15.3257
	4	7.8470	7.7668	14.3637	15.0564
	5	7.9945	6.7713	15.0669	12.7739
O ₃ SUF 1	1	7.0963	4.1056	14.8619	61.9687
	2	6.7381	5.7329	12.8023	62.8569
	3	6.5901	4.9913	12.4172	70.0408
	4	8.0359	9.5192	21.0878	100.1613
	5	7.0004	3.1133	13.0896	90.8060
O ₃ SUF 6	1	5.0810	5.9985	16.6233	36.0057
	2	5.4305	5.9091	19.6848	39.4173
	3	4.9880	6.0187	15.9238	34.3537
	4	5.1180	5.7590	16.2780	36.3864
	5	4.9873	6.4622	16.1342	35.3452
O ₃ SUF 7	1	6.5254	3.2437	19.4472	27.8764
	2	6.4824	3.4645	21.0575	25.8593
	3	6.5089	3.2215	25.4697	27.4514
	4	6.8546	4.4213	28.1189	30.8437
	5	6.8548	4.4227	28.1203	30.8508
PM ₁₀ SUF 1	1	11.5193	2.5856	19.0667	7.8949
	2	11.5405	2.5592	20.3541	7.8837
	3	11.8038	3.3428	20.4729	10.9511
	4	11.6094	2.5539	22.6405	8.2133
	5	11.6622	2.6831	18.7172	9.5276
PM ₁₀ SUF 6	1	3.4146	1.0640	15.0697	9.8630
	2	3.3481	0.4866	12.4643	3.1525
	3	3.2952	0.4879	11.7250	3.5274

Variabel	Neuron	RMSE	RMSEP	sMAPE	sMAPEP
	4	3.6179	1.6278	23.7497	16.4532
	5	3.3456	0.5670	11.3812	3.9271
PM ₁₀ SUF 7	1	15.0371	1.7804	10.9491	5.4679
	2	14.5199	1.6323	10.3578	4.1773
	3	14.5576	1.5335	10.3361	4.0662
	4	14.5009	2.3111	11.2402	6.5194
	5				
SO ₂ SUF 1	1	14.4784	5.1397	36.9175	33.1278
	2	14.4051	7.7614	26.3357	71.0808
	3	14.3758	5.0796	33.5602	31.1111
	4	14.1522	7.1560	31.1093	61.3641
	5	14.2595	4.9895	34.9013	31.6100
SO ₂ SUF 6	1	5.5127	3.2588	17.0689	22.9869
	2	5.4867	3.1870	18.4968	22.0318
	3	5.4571	3.1962	18.8228	22.2661
	4	5.5881	3.3625	17.2091	24.9687
	5	5.8686	3.2399	18.6720	22.9494
SO ₂ SUF 7	1	3.2371	1.9377	9.3522	11.2619
	2	3.2591	2.0466	9.5613	12.7500
	3	3.2069	1.8718	9.2255	10.4508
	4	3.2030	1.9188	9.1541	11.2828
	5	3.4470	2.1918	10.9561	14.5645

Lampiran 8. Output LSTM pada Lima Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya

CO SUF 1

```
{'name': 'lstm_2', 'trainable': True, 'batch_input_shape': (None, 1, 17), 'dtype': 'float32', 'return_sequences': False, 'return_state': False, 'go_backwards': False, 'stateful': False, 'unroll': False, 'units': 1, 'activation': 'tanh', 'recurrent_activation': 'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed': None}}, 'recurrent_initializer': {'class_name': 'Orthogonal', 'config': {'gain': 1.0, 'seed': None}}, 'bias_initializer': {'class_name': 'Zeros', 'config': {}}, 'unit_forget_bias': True, 'kernel_regularizer': None, 'recurrent_regularizer': None, 'bias_regularizer': None, 'activity_regularizer': None, 'kernel_constraint': None, 'recurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0, 'recurrent_dropout': 0.0, 'implementation': 1} [array([[ 1.7404989 , -0.1194751 , 1.9440696 , 1.0262889 ], [-0.51173633, 0.40696758, 0.03009076, 0.00830147], [-0.40821645, 0.34502202, -0.03045124, 0.44218114], [-0.2044098 , 0.46645087, 0.02377924, 0.21821651], [-0.31646428, 0.23225486, -0.05128479, 0.5523352 ], [-0.21422006, -0.04362273, 0.12627009, 0.02876572], [ 0.01349324, -0.36179143, 0.06223663, 0.7189782 ], [-0.12218646, -0.2408559 , -0.06592844, -0.28439957], [ 0.05552476, -0.0102514 , 0.05540881, 0.14870854], [-0.49611288, 0.11882716, -0.04432157, 0.23987742], [ 0.32819405, 0.30252326, 0.01614301, -0.00667564], [ 0.03423567, 0.502907 , -0.007013 , -0.06387589], [-0.2612637 , -0.02487832, 0.10778038, 0.1765848 ], [-0.49196583, 0.10892266, 0.26449686, -0.07479704], [-0.5707994 , -0.10026145, -0.11267632, 0.2519427 ], [-0.08128428, -0.06267339, 0.14226294, 0.17943807], [-0.11762904, -0.37936902, -0.09826867, 0.20849739]], dtype=float32), array([[[-0.17638741, -0.9040711 , 0.02229068, -0.3886464 ]], dtype=float32), array([0.34823954, 1. , -0.2966131 , 0.8808213 ], dtype=float32)] {'name': 'dense_2', 'trainable': True, 'units': 1, 'activation': 'linear', 'use_bias': True, 'kernel_initializer': {'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed': None}}, 'bias_initializer': {'class_name': 'Zeros', 'config': {}}, 'kernel_regularizer': None, 'bias_regularizer': None, 'activity_regularizer': None, 'kernel_constraint': None, 'bias_constraint': None} [array([[1.0177189]], dtype=float32), array([0.11338704], dtype=float32)]
```

CO SUF 6

```
{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1, 13), 'dtype': 'float32', 'return_sequences': False, 'return_state': False, 'go_backwards': False, 'stateful': False, 'unroll': False,
```

```

'units': 2, 'activation': 'tanh', 'recurrent_activation':
'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class_name':
'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg',
'distribution': 'uniform', 'seed': None}}, 'recurrent_initializer':
{'class_name': 'Orthogonal', 'config': {'gain': 1.0, 'seed': None}},
'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'unit_forget_bias': True, 'kernel_regularizer': None,
'recurrent_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'recurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0,
'recurrent_dropout': 0.0, 'implementation': 1] [array([[ 0.7525708 ,
0.97199345, -0.19026971, -0.03752843, -0.89324874, -1.011029 ,
0.18946888, 0.90434694], [ 0.38376963, 0.41085985, -0.01411206, -
0.3826432 , -0.7413195 , -1.4804094 , 0.9209709 , 1.410044 ], [
0.13288823, 0.20005491, -0.3713274 , 0.07301044, -0.08312128, -
0.08505764, 0.44084385, 0.11462395], [ 0.41807243, 0.15426734, -
0.00544298, 0.22566724, -0.17338622, -0.0033035 , 0.7506786 ,
0.44071287], [-0.04772295, 0.09174153, -0.14431238, -0.46346813, -
0.34243354, 0.0457021 , -
0.06630257, -0.23324102], [-0.18594201, -0.2123079 , -0.12418732,
0.24899119, 0.12097751, -0.03720513, -0.53339094, 0.08916698], [-
0.02296961, -0.43110982, -0.15315291, -0.1106891 , -0.41578335,
0.02063377, 0.09533479, -0.68607277], [-0.91784203, -0.32918203, -
0.09643632, -0.12291124, 0.28644237, -0.27716228, -0.48943198, -
0.37726596], [-0.17504779, 0.13252631, -0.2769003 , 0.23575795,
0.66319615, -0.22931953, 0.00889922, -0.30943903], [ 0.16888319,
0.12716635, -0.4012019 , -0.35631448, -0.14205062, -0.9334612 ,
0.6437249 , -0.29649323], [-1.4140856 , -0.61157393, 0.23045117,
0.02095091, 0.467362 , 0.08721709, -0.6379571 , -0.04983504], [-
0.04039212, -0.6289408 , 0.24878228, -0.2122939 , -0.78982216,
0.2485334 , 0.02196078, -0.2741727 ], [-0.30921188, 0.3402241 , -
0.49014413, 0.19756716, -0.37108126, 0.3021567 , 0.02431487, -
0.06763455]], dtype=float32), array([[ 0.10285524, 0.02719793, -
0.12311766, 0.22590087, 0.68737066, -0.21384801, 0.4281773 ,
0.47004965], [-0.3293994 , -0.5659455 , -0.08715995, 0.33737484, -
0.20980512, -0.59293926, 0.14901614, -0.1788354 ]], dtype=float32),
array([-0.00239978, 0.3595192 , 1. , 1. , 0.23387061, 0.12929988,
0.141571 , 0.3463776 ], dtype=float32)] {'name': 'dense_1',
'trainable': True, 'units': 1, 'activation': 'linear', 'use_bias':
True, 'kernel_initializer': {'class_name': 'VarianceScaling',
'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform',
'seed': None}}, 'bias_initializer': {'class_name': 'Zeros', 'config':
{}}, 'kernel_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'bias_constraint': None} [array([[ -0.39623758], [-0.7062035 ]],
dtype=float32), array([0.06203839], dtype=float32)]

```

CO SUF 7

```
{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1, 3), 'dtype': 'float32', 'return_sequences': False, 'return_state': False, 'go_backwards': False, 'stateful': False, 'unroll': False, 'units': 2, 'activation': 'tanh', 'recurrent_activation': 'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed': None}}, 'recurrent_initializer': {'class_name': 'Orthogonal', 'config': {'gain': 1.0, 'seed': None}}, 'bias_initializer': {'class_name': 'Zeros', 'config': {}}, 'unit_forget_bias': True, 'kernel_regularizer': None, 'recurrent_regularizer': None, 'bias_regularizer': None, 'activity_regularizer': None, 'kernel_constraint': None, 'recurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0, 'recurrent_dropout': 0.0, 'implementation': 1} [array([[ 0.48693803, 1.0973603, -0.26289538, -0.051853, 1.284979, -1.3723117, -0.37696373, 0.8467993 ], [ 0.24126112, -0.8565525, -0.01949865, -0.52869755, 0.13982916, -0.9448105, 0.82827383, 0.5794025 ], [ 0.23409927, -0.25450692, -0.51306254, -0.10087842, -0.389952, 0.06005592, 0.5114136, -0.27088404]], dtype=float32), array([[ 0.10285524, 0.02719793, -0.12311766, 0.22590087, 0.68737066, -0.21384801, 0.4281773, 0.47004965], [-0.3293994, -0.5659455, -0.08715995, 0.33737484, -0.20980512, -0.59293926, 0.14901614, -0.1788354 ]], dtype=float32), array([ 0.81936496, 0.41089886, 1., 1., -0.19253796, 0.01197887, 0.8054356, 0.48709944], dtype=float32)]
{'name': 'dense_1', 'trainable': True, 'units': 1, 'activation': 'linear', 'use_bias': True, 'kernel_initializer': {'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed': None}}, 'bias_initializer': {'class_name': 'Zeros', 'config': {}}, 'kernel_regularizer': None, 'bias_regularizer': None, 'activity_regularizer': None, 'kernel_constraint': None, 'bias_constraint': None} [array([[ 0.7770018], [-0.7397639]], dtype=float32), array([0.0724599], dtype=float32)]
```

NO₂ SUF 1

```
{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1, 8), 'dtype': 'float32', 'return_sequences': False, 'return_state': False, 'go_backwards': False, 'stateful': False, 'unroll': False, 'units': 2, 'activation': 'tanh', 'recurrent_activation': 'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed': None}}, 'recurrent_initializer': {'class_name': 'Orthogonal', 'config': {'gain': 1.0, 'seed': None}}, 'bias_initializer': {'class_name': 'Zeros', 'config': {}}, 'unit_forget_bias': True, 'kernel_regularizer': None, 'recurrent_regularizer': None, 'bias_regularizer': None, 'activity_regularizer': None, 'kernel_constraint': None,
```



```

'recurrent_constraint': None, 'bias_constraint': None, 'dropout':
0.0, 'recurrent_dropout': 0.0, 'implementation': 1} [array([[ 1.3825593
, 1.112573 , -0.21798134, -0.0429942 , -1.5740566 , -1.7561454 ,
0.571477 , 0.8791994 ], [-0.5738552 , -0.6698137 , -0.0161674 , -
0.43837288, 0.1486532 , -0.21350336, 0.10545546, 0.48633736], [-
0.01101132, 0.19491072, -0.42540902, 0.08364397, -0.60435236, -
0.30623576, 0.36295667, 0.12537757], [ 0.04415768, 0.04730987, -
0.00623572, 0.2585343 , 0.03437937, 0.3280165 , 0.5201843 , 0.5054915
], [-0.20975137, 0.01081148, -0.16533062, -0.5309695 , -0.35672495,
0.22235945, -0.19735652, -0.20891744], [ 0.09153517, 0.25528944, -
0.14227444, 0.28525525, 0.00404726, -0.09474878, -0.3098079 ,
0.73245007], [ 0.43547392, 0.11358773, -0.1754587 , -0.12681031, -
0.5538261 , 0.1536362 , 0.6287204 , 0.06672042], [-0.6199569 , -
0.12218088, -0.11048168, -0.14081255, 0.1197382 , 0.04683952, -
0.1602211 , 0.03526025]], dtype=float32), array([[ 0.10285524,
0.02719793, -0.12311766, 0.22590087, 0.68737066, -0.21384801,
0.4281773 , 0.47004965], [-0.3293994 , -0.5659455 , -0.08715995,
0.33737484, -0.20980512, -0.59293926, 0.14901614, -0.1788354 ]],
dtype=float32), array([0.35349768, 0.40552735, 1. , 1. , 0.08982494,
0.15039262, 0.4380652 , 0.4530671 ]), dtype=float32)] {'name':
'dense_1', 'trainable': True, 'units': 1, 'activation': 'linear',
'use_bias': True, 'kernel_initializer': {'class_name':
'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg',
'distribution': 'uniform', 'seed': None}}, 'bias_initializer':
{'class_name': 'Zeros', 'config': {}}, 'kernel_regularizer': None,
'bias_regularizer': None, 'activity_regularizer': None,
'kernel_constraint': None, 'bias_constraint': None} [array([[[-
0.5680822]], [-0.6663797]], dtype=float32), array([0.05280042],
dtype=float32)]

```

NO₂ SUF 6

```

{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1,
5), 'dtype': 'float32', 'return_sequences': False, 'return_state':
False, 'go_backwards': False, 'stateful': False, 'unroll': False,
'units': 5, 'activation': 'tanh', 'recurrent_activation':
'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class_name':
'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg',
'distribution': 'uniform', 'seed': None}}, 'recurrent_initializer':
{'class_name': 'Orthogonal', 'config': {'gain': 1.0, 'seed': None}},
'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'unit_forget_bias': True, 'kernel_regularizer': None,
'recurrent_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'recurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0,
'recurrent_dropout': 0.0, 'implementation': 1} [array([[ 7.4893957e-
01, 4.4275483e-01, -2.5883922e-01, 6.1886787e-01, 4.0677705e-01, -
8.9049965e-02, -4.8750409e-01, -3.0156970e-04, -3.6194924e-01, -
3.7612253e-01, 7.8700995e-01, -1.3349760e+00, 1.1689951e+00,
3.3587119e-01, -8.6892998e-01, 1.0126895e+00, 3.4338352e-01, -

```

```

1.0577592e-01, 2.7168909e-02, 3.3774933e-01], [ 1.8455426e-01,
7.5278878e-01, 8.4349102e-01, -1.3864210e+00, 3.6657473e-01, -
4.8317909e-02, -4.9885511e-03, 2.0682743e-01, 9.4681412e-02,
1.5625516e-01, 6.3460660e-01, 1.7137448e-01, 2.2152180e-02, -
1.9946209e-01, -3.1109342e-01, -4.0338230e-01, 4.2138445e-01,
5.8509296e-01, -1.4720200e+00, 8.1440292e-02], [ 4.3712485e-01,
3.2367986e-01, -3.6837902e-02, -5.9711695e-01, -1.3143541e-01, -
4.1947314e-01, -3.5792241e-01, 2.1582541e-01, 2.6291832e-01, -
7.6310605e-02, 1.1661912e-02, -3.7726101e-02, -1.8219817e-01, -
8.8038158e-01, 9.8997829e-03, -6.3070871e-02, 2.7214080e-01,
3.6853370e-01, -9.4212192e-01, -1.2463901e-01], [ 2.4060763e-01, -
6.0826659e-01, -7.4672306e-01, -7.5176579e-01, -4.7460607e-01,
4.6707508e-01, -2.5378332e-01, 2.1607569e-01, 3.8486871e-01, -
3.5434377e-01, -2.9639393e-01, 1.9602597e-01, 7.6091811e-02, -
1.0962912e+00, -5.9119952e-01, -4.1148090e-01, 7.5163923e-02, -
7.2755182e-01, -8.2694727e-01, -5.6341207e-01], [-1.6869682e-01,
1.3845283e-01, -1.9065255e-02, -2.9337397e-01, 6.8076856e-02, -
4.4062379e-01, 2.8359696e-01, 4.5772681e-01, 2.9086068e-01, -
4.0276071e-01, 3.1015843e-01, -2.1889830e-01, -1.7822255e-01,
8.6349184e-03, 2.1996005e-01, 3.8898420e-02, 3.9046267e-01,
1.4716188e-02, -7.8088677e-01, 2.9917151e-01]], dtype=float32),
array([[ -0.19502647, -0.11766353, -0.2091057, -0.07414206, 0.2104231
, -0.17554195, 0.1331939, 0.19254029, -0.6808049, 0.0228696, -
0.00799542, -0.09402898, 0.03917344, 0.34188852, 0.0898625, -
0.21057948, -0.14237814, 0.15418458, 0.07697924, 0.27433053], [-
0.40956342, -0.387628, 0.3160286, -0.06731085, -0.22597058, -
0.09914427, 0.26732412, -0.36454418, -0.00151767, -0.03797069,
0.04280493, 0.19495293, 0.34027818, -0.03139111, 0.19635597, -
0.20405263, 0.17135224, 0.05234374, 0.14648469, -0.14331992], [-
0.1018487, -0.15790077, 0.23064071, -0.07212225, 0.10435078, 0.3077141
, 0.14377782, 0.18532777, 0.00789372, -0.13587615, 0.33400774,
0.04201511, -0.21418495, 0.16989745, -0.3263934, -0.24610054,
0.06090693, 0.17974024, -0.5473686, -0.19074549], [-0.03535502, -
0.26338255, -0.18268858, -0.32899106, 0.21480972, -0.18155822, -
0.416624, -0.4153166, -0.07406035, 0.01818663, -0.2835144, -
0.01412864, 0.04152709, -0.22246008, -0.38509777, -0.1057838, -
0.08809126, 0.03834176, -0.23428966, -0.03712576], [-0.04871237, -
0.2781039, -0.25314048, 0.20102029, -0.11198268, -0.0988622, -
0.19645576, 0.29811674, -0.24689929, -0.25862923, 0.08655382,
0.19551487, 0.22090916, -0.16097338, 0.11733126, 0.48229218,
0.09174158, 0.06652057, -0.21806727, -0.3331175 ]], dtype=float32),
array([ 0.03841991, 0.31779855, 0.17975348, -1.1729505, 0.01178144,
1., 1., 1., 1., 1., 0.00631353, 0.14132932, -0.08947492, -
0.02550246, 0.10458146, 0.01243882, 0.37160793, 0.20427668, -1.1631068
, 0.00170559], dtype=float32)] {'name': 'dense_1', 'trainable': True,
'units': 1, 'activation': 'linear', 'use_bias': True,
'kernel_initializer': {'class_name': 'VarianceScaling', 'config':
{'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed':
None}}, 'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'kernel_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'bias_constraint': None} [array([[ 0.96260875], [-0.42348227],

```

```
[ 1.036387 ], [ 0.56424814], [-0.5204396  ]], dtype=float32),
array([[0.06102556], dtype=float32)]
```

NO₂ SUF 7

```
{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1,
14), 'dtype': 'float32', 'return_sequences': False, 'return_state':
False, 'go_backwards': False, 'stateful': False, 'unroll': False,
'units': 5, 'activation': 'tanh', 'recurrent_activation':
'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class_name':
'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg',
'distribution': 'uniform', 'seed': None}}, 'recurrent_initializer':
{'class_name': 'Orthogonal', 'config': {'gain': 1.0, 'seed': None}},
'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'unit_forget_bias': True, 'kernel_regularizer': None,
'recurrent_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'recurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0,
'recurrent_dropout': 0.0, 'implementation': 1} [array([[ 7.65401006e-
01,  6.02087080e-01, -7.95920730e-01, -1.99328810e-02,  7.91294932e-01,
-7.63597190e-02, -4.18031335e-01, -2.58594751e-04, -3.10368925e-01, -
3.22522432e-01,  1.53167939e+00, -1.70849347e+00,  1.46626759e+00,
9.66759264e-01, -1.18513429e+00,  9.70870674e-01,  4.93030995e-01, -
6.06390417e-01, -2.92293996e-01,  7.98679948e-01],

[ 1.96041182e-01,  2.42253065e-01, -6.35793433e-03, -4.15630162e-01,
4.09312993e-01, -4.14322615e-02, -4.27764654e-03,  1.77353054e-01,
8.11886489e-02,  1.33987695e-01,  1.61248937e-01,  2.39971504e-01, -
1.37208596e-01, -2.02460408e-01, -4.85859290e-02, -1.47954777e-01,
4.37704660e-03, -1.76763609e-01, -4.73806381e-01,  2.30481714e-01], [-
5.00725135e-02, -3.60979259e-01, -1.36459470e-01, -3.15357953e-01], [-
8.71286243e-02, -3.59695256e-01, -3.06915939e-01,  1.85068756e-01,
2.25450605e-01, -6.54358268e-02,  2.34439880e-01, -2.69746780e-01,
4.53996891e-03,  1.81111485e-01,  9.93089154e-02, -3.19619119e-01, -
4.65510815e-01,  1.82203025e-01, -5.81472933e-01, -4.37222421e-02], [
4.75277007e-01,  1.44082621e-01,  7.63638675e-01,  2.02474609e-01,
1.24857858e-01,  4.00513560e-01, -2.17617407e-01,  1.85283393e-01,
3.30022186e-01, -3.03847253e-01, -3.52147371e-02, -5.64163812e-02,
2.27555424e-01, -5.38798645e-02, -6.90587878e-01,  4.96371984e-02,
6.18242919e-01,  7.85395622e-01,  1.96010843e-01,  1.88544486e-02], [-
3.18391204e-01, -1.51304334e-01, -9.34652805e-01, -5.36974430e-01, -
1.01008184e-01, -3.77831787e-01,  2.43182391e-01,  3.92497510e-01,
2.49410957e-01, -3.45364451e-01,  1.21682681e-01,  6.28269911e-02, -
6.86488807e-01, -7.70965293e-02,  2.89089650e-01, -1.70400545e-01,
9.96242538e-02, -8.47282708e-01, -8.74632061e-01,  1.43670261e-01], [-
4.59642738e-01, -2.68421680e-01,  5.47013700e-01, -3.24665070e-01, -
1.92622453e-01,  1.88721150e-01,  3.54692936e-02,  1.31520361e-01, -
1.58379316e-01, -1.11707598e-01,  2.15004429e-01,  2.23495305e-01,
4.09478515e-01, -6.87108710e-02,  3.72396797e-01, -2.29867101e-01,
2.42636964e-01,  1.01186745e-01, -3.53248566e-01,  5.51850617e-01],
```

```

[ 7.99460411e-02, 1.94393843e-01, 5.91594934e-01, -2.82163620e-01, -
1.46352217e-01, -2.47491479e-01, 2.00388521e-01, 2.96087295e-01, -
2.96138078e-01, 3.89795989e-01, 2.06687629e-01, -1.65944457e-01,
3.23367082e-02, -2.52121359e-01, 7.11087510e-02, 5.26917651e-02, -
4.20348831e-02, 5.77567577e-01, 6.41779881e-03, -1.88258570e-02], [
2.05095381e-01, 6.29911602e-01, 2.42547601e-01, -5.54354638e-02,
4.16263402e-01, 3.92062217e-01, 2.65556276e-02, 3.42386216e-01,
3.62546593e-01, -4.74607944e-03, 6.63342476e-02, -1.91302031e-01,
1.75773323e-01, 2.15094075e-01, -5.53141117e-01, 3.03825378e-01, -
9.09933820e-03, 4.86490786e-01, -5.47008812e-01, 7.98826888e-02], [-
1.52370349e-01, -2.10781917e-01, -5.69254398e-01, -2.93184310e-01, -
1.65479526e-01, 9.48706269e-03, 2.00322598e-01, 2.76946217e-01,
4.13808256e-01, -3.03606302e-01, -8.15298706e-02, 4.46505427e-01, -
5.49540818e-01, -3.89226735e-01, -9.60617289e-02, 2.5553067e-01,
3.97947170e-02, -9.44715858e-01, -4.38566476e-01, -1.29474983e-01], [
2.81386636e-02, 4.18941855e-01, 2.49845609e-01, -6.40582442e-01,
5.08229356e-01, 2.76050240e-01, -8.75310004e-02, -1.53432548e-01,
3.08177084e-01, 3.61985307e-03, 2.76308251e-03, 1.12699784e-01,
6.08687177e-02, 5.38107991e-01, -3.19527656e-01, 3.98742780e-02, -
2.13241994e-01, -5.27485609e-02, -2.10494101e-01, 1.11180685e-01], [
2.63103485e-01, 1.11279495e-01, 2.83648074e-01, -2.72679657e-01,
1.60876840e-01, 1.79038674e-01, -1.31297201e-01, 1.25495285e-01, -
1.82438672e-01, -1.58580840e-02, 6.08568527e-02, -5.79366311e-02, -
2.17294887e-01, -1.23386443e-01, -3.41934383e-01, -2.60450333e-01, -
1.67631403e-01, 1.20073818e-01, -1.45946100e-01, -2.06235990e-01], [
9.82096568e-02, -4.19775993e-02, -1.01075852e+00, -5.53077400e-01,
2.47914165e-01, -3.02325308e-01, 8.72125924e-02, 7.38301873e-02,
8.53056610e-02, 2.58089870e-01, -7.65457898e-02, -1.06921501e-01, -
5.64911902e-01, -4.70318235e-02, -1.65251553e-01, 2.78176725e-01, -
9.78703126e-02, -6.08117163e-01, -2.83368766e-01, 4.07214053e-02], [-
3.69430110e-02, -2.67768830e-01, 2.41534248e-01, -4.31492507e-01, -
4.82270688e-01, -3.49131435e-01, 4.14514840e-02, -2.49189526e-01,
1.64857417e-01, 3.39582771e-01, 4.24550287e-02, 7.47261420e-02,
2.45775521e-01, -4.04674292e-01, 1.75708935e-01, -6.17045686e-02, -
7.63701275e-02, 5.68881966e-02, -6.18706048e-01, 4.65635657e-02], [
4.13388133e-01, 1.35979444e-01, -4.03887182e-01, -3.45848978e-01, -
9.13098082e-02, -3.69317532e-01, 3.29931378e-02, -2.06960142e-02, -
4.16277409e-01, -2.56386995e-02, -8.34631324e-02, 4.88436297e-02, -
9.33903232e-02, 8.93749818e-02, -1.36762306e-01, 2.86096692e-01, -
1.83723599e-01, -4.33350891e-01, -3.42300266e-01, 2.99359262e-01]],
dtype=float32), array([[-0.19502647, -0.11766353, -0.2091057,
0.07414206, 0.2104231, -0.17554195, 0.1331939, 0.19254029, -0.6808049
, 0.0228696, -0.00799542, -0.09402898, 0.03917344, 0.34188852,
0.0898625, -0.21057948, -0.14237814, 0.15418458, 0.07697924,
0.27433053], [-0.40956342, -0.387628, 0.3160286, -0.06731085, -
0.22597058, -0.09914427, 0.26732412, -0.36454418, -0.00151767,
-0.03797069, 0.04280493, 0.19495293, 0.34027818, -0.03139111,
0.19635597, -0.20405263, 0.17135224, 0.05234374, 0.14648469, -
0.14331992], [-0.1018487, -0.15790077, 0.23064071, -0.07212225,
0.10435078, 0.3077141, 0.14377782, 0.18532777, 0.00789372, -
0.13587615, 0.33400774, 0.04201511, -0.21418495, 0.16989745, -
0.3263934, -0.24610054, 0.06090693, 0.17974024, -0.5473686,

```

```

-0.19074549], [-0.03535502, -0.26338255, -0.18268858, -0.32899106,
0.21480972, -0.18155822, -0.416624, -0.4153166, -0.07406035,
0.01818663, -0.2835144, -0.01412864, 0.04152709, -0.22246008, -
0.38509777, -0.1057838, -0.08809126, 0.03834176, -0.23428966, -
0.03712576], [-0.04871237, -0.2781039, -0.25314048, 0.20102029, -
0.11198268, -0.0988622, -0.19645576, 0.29811674, -0.24689929, -
0.25862923, 0.08655382, 0.19551487, 0.22090916, -0.16097338,
0.11733126, 0.48229218, 0.09174158, 0.06652057, -0.21806727, -
0.3331175 ], dtype=float32), array([-0.16375653, 0.15132605, -
0.0698129, -0.75821555, -0.02479092, 1., 1., 1., 1., 1., 1.,
0.01155324, 0.195335, -0.16982712, -0.15163952, 0.0793613, -0.169453
, 0.13892068, -0.0462187, -0.77983093, -0.01654267], dtype=float32)]
{'name': 'dense_1', 'trainable': True, 'units': 1, 'activation':
'linear', 'use_bias': True, 'kernel_initializer': {'class_name':
'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg',
'distribution': 'uniform', 'seed': None}}, 'bias_initializer':
{'class_name': 'Zeros', 'config': {}}, 'kernel_regularizer': None,
'bias_regularizer': None, 'activity_regularizer': None,
'kernel_constraint': None, 'bias_constraint': None} [array([[
0.6993967 ], [-0.24212113], [ 0.919577 ], [ 0.11833563], [-
0.48756245]], dtype=float32), array([0.05862638], dtype=float32)]

```

O₃ SUF 1

```

{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1, 2
0), 'dtype': 'float32', 'return_sequences': False, 'return_state': Fa
lse, 'go_backwards': False, 'stateful': False, 'unroll': False, 'unit
s': 1, 'activation': 'tanh', 'recurrent_activation': 'hard_sigmoid', '
use_bias': True, 'kernel_initializer': {'class_name': 'VarianceScalin
g', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'unif
orm', 'seed': None}}, 'recurrent_initializer': {'class_name': 'Orthog
onal', 'config': {'gain': 1.0, 'seed': None}}, 'bias_initializer': {'
class_name': 'Zeros', 'config': {}}, 'unit_forget_bias': True, 'kerne
l_regularizer': None, 'recurrent_regularizer': None, 'bias regularize
r': None, 'activity_regularizer': None, 'kernel constraint': None, 'r
ecurrent constraint': None, 'bias constraint': None, 'dropout': 0.0, '
recurrent_dropout': 0.0, 'implementation': 1}
[array([[ 1.2840513, 0.18823528, -1.6310927, 1.0571551 ],
[-0.01966843, -0.09088624, -0.07383426, -0.06632736],
[-0.19839048, -0.38387847, -0.11021324, -0.17664227],
[ 0.0673882, -0.35116422, 0.06890209, 0.21820909],
[-0.08608904, -0.02875352, -0.10487473, -0.05874582],
[ 0.1527915, -0.08204186, 0.0675669, -0.08675086],
[ 0.01358772, -0.04931426, -0.02249604, 0.16787371],
[ 0.02619785, 0.15947723, 0.04185637, 0.15571177],
[-0.07764632, 0.15785408, -0.04280522, -0.4049221 ],
[ 0.4346667, -0.11419737, -0.7793567, 0.8286521 ],
[-0.4014315, -0.074525, 0.7527073, -0.0404391 ],
[-0.32943127, -0.428123, -0.04577634, 0.19699815],
[ 0.11015505, -0.0778842, -0.11129583, -0.15811376],
[-0.04908687, 0.09589446, 0.07554658, 0.05057788],
[-0.12003133, 0.27894676, 0.06672542, 0.0607268 ],

```

```

[ 0.03209668, -0.18667531, 0.13468556, 0.17152046],
[ 0.2326458 , 0.4767065 , -0.32104155, 0.75956774],
[-0.1702531 , -0.3616506 , 0.2340648 , -0.19028547],
[-0.07354877, 0.06577373, -0.18429214, -0.23640293],
[ 0.35212317, 0.03667819, 0.07011274, -0.17847656]],
dtype=float32), array([[ -0.5285954 , -0.79616123, -0.02723205,
0.29321092]],
dtype=float32), array([0.23083498, 1. , 0.19961491, 0.23
746869], dtype=float32)]
{'name': 'dense_1', 'trainable': True, 'units': 1, 'activation': 'lin
ear', 'use_bias': True, 'kernel_initializer': {'class_name': 'Varianc
eScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution'
: 'uniform', 'seed': None}}, 'bias_i
nitializer': {'class_name': 'Zeros', 'config': {}}, 'kernel_regulariz
er': None, 'bias_regularizer': None, 'activity_regularizer': None, 'k
ernel_constraint': None, 'bias_constraint': None}
[array([[ -1.4079745]], dtype=float32), array([0.08996405], dtype=floa
t32)]

```

O₃ SUF 6

```

{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1,
20), 'dtype': 'float32', 'return_sequences': False, 'return_state':
False, 'go_backwards': False, 'stateful': False, 'unroll': False,
'units': 4, 'activation': 'tanh', 'recurrent_activation':
'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class_name':
'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg',
'distribution': 'uniform', 'seed': None}}, 'recurrent_initializer':
{'class_name': 'Orthogonal', 'config': {'gain': 1.0, 'seed': None}},
'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'unit_forget_bias': True, 'kernel_regularizer': None,
'recurrent_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'recurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0,
'recurrent_dropout': 0.0, 'implementation': 1} [array([[
1.14115751e+00, 1.47193444e+00, 7.74315834e-01, 1.11211002e+00,
1.17284536e-01, -7.42082894e-02, -4.06253457e-01, -2.51322985e-04,
1.39766705e+00, 1.67750001e+00, 1.59118009e+00, -1.80222691e+00,
1.16422153e+00, 1.03856432e+00, 9.52038467e-01, 1.47980571e+00], [-
3.56024116e-01, -1.38845623e-01, -6.05612159e-01, 3.70593183e-02,
4.95809615e-02, -6.69868886e-02, 1.30147398e-01, -1.30589604e-01, -
2.16324702e-01, -9.38467979e-02, -2.56860286e-01, 2.91187346e-01, -
2.83502489e-01, 1.53281778e-01, -8.72269794e-02, 1.10482410e-01], [-
6.11137152e-01, 5.67855500e-02, -7.09198833e-01, -4.27111715e-01, -
3.57024938e-01, -9.32417810e-02, -1.89002827e-01, -1.32645965e-01, -
2.69073732e-02, 1.98973447e-01, -2.59193301e-01, 8.22000951e-02, -
6.79591179e-01, -2.49290079e-01, -8.57852280e-01, 1.71053335e-02], [
4.63772595e-01, 5.25981039e-02, 2.72241056e-01, 1.47650793e-01, -
2.14782909e-01, 7.82974958e-02, 2.23092318e-01, -1.77052364e-01, -
1.40264288e-01, 1.07616022e-01, -1.12465702e-01, -4.26532850e-02,
4.88606751e-01, 4.46896367e-02, 4.02171075e-01, 4.73755449e-01], [-
3.99945855e-01, 2.04652473e-01, -2.80413121e-01, 2.42948048e-02,

```

3.20723951e-01, -2.95286477e-01, -2.02016965e-01, 1.09375834e-01,
 1.09050504e-03, -2.39561568e-03, -4.74556029e-01, -1.20781042e-01,
 1.32746607e-01, -8.47802684e-02, 1.17420770e-01, 3.72900724e-01], [-
 5.34781396e-01, -1.98198006e-01, -1.76800024e-02, -1.48855686e-01, -
 7.57170916e-02, -3.67186517e-01, 2.36330807e-01, 3.81439030e-01,
 6.67908192e-01, 9.37247574e-02, 2.75136679e-01, -2.51938015e-01, -
 6.40559494e-01, 3.23633701e-01, 2.30351798e-02, -2.64578193e-01], [
 3.41139957e-02, 4.70596403e-02, -3.78599942e-01, 1.52731866e-01, -
 3.49589705e-01, -9.95404422e-02, 3.41985106e-01, -7.02227652e-02, -
 5.72552323e-01, -5.34790754e-02, -1.94698766e-01, 2.97948509e-01, -
 2.27004379e-01, -1.03550531e-01, 8.95702094e-02, 2.07659632e-01], [
 2.70297289e-01, 1.38333529e-01, 4.33201641e-01, -4.19533588e-02,
 3.68591249e-01, -1.55431867e-01, -3.22988331e-02, 3.73550892e-01,
 2.06515715e-01, 3.53700042e-01, 7.79539254e-03, -5.96733727e-02], [
 1.83305368e-01, -1.85680911e-02, 2.72048831e-01, 3.37060094e-01], [-
 6.83529317e-01, 2.63519704e-01, 1.32051259e-01, -3.53797376e-01,
 2.95665860e-01, 2.43901849e-01, 2.02065706e-03, 1.62327409e-01, -
 5.12469821e-02, -1.49133384e-01, 1.76057413e-01, 6.57937303e-02, -
 4.64558303e-01, 4.41288203e-01, -2.07743272e-01, 8.37440323e-03], [-
 4.41803187e-01, 1.18272692e-01, -4.97166336e-01, 1.79089889e-01,
 3.52331996e-01, -4.61235642e-03, -1.86278641e-01, 4.70250547e-02, -
 5.12774289e-01, -6.40693307e-03, -5.38502574e-01, 9.04118419e-02, -
 9.26148593e-01, 1.65066615e-01, -8.66686583e-01, -3.28600556e-01], [-
 1.15492888e-01, 2.97965370e-02, 7.57970273e-01, 2.99814582e-01, -
 2.11690605e-01, 9.21976566e-03, 1.94678545e-01, 2.69143343e-01,
 9.13028181e-01, 1.00057431e-01, 1.08720332e-01, 4.03505340e-02, -
 2.88383871e-01, 2.21700132e-01, 3.10530275e-01, 3.29884320e-01], [-
 2.77365744e-01, -2.71737605e-01, 2.63862222e-01, -2.66769052e-01, -
 5.80080450e-02, 3.59426737e-01, -3.91178429e-02, -3.69706184e-01,
 2.80182362e-01, 2.11491995e-02, -4.14509088e-01, 6.51564002e-02,
 6.79388866e-02, -5.01969494e-02, -4.07016464e-03, 2.10281268e-01], [-
 5.20439744e-01, 2.27475524e-01, 9.60124359e-02, 3.24424100e-03, -
 3.23563844e-01, -3.49529237e-01, 1.00782514e-01, -6.16068542e-02,
 4.02265221e-01, 1.28463387e-01, 3.14342320e-01, 1.33044347e-01, -
 1.30831555e-01, 3.31471324e-01, 1.23876601e-01, 1.58627763e-01], [-
 7.55076110e-01, -1.95232823e-01, -6.50295094e-02, -3.15384328e-01, -
 1.71994790e-01, -7.48145878e-02, -3.84061307e-01, -2.27721706e-01, -
 6.68727815e-01, -2.25981951e-01, -1.05311483e-01, -1.16761297e-01, -
 4.37521189e-01, -1.32983610e-01, 1.98247842e-02, -1.45855993e-01], [
 1.88021600e-01, -2.60780334e-01, -8.71900767e-02, -3.37427296e-02,
 8.29021633e-02, 2.50818253e-01, -1.64154544e-01, -3.34373772e-01, -
 1.64252490e-01, 4.68100786e-01, -6.87641650e-02, 1.43581480e-01, -
 2.19253644e-01, 4.70582157e-01, 1.66288987e-01, -2.97525555e-01], [
 3.57073583e-02, -2.26449981e-01, -7.00890571e-02, 6.04804568e-02, -
 3.65441591e-01, -3.39294761e-01, 4.02836204e-02, -2.42168695e-01, -
 2.08380856e-02, 2.85328835e-01, 1.12670980e-01, -5.48856631e-02,
 3.20816994e-01, 3.81047390e-02, -6.60788491e-02, 2.12367587e-02], [-
 2.14736953e-01, -1.54773936e-01, -3.76617134e-01, 2.14844778e-01,
 2.70636857e-01, 1.52606845e-01, -1.65729210e-01, -8.79039764e-02, -
 2.36871049e-01, -2.43850291e-01, -1.23950234e-02, -1.21487342e-01, -
 6.77227259e-01, 4.79625314e-02, -2.49375626e-01, 1.47929177e-01], [-
 3.32397372e-01, 3.17085564e-01, -2.15766877e-02, 2.26619422e-01,

```

-1.88923404e-01, -2.72240341e-01, -1.01915300e-01, 2.17703342e-01, -
4.91908230e-02, 6.67579239e-03, -1.96696565e-01, 1.27620310e-01,
4.43532504e-02, -2.23154470e-01, -9.75689813e-02, -1.48875099e-02], [
3.45788226e-02, 2.60964125e-01, 1.73528329e-01, 4.35721800e-02, -
2.24993825e-01, 3.41639459e-01, 8.89787376e-02, 3.78814995e-01,
1.35706574e-01, 4.76858914e-02, 4.36455518e-01, -1.13926446e-02,
5.38167000e-01, 8.47948641e-02, 2.62887895e-01, 6.55220672e-02], [
1.20069645e-01, 2.74467170e-02, -3.43096964e-02, -2.77239501e-01, -
2.07900032e-01, -9.74288881e-02, 3.06276381e-01, -1.68170735e-01, -
2.12165579e-01, 9.70285162e-02, -4.93520014e-02, 8.43783468e-02, -
2.21807859e-03, 3.29344898e-01, -6.33658648e-01, -4.39513177e-01]],
dtype=float32), array([[ -0.17617251, -0.19658914, -0.39012647,
0.08372848, -0.02308262, 0.01299367, -0.32674885, -0.11666136, -
0.22822423, -0.2043311 , 0.46286932, 0.16909331, -0.44279933,
0.08047321, 0.23243937, -0.23827969], [ 0.08660343, -0.42268744,
0.00994206, 0.13964099, 0.02841771, -0.20661362, -0.14430282, -
0.48644593, -0.02023174, -0.07676803, 0.0358225 , -0.13958728,
0.50495106, 0.06580411, 0.38008708, 0.24988906], [-0.42879516, -
0.06104 , -0.10597127, -0.1213974 , -0.40142143, -0.18245745,
0.01378008, 0.12598825, -0.12244142, -0.04163726, -0.21751621,
0.41246885, 0.19250245, -0.53336424, 0.12973201, 0.05843278], [
0.04886275, 0.04668917, 0.15640222, 0.5073533 , -0.32711133,
0.04542294, 0.13108167, 0.05289675, 0.4339154 , -0.15059823,
0.17547204, 0.3351336 , -0.18170321, 0.14934203, 0.05931591,
0.41426212]], dtype=float32), array([ 0.0157386 , -0.16638139, -
0.13359238, 0.18050483, 1. , 1. , 1. , 1. , -0.38572335, -0.04125542,
-0.15839149, 0.12259395, -0.00141827, -0.05732121, -0.14989503,
0.14708103], dtype=float32)] {'name': 'dense_1', 'trainable': True,
'units': 1, 'activation': 'linear', 'use_bias': True,
'kernel_initializer': {'class_name': 'VarianceScaling', 'config':
{'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed':
None}}, 'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'kernel_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'bias_constraint': None} [array([[ 0.33279344], [ 0.5379698 ]], [
0.21944831], [-1.0494031 ]], dtype=float32), array([0.08148669],
dtype=float32)]

```

O3 SUF 7

```

{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1,
7), 'dtype': 'float32', 'return_sequences': False, 'return_state':
False, 'go_backwards': False, 'stateful': False, 'unroll': False,
'units': 3, 'activation': 'tanh', 'recurrent_activation':
'hard_sigmoid', 'use_bias': True, 'kernel_initializer':
{'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode':
'fan_avg', 'distribution': 'uniform', 'seed': None}},
'recurrent_initializer': {'class_name': 'Orthogonal', 'config':
{'gain': 1.0, 'seed': None}}, 'bias_initializer': {'class_name':
'Zeros', 'config': {}}, 'unit_forget_bias':

```



```

True, 'kernel_regularizer': None, 'recurrent_regularizer': None,
'bias_regularizer': None, 'activity_regularizer': None,
'kernel_constraint': None, 'recurrent_constraint': None,
'bias_constraint': None, 'dropout': 0.0, 'recurrent_dropout': 0.0,
'implementation': 1) [array([[ 0.63735306, 0.8213807 , 0.19265574, -
0.03945422, 0.1614415 , -0.10214731, -1.727694 , 0.6488847 , -
1.5136214 , -0.07411839, 0.55760723, -0.06158238], [ 0.8275915 , -
0.6950148 , 0.6466498 , 0.48435718, 0.0410924 , -0.03231615, -
0.38380405, 0.7405622 , -0.05096598, 0.37211862, -0.05243524,
0.41932383], [ 0.01813215, -0.12602569, 0.13780761, 0.23724729,
0.10860699, 0.17923695, 0.65886104, 0.09458397, 0.18757032,
0.09892161, -0.18483728, -0.36191827], [ 0.09328745, -0.25250193, -
0.02458695, -0.18258643, 0.1772657 , -0.08375886, -0.23165026,
0.8822581 , -0.37166288, -0.02372546, -0.5282112 , 0.49166465], [
0.2404742 , -0.4126898 , 0.17541628, -0.1163691 , -0.29564744,
0.10777605, 0.62836015, -0.60677177, 0.04571227, 0.21028773, -
0.41563052, 0.198601 ], [ 0.62588197, -0.29505172, 0.88102466,
0.3400712 , -0.20740402, 0.5357718 , -0.41598836, 0.71563965,
0.32722616, -0.10953631, -0.33698446, 0.99187744], [-0.11424942, -
0.24509422, 0.07965831, -0.3745987 , 0.45402092, 0.04122275,
0.4947176 , -0.35344732, -0.05096816, -0.13348277, -0.03998354,
0.5000398 ]], dtype=float32), array([[ 0.12336798, -0.26256737,
0.4248357 , 0.36498597, -0.49594355, 0.03308986, 0.09538739, -
0.18153313, 0.13894424, 0.31577802, 0.42475548, -0.11658525], [-
0.58244365, 0.13638154, -0.22785917, -0.17269391, -0.5485349 ,
0.01708786, -0.28578395, 0.14437146, -0.16227052, 0.29424682,
0.00560439, 0.20922232], [ 0.15805283, 0.48719367, 0.05391592, -
0.148451 , 0.17000327, 0.43492323, -0.0042397 , 0.3855691 , -
0.03018465, 0.36444333, 0.3029014 , -0.34712657]], dtype=float32),
array([ 0.6421713 , 0.00189048, 0.0542117 , 1. , 1. , 1. , 0.1614276
, -0.09126156, 0.0662864 , 0.43705094, 0.01341878, 0.02461145]),
dtype=float32) {'name': 'dense_1', 'trainable': True, 'units': 1,
'activation': 'linear', 'use_bias': True, 'kernel_initializer':
{'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode':
'fan_avg', 'distribution': 'uniform', 'seed': None}},
'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'kernel_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'bias_constraint': None} [array([[ -0.35257035], [ 1.1134621 ], [ -
0.8297598 ]], dtype=float32), array([0.05508922], dtype=float32)]

```

PM₁₀ SUF 1

```

{'name': 'lstm_2', 'trainable': True, 'batch_input_shape': (None, 1, 1
), 'dtype': 'float32', 'return_sequences': False, 'return_state': Fal
se, 'go_backwards': False, 'stateful': False, 'unroll': False, 'units
': 2, 'activation': 'tanh', 'recurrent_activation': 'hard sigmoid', '
use_bias': True, 'kernel_initializer': {'class_name': 'VarianceScalin
g', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'unif
orm', 'seed': None}}, 'recurrent_initializer': {'class_name': 'Orthog
onal', 'config': {'gain': 1.0, 'seed': None}}, 'bias_initializer': {'

```

```

class_name': 'Zeros', 'config': {}}, 'unit_forget_bias': True, 'kernel_regularizer': None, 'recurrent_regularizer': None, 'bias_regularizer': None, 'activity_regularizer': None, 'kernel_constraint': None, 'recurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0, 'recurrent_dropout': 0.0, 'implementation': 1}
[array([[ 0.14513265,  0.924111, -0.22655207,  0.611815, -0.08354488,
         -1.5068641, -0.99065274,  0.7747102 ], dtype=float32), array([[[-0.43073112, -0.3448399,  0.6581061, -0.09964278, -0.04005455,
         0.11729331, -0.11278772, -0.47375172],
        [ 0.49048582, -0.47797805,  0.37565213, -0.25560525,  0.2752947,
         -0.30729875, -0.04861751,  0.38978037]], dtype=float32), array([[[-2.3012023,  1.014852,  1.,  1.,  0.01334897,
         0.1304977, -1.8090823,  1.1217986 ], dtype=float32])
{'name': 'dense 2', 'trainable': True, 'units': 1, 'activation': 'linear', 'use_bias': True, 'kernel_initializer': {'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed': None}}, 'bias_initializer': {'class_name': 'Zeros', 'config': {}}, 'kernel_regularizer': None, 'bias_regularizer': None, 'activity_regularizer': None, 'kernel_constraint': None, 'bias_constraint': None}
[array([[[-0.01658262],
        [-1.15249   ]], dtype=float32), array([0.08438526], dtype=float32)]

```

PM₁₀ SUF 6

```

{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1, 4), 'dtype': 'float32', 'return_sequences': False, 'return_state': False, 'go_backwards': False, 'stateful': False, 'unroll': False, 'units': 2, 'activation': 'tanh', 'recurrent_activation': 'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed': None}}, 'recurrent_initializer': {'class_name': 'Orthogonal', 'config': {'gain': 1.0, 'seed': None}}, 'bias_initializer': {'class_name': 'Zeros', 'config': {}}, 'unit_forget_bias': True, 'kernel_regularizer': None, 'recurrent_regularizer': None, 'bias_regularizer': None, 'activity_regularizer': None, 'kernel_constraint': None, 'recurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0, 'recurrent_dropout': 0.0, 'implementation': 1} [array([[ 0.9197628,  1.1130164, -0.25170317, -0.04964542,  1.6814996, -1.7194366, -0.00810809,  0.8914544 ], [-0.5817141, -0.77901495, -0.01866853, -0.50618935, -0.44923064,  0.22642523,  0.08936359,  0.44594315], [-0.11120557, -0.11861939, -0.49122,  0.09658372, -0.08605235, -0.11134491,  0.15637629, -0.23628286], [-0.17717056, -0.20105524, -0.00720036,  0.29852968,  0.03996613,  0.15443094,  0.1597898,  0.23522966]], dtype=float32), array([[ 0.10285524,  0.02719793, -0.12311766,  0.22590087,  0.68737066, -0.21384801,  0.4281773,  0.47004965], [-0.3293994, -0.5659455, -0.08715995,  0.33737484,

```

```
-0.20980512, -0.59293926, 0.14901614, -0.1788354 ]], dtype=float32),
array([ 0.841898 , 0.5605545 , 1. , 1. , -0.12495554, 0.03735626,
0.8903708 , 0.6469615 ], dtype=float32)] {'name': 'dense_1',
'trainable': True, 'units': 1, 'activation': 'linear', 'use_bias':
True, 'kernel_initializer': {'class_name': 'VarianceScaling',
'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform',
'seed': None}}, 'bias_initializer': {'class_name': 'Zeros', 'config':
{}}, 'kernel_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'bias_constraint': None} [array([[ 0.7987611], [-0.8523435]],
dtype=float32), array([0.0600848], dtype=float32)]
```

PM₁₀ SUF 7

```
{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1,
10), 'dtype': 'float32', 'return_sequences': False, 'return_state':
False, 'go_backwards': False, 'stateful': False, 'unroll': False,
'units': 3, 'activation': 'tanh', 'recurrent_activation':
'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class_name':
'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg',
'distribution': 'uniform', 'seed': None}}, 'recurrent_initializer':
{'class_name': 'Orthogonal', 'config': {'gain': 1.0, 'seed': None}},
'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'unit_forget_bias': True, 'kernel_regularizer': None,
'recurrent_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'recurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0,
'recurrent_dropout': 0.0, 'implementation': 1} [array([[ 2.760391 ,
0.5591588 , 0.6279898 , -0.03666559, 0.15003085, -0.09492758,
1.8597184 , 0.99277174, -1.5215431 , -0.08727627, 0.32552943, 0.3317588
], [-0.24027973, -0.5961968 , 0.33275953, 0.45012295, 0.03818798, -
0.03003207, -0.22135496, -0.00509499, 0.15175086, -0.6979708 , -
0.06871361, 0.07215982], [-0.79022056, -0.26089087, 0.391198 ,
0.22047877, 0.10093069, 0.16656852, 0.24975307, 0.20861502, -
0.04446549, -0.8732517 , -0.35432723, -0.13712355], [ 1.1643157 , -
0.09624253, -0.1957363 , -0.16968128, 0.16473663, -0.07783881,
0.02508136, 0.0990722 , -0.1044059 , 0.2554298 , -0.40312698,
0.28458223], [ 1.6211625 , -0.04533537, 0.0121359 , -0.10814419, -
0.2747512 , 0.10015851, 0.25339937, -0.18571185, -0.3038168 ,
0.62702596, -0.11489088, 0.03673462], [ 0.3582375 , -0.32662082,
0.05061976, 0.3160351 , -0.19274476, 0.49790365, -0.40008768, 0.6112404
, 0.01291255, -0.38410354, -0.4574538 , 0.19525516], [-0.9476026 , -
0.1883359 , -0.0568678 , -0.34812224, 0.4219309 , 0.0383091 , 0.4128211
, -0.46110696, 0.06769801, -0.624038 , -0.06422195, 0.29448363], [
1.0948824 , -0.68633646, 0.23216882, 0.48793834, 0.31005853, -
0.42934436, 0.21810055, -0.25558537, -0.3873523 , 0.94185174, -
0.0106523 , -0.1789205 ], [ 0.75644714, 0.05792641, -0.54146856,
0.19302481, -0.4471966 , -0.12733257, 0.21126479, 0.2001748 ,
```

```

-0.9452154 , 0.3292928 , -0.2541809 , 0.08900159], [-0.78488874, -
0.22581206, 0.39174396, 0.3314609 , 0.49799687, 0.15449244, 0.24246769,
-0.18842138, 0.49649936, -0.78893816, -0.16863002, 0.74966854]],
dtype=float32), array([[ 0.12336798, -0.26256737, 0.4248357 ,
0.36498597, -0.49594355, 0.03308986, 0.09538739, -0.18153313,
0.13894424, 0.31577802, 0.42475548, -0.11658525], [-0.58244365,
0.13638154, -0.22785917, -0.17269391, -0.5485349 , 0.01708786, -
0.28578395, 0.14437146, -0.16227052, 0.29424682, 0.00560439,
0.20922232], [ 0.15805283, 0.48719367, 0.05391592, -0.148451 ,
0.17000327, 0.43492323, -0.0042397 , 0.3855691 , -0.03018465,
0.36444333, 0.3029014 , -0.34712657]], dtype=float32), array([
1.0577985 , -0.23157236, 0.098832 , 1. , 1. , 1. , 0.09696368, -
0.04017352, 0.18334112, 0.555012 , -0.24287874, 0.09266759],
dtype=float32)] {'name': 'dense_1', 'trainable': True, 'units': 1,
'activation': 'linear', 'use_bias': True, 'kernel_initializer':
{'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode':
'fan_avg', 'distribution': 'uniform', 'seed': None}},
'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'kernel_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'bias_constraint': None} [array([[[-0.4802921 ], [ 0.79094744], [-
0.8141838 ]], dtype=float32), array([0.07668796], dtype=float32)]

```

SO₂ SUF 1

```

{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1, 4), 'dtype':
'float32', 'return_sequences': False, 'return_state': False, 'go_backwards': Fals
e, 'stateful': False, 'unroll': False, 'units': 5, 'activation': 'tanh', 'recurre
nt_activation': 'hard sigmoid', 'use_bias': True, 'kernel_initializer': {'class n
ame': 'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distributio
n': 'uniform', 'seed': None}}, 'recurrent_initializer': {'class name': 'Orthogona
l', 'config': {'gain': 1.0, 'seed': None}}, 'bias_initializer': {'class_name': 'Z
eros', 'config': {}}, 'unit_forget_bias': True, 'kernel_regularizer': None, 'recu
rrent_regularizer': None, 'bias_regularizer': None, 'activity_regularizer': None,
'kernel_constraint': None, 'recurrent_constraint': None, 'bias_constraint': None,
'dropout': 0.0, 'recurrent_dropout': 0.0, 'implementation': 1}
[array([[[-2.9728234e-01, -7.0802552e-01, -1.1464664e+00, 2.1250525e+00,
-1.2710268e+00, -9.0886235e-02, -4.9755681e-01, -3.0779839e-04,
-3.6941290e-01, -3.8387847e-01, 2.1774294e-02, -1.9729182e+00,
-1.9272878e+00, -5.4404336e-01, -1.3570434e-01, 5.4394122e-02,
-1.0535318e+00, -1.0498776e+00, 1.8155873e+00, -1.3998009e+00],
[-9.6805686e-01, 7.2453493e-01, 5.5524832e-01, -1.5267498e+00,
-1.9947189e-01, -4.9314260e-02, -5.0914288e-03, 2.1109235e-01,
9.6633792e-02, 1.5947723e-01, 6.5337682e-01, 5.4624915e-01,
-6.5079853e-02, 5.7271594e-01, 3.4463790e-01, -1.3704838e+00,
1.9109209e-01, 1.8171600e-01, -1.4900161e+00, -5.2023208e-01],
[ 5.9997725e-01, 9.4936639e-01, 7.6537132e-01, 6.7454290e-01,
3.5511079e-01, -4.2812300e-01, -3.6530304e-01, 2.2027588e-01,
2.6833987e-01, -7.7884197e-02, 2.6294550e-01, -2.3478931e-01,
-2.7624259e-02, 5.4224527e-01, -5.9620000e-02, 2.2715934e-01,
8.2982165e-01, 1.1963862e+00, 3.9870554e-01, 3.9934438e-01],
[ 2.7138367e-01, 3.8887817e-01, 3.4847057e-01, 2.6496249e-01,
-7.9714380e-02, 4.7670650e-01, -2.5901651e-01, 2.2053134e-01,
3.9280498e-01, -3.6165059e-01, -2.0820630e-01, 7.4977122e-02,
7.8818358e-02, 3.7782885e-02, -3.2760498e-01, -2.8108078e-01,
9.4057405e-01, 3.8493091e-01, 2.4932480e-01, -1.4692521e-01]],

```

```

dtype=float32), array([[ -0.19502647, -0.11766353, -0.2091057 , -0.07414206,
0.2104231 ,
-0.17554195, 0.1331939 , 0.19254029, -0.6808049 , 0.0228696 ,
-0.00799542, -0.09402898, 0.03917344, 0.34188852, 0.0898625 ,
-0.21057948, -0.14237814, 0.15418458, 0.07697924, 0.27433053],
[-0.40956342, -0.387628 , 0.3160286 , -0.06731085, -0.22597058,
-0.09914427, 0.26732412, -0.36454418, -0.00151767, -0.03797069,
0.04280493, 0.19495293, 0.34027818, -0.03139111, 0.19635597,
-0.20405263, 0.17135224, 0.05234374, 0.14648469, -0.14331992],
[-0.1018487 , -0.15790077, 0.23064071, -0.07212225, 0.10435078,
0.3077141 , 0.14377782, 0.18532777, 0.00789372, -0.13587615,
0.33400774, 0.04201511, -0.21418495, 0.16989745, -0.3263934 ,
-0.24610054, 0.06090693, 0.17974024, -0.5473686 , -0.19074549],
[-0.03535502, -0.26338255, -0.18268858, -0.32899106, 0.21480972,
-0.18155822, -0.416624 , -0.4153166 , -0.07406035, 0.01818663,
-0.2835144 , -0.01412864, 0.04152709, -0.22246008, -0.38509777,
-0.1057838 , -0.08809126, 0.03834176, -0.23428966, -0.03712576],
[-0.04871237, -0.2781039 , -0.25314048, 0.20102029, -0.11198268,
-0.0988622 , -0.19645576, 0.29811674, -0.24689929, -0.25862923,
0.08655382, 0.19551487, 0.22090916, -0.16097338, 0.11733126,
0.48229218, 0.09174158, 0.06652057, -0.21806727, -0.3331175 ]],
dtype=float32), array([-0.95694554, 0.4175404 , 0.14959383, -0.17199504,
-1.1377529 ,
1. , 1. , 1. , 1. , 1. ,
-0.11404169, 0.13428974, 0.03392003, -0.10534134, 0.05533162,
-0.8426929 , 0.25322646, 0.09133583, -0.01552259, -1.1631607 ],
dtype=float32)]
{'name': 'dense_1', 'trainable': True, 'units': 1, 'activation': 'linear', 'use_b
ias': True, 'kernel_initializer': {'class_name': 'VarianceScaling', 'config': {'s
cale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed': None}}, 'bias_i
nitializer': {'class_name': 'Zeros', 'config': {}}, 'kernel_regularizer': None, '
bias_regularizer': None, 'activity_regularizer': None, 'kernel_constraint': None,
'bias_constraint': None}
[array([[ 0.06954876],
[-0.4881182 ],
[ 1.1513928 ],
[ 0.5934152 ],
[ 0.03583176]], dtype=float32), array([0.03396836], dtype=float32)]

```

SO₂ SUF 6

```

{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1,
20), 'dtype': 'float32', 'return_sequences': False, 'return_state':
False, 'go_backwards': False, 'stateful': False, 'unroll': False,
'units': 2, 'activation': 'tanh', 'recurrent_activation':
'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class_name':
'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg',
'distribution': 'uniform', 'seed': None}}, 'recurrent_initializer':
{'class_name': 'Orthogonal', 'config': {'gain': 1.0, 'seed': None}},
'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'unit_forget_bias': True, 'kernel_regularizer': None,
'recurrent_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'recurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0,
'recurrent_dropout': 0.0, 'implementation': 1} [array([[
1.35770738e+00, 1.28758085e+00, -1.64778411e-01, -3.25005651e-02, -
2.20742536e+00,

```

```

-2.38426375e+00, 6.72823787e-01, 9.98657465e-01], [-5.42645991e-01, -
7.12325513e-01, -1.22214258e-02, -3.31378758e-01, 3.62723380e-01, -
2.10219219e-01, -8.63268971e-02, 8.51937979e-02], [-3.90444994e-02, -
1.78722411e-01, -3.21578979e-01, 6.32289052e-02, 5.22051789e-02, -
5.62194772e-02, 1.62273824e-01, -2.76944011e-01], [ 1.00015767e-01, -
8.68924111e-02, -4.71374393e-03, 1.95433557e-01, -7.28819072e-02,
4.03268114e-02, 3.36340964e-01, 1.57542765e-01], [-9.86805558e-02,
7.49367476e-02, -1.24978215e-01, -4.01375175e-01, -1.82096034e-01,
1.52467147e-01, -1.68130383e-01, -1.90396458e-01], [ 3.17631006e-01,
1.04548097e-01, -1.07549369e-01, 2.15632677e-01, -4.70904410e-01, -
4.95428085e-01, -1.96022332e-01, 3.93403560e-01], [ 2.17918053e-01, -
1.28190026e-01, -1.32634312e-01, -9.58595872e-02, 3.25383656e-02,
6.05240107e-01, 2.80955076e-01, -2.09748343e-01], [-2.23812580e-01,
2.68435657e-01, -8.35163295e-02, -1.06444269e-01, 1.99126020e-01, -
6.13941438e-02, 4.18769307e-02, 3.17951322e-01], [-5.87632716e-01, -
1.40156135e-01, -2.39802703e-01, 2.04172373e-01, 3.80901515e-01, -
2.06055269e-01, -5.27705193e-01, -4.17822927e-01], [ 2.37346306e-01,
5.40026009e-01, -3.47451061e-01, -3.08577389e-01, 1.78217947e-01,
8.69735256e-02, 4.96472210e-01, 2.58743376e-01], [-2.90846020e-01, -
1.21639222e-02, 1.99576616e-01, 1.81440115e-02, -4.51416671e-02, -
1.86254993e-01, 2.17413664e-01, 4.89805520e-01], [-2.33327528e-03, -
5.32179356e-01, 2.15451777e-01, -1.83851928e-01, -6.37508690e-01,
3.18646222e-01, -2.64229421e-02, -2.53347456e-01], [ 1.99171722e-01,
3.54542106e-01, -4.24477279e-01, 1.71098232e-01, -3.43160719e-01,
3.37248445e-02, 4.86029088e-01, 7.55973309e-02], [-7.14825332e-01, -
1.58955082e-01, 3.90852690e-02, 1.44928336e-01, 6.58176094e-03,
9.19889212e-02, -1.07868575e-01, 3.52061214e-03], [ 4.83684570e-01,
2.22118571e-01, 4.50346291e-01, -1.92357510e-01, 2.45183483e-01, -
2.10622787e-01, 5.51120080e-02, 5.35258591e-01], [-3.96433473e-02,
1.06980786e-01, 1.39364004e-02, 3.03176343e-02, 4.29384634e-02, -
2.48735603e-02, 4.24726754e-02, 6.41586334e-02], [-5.62318504e-01,
3.20367105e-02, 4.04470980e-01, -3.87378514e-01, 6.51459023e-02,
1.36053786e-02, -1.44161463e-01, -1.92272767e-01], [ 4.44052726e-01,
2.70023108e-01, 3.84288728e-01, 7.07606077e-02, -4.19500470e-01,
2.06386879e-01, 3.16712290e-01, 5.03339171e-01], [ 3.83500397e-01,
5.52741051e-01, 2.92628706e-02, 3.77291262e-01, 1.55577809e-01, -
1.67353585e-01, 5.78000734e-04, 2.13298947e-01], [-1.72629908e-01,
1.21239826e-01, -1.89900875e-01, -6.98159933e-02, -3.13096017e-01,
2.42405891e-01, -4.39325035e-01, -1.78499237e-01]], dtype=float32),
array([[ 0.10285524, 0.02719793, -0.12311766, 0.22590087, 0.68737066,
-0.21384801, 0.4281773 , 0.47004965], [-0.3293994 , -0.5659455 ,
-0.08715995, 0.33737484, -0.20980512, -0.59293926, 0.14901614, -
0.1788354 ]], dtype=float32), array([0.32624534, 0.49825063, 1. , 1. ,
0.13571201, 0.04282895, 0.3776192 , 0.4449917 ]], dtype=float32)]
{'name': 'dense_1', 'trainable': True, 'units': 1, 'activation':
'linear', 'use_bias': True, 'kernel_initializer': {'class_name':
'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg',
'distribution': 'uniform', 'seed': None}}, 'bias_initializer':
{'class_name': 'Zeros', 'config': {}}, 'kernel_regularizer': None,
'bias_regularizer': None, 'activity_regularizer': None,
'kernel_constraint': None, 'bias_constraint': None} [array([[[-

```

```
0.45635703], [-0.59827644]], dtype=float32), array([0.03374797],
dtype=float32)]
```

SO₂ SUF 7

```
{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1,
10), 'dtype': 'float32', 'return_sequences': False, 'return_state':
False, 'go_backwards': False, 'stateful': False, 'unroll': False,
'units': 3, 'activation': 'tanh', 'recurrent_activation':
'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class_name':
'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg',
'distribution': 'uniform', 'seed': None}}, 'recurrent_initializer':
{'class_name': 'Orthogonal', 'config': {'gain': 1.0, 'seed': None}},
'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'unit_forget_bias': True, 'kernel_regularizer': None,
'recurrent_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'recurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0,
'recurrent_dropout': 0.0, 'implementation': 1} [array([[ 0.77504855,
0.88021505,

0.27265596, -0.03666559, 0.15003085, -0.09492758, -1.43157 , 0.7713836
, -1.4858128 , -0.7133332 , 0.611478 , 0.03244465], [-0.12990198, -
0.308249 , 0.4657421 , 0.45012295, 0.03818798, -0.03003207, -
0.43753216, 0.42180288, 0.07877219, -0.26083174, 0.27675545, 0.2424071
], [ 1.7595624 , 0.0839085 , 0.15607953, 0.22047877, 0.10093069,
0.16656852, 0.49868912, -0.01384978, 0.15097535, -0.63012946, -
0.03146398, -0.31538218], [ 0.00702976, -0.03661614, 0.01405792, -
0.16968128, 0.16473663, -0.07783881, -0.09465649, 0.5215984 , -
0.1477882 , 0.18594736, -0.29620773, 0.5048982 ], [ 2.295265 , -
0.06078807, 0.09788381, -0.10814419, -0.2747512 , 0.10015851,
0.44111934, -0.27261367, -0.09092348, -0.0398041 , 0.03125929,
0.12062653], [-0.16745259, -0.16466317, 0.53159136, 0.3160351 , -
0.19274476, 0.49790365, -0.42380545, 0.6916886 , 0.39018545, -0.1066499
, -0.1926324 , 0.63858885], [ 1.7125623 , 0.14812739, -0.18913977, -
0.34812224, 0.4219309 , 0.0383091 , 0.4608763 , -0.3808515 , -
0.11317293, -0.67429185, 0.30381832, 0.17073832], [-0.30990687, -
0.5173966 , 0.32953474, 0.48793834, 0.31005853, -0.42934436,
0.05649432, 0.20115197, -0.44551885, 0.6438092 , 0.2604888 , -
0.08407491], [ 1.4820594 , 0.06227887, -0.3769319 , 0.19302481, -
0.4471966 , -0.12733257, 0.6562471 , -0.08724289, -0.06620353, -
0.54272723, -0.17206143, 0.22855899], [-0.19027957, -0.18985398,
0.34372777, 0.3314609 , 0.49799687, 0.15449244, 0.10025706, 0.38592684,
0.27028465, -0.69784313, -0.09317268, 0.7213977 ]], dtype=float32),
array([[ 0.12336798, -0.26256737, 0.4248357 , 0.36498597, -0.49594355,
0.03308986, 0.09538739, -0.18153313, 0.13894424, 0.31577802,
0.42475548, -0.11658525], [-0.58244365, 0.13638154, -0.22785917, -
0.17269391, -0.5485349 , 0.01708786, -0.28578395, 0.14437146, -
0.16227052, 0.29424682, 0.00560439, 0.20922232], [ 0.15805283,
0.48719367, 0.05391592, -0.148451 , 0.17000327, 0.43492323, -0.0042397
```

```

, 0.3855691 , -0.03018465, 0.36444333, 0.3029014 , -0.34712657]],
dtype=float32), array([ 1.23284054e+00, -1.25288963e-03, -1.48768835e-
02, 1.00000000e+00, 1.00000000e+00, 1.00000000e+00, 2.17728302e-01, -
7.11935312e-02, 1.24281138e-01, 4.82605517e-01, 3.40996106e-04, -
4.55306731e-02], dtype=float32)) {'name': 'dense_1', 'trainable':
True, 'units': 1, 'activation': 'linear', 'use_bias': True,
'kernel_initializer': {'class_name': 'VarianceScaling', 'config':
{'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed':
None}}, 'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'kernel_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'bias_constraint': None} [array([[ -0.37337872], [ 1.0728024 ], [ -
0.74666476]], dtype=float32), array([[0.08905973], dtype=float32)]

```


Lampiran 9. Perbandingan Model AR Terbaik pada Model TSR dengan AR *Error*

Variabel	Model AR	RMSE	RMSEP	sSMAPE	sMAPEP
CO SUF 1	AR(1)	0.190	0.280	17.136	14.598
	AR(1) ⁴⁸	0.357	0.459	35.081	27.469
	AR(1) ³³⁶	0.381	0.457	38.640	28.358
	AR(1)(1) ⁴⁸	0.190	0.280	17.133	14.770
	AR(1)(1)³³⁶	0.190	0.279	17.128	14.578
	AR(1)(1) ⁴⁸ (1) ³³⁶	0.190	0.279	17.126	14.744
CO SUF 6	AR(1)	0.676	0.714	50.533	16.963
	AR(1) ⁴⁸	0.929	1.125	64.332	43.708
	AR(1) ³³⁶	0.992	0.779	67.094	28.033
	AR(1)(1) ⁴⁸	0.673	0.725	50.571	17.250
	AR(1)(1)³³⁶	0.674	0.672	50.306	15.951
	AR(1)(1) ⁴⁸ (1) ³³⁶	0.671	0.682	50.366	16.256
CO SUF 7	AR(1)	0.423	0.142	46.916	200.000
	AR(1) ⁴⁸	0.776	0.529	65.377	200.000
	AR(1) ³³⁶	0.884	0.812	71.776	200.000
	AR(1)(1) ⁴⁸	0.418	0.140	46.797	200.000
	AR(1)(1) ³³⁶	0.421	0.133	46.970	200.000
	AR(1)(1)⁴⁸(1)³³⁶	0.418	0.132	46.764	200.000
NO ₂ SUF 1	AR(1)	6.618	4.668	22.743	41.626
	AR(1) ⁴⁸	11.727	6.874	40.505	50.789
	AR(1)³³⁶	12.862	5.070	45.208	43.705
	AR(1)(1) ⁴⁸	6.611	4.754	22.726	41.479
	AR(1)(1) ³³⁶	6.619	4.648	22.732	41.940
	AR(1)(1) ⁴⁸ (1) ³³⁶	6.613	4.731	22.714	41.768
NO ₂	AR(1)	5.451	7.765	37.961	29.633

Variabel	Model AR	RMSE	RMSEP	sSMAPE	sMAPEP
SUF 6	AR(1) ⁴⁸	11.072	13.709	61.210	58.043
	AR(1) ³³⁶	11.773	12.601	63.869	56.012
	AR(1)(1) ⁴⁸	5.445	7.706	37.942	28.844
	AR(1)(1) ³³⁶	5.452	13.658	37.949	66.745
	AR(1)(1)⁴⁸(1)³³⁶	5.446	7.683	37.931	28.803
NO ₂ SUF 7	AR(1)	8.003	6.333	17.464	11.335
	AR(1) ⁴⁸	13.923	16.607	35.476	30.252
	AR(1)³³⁶	15.207	8.499	40.115	17.152
	AR(1)(1) ⁴⁸	7.838	8.347	17.258	15.571
	AR(1)(1) ³³⁶	7.933	5.894	17.352	11.276
	AR(1)(1) ⁴⁸ (1) ³³⁶	7.798	7.752	17.131	14.921
O ₃ SUF 1	AR(1)	7.733	4.209	12.051	58.154
	AR(1) ⁴⁸	14.416	31.294	25.330	156.599
	AR(1) ³³⁶	20.426	16.636	33.556	132.918
	AR(1)(1) ⁴⁸	7.712	4.447	12.142	61.987
	AR(1)(1) ³³⁶	7.728	4.194	12.015	60.214
	AR(1)(1) ⁴⁸ (1) ³³⁶	7.707	4.425	12.101	62.033
O ₃ SUF 6	AR(1)	5.054	5.967	15.683	36.289
	AR(1) ⁴⁸	11.239	17.072	38.321	82.784
	AR(1) ³³⁶	12.360	13.921	44.321	79.029
	AR(1)(1)⁴⁸	5.053	5.935	15.670	35.947
	AR(1)(1) ³³⁶	5.054	5.971	15.689	36.287
	AR(1)(1) ⁴⁸ (1) ³³⁶	5.053	5.939	15.677	35.939
O ₃ SUF 7	AR(1)	6.031	2.521	18.657	18.644
	AR(1) ⁴⁸	10.770	5.552	36.179	41.631
	AR(1) ³³⁶	11.456	3.973	40.709	35.469
	AR(1)(1) ⁴⁸	5.990	2.802	18.550	17.585
	AR(1)(1)³³⁶	6.018	2.334	18.556	17.723

Variabel	Model AR	RMSE	RMSEP	sSMAPE	sMAPEP
	AR(1)(1) ⁴⁸ (1) ³³⁶	5.981	2.646	18.464	16.876
PM ₁₀ SUF 1	AR(1)	11.377	2.977	20.133	10.408
	AR(1) ⁴⁸	24.208	3.970	49.884	16.660
	AR(1) ³³⁶	25.042	3.044	51.762	11.674
	AR(1)(1) ⁴⁸	11.376	2.979	20.148	10.585
	AR(1)(1) ³³⁶	11.378	2.990	20.155	10.485
	AR(1)(1) ⁴⁸ (1) ³³⁶	11.376	2.989	20.167	10.647
PM ₁₀ SUF 6	AR(1)	3.506	0.437	12.666	3.127
	AR(1) ⁴⁸	13.009	5.848	51.983	33.154
	AR(1) ³³⁶	13.479	7.742	55.167	52.639
	AR(1)(1) ⁴⁸	3.506	0.465	12.667	3.518
	AR(1)(1) ³³⁶	3.505	0.459	12.679	3.527
	AR(1)(1) ⁴⁸ (1) ³³⁶	3.505	0.459	12.680	3.432
PM ₁₀ SUF 7	AR(1)	14.578	2.959	12.019	9.375
	AR(1) ⁴⁸	33.937	13.057	34.842	36.286
	AR(1) ³³⁶	36.435	18.796	38.332	45.091
	AR(1)(1) ⁴⁸	14.402	3.263	11.997	9.900
	AR(1)(1) ³³⁶	14.527	3.066	11.965	9.761
	AR(1)(1) ⁴⁸ (1) ³³⁶	14.383	3.303	11.940	10.222
SO ₂ SUF 1	AR(1)	16.833	5.239	38.327	32.315
	AR(1) ⁴⁸	20.630	7.421	49.194	47.731
	AR(1) ³³⁶	21.801	6.886	52.697	43.159
	AR(1)(1) ⁴⁸	16.778	5.251	38.453	33.266
	AR(1)(1)³³⁶	16.806	5.180	38.437	31.649
	AR(1)(1) ⁴⁸ (1) ³³⁶	16.755	5.176	38.539	32.269
SO ₂ SUF 6	AR(1)	5.705	3.056	19.866	21.374
	AR(1) ⁴⁸	11.222	3.996	38.169	30.011
	AR(1) ³³⁶	12.137	3.139	42.334	24.688

Variabel	Model AR	RMSE	RMSEP	sSMAPE	sMAPEP
	AR(1)(1) ⁴⁸	5.702	3.064	19.901	21.390
	AR(1)(1)³³⁶	5.699	2.997	19.862	20.930
	AR(1)(1) ⁴⁸ (1) ³³⁶	5.697	7.450	19.899	50.234
SO ₂ SUF 7	AR(1)	3.120	1.963	9.706	9.897
	AR(1) ⁴⁸	6.241	4.174	21.973	23.422
	AR(1) ³³⁶	6.649	8.419	24.483	46.510
	AR(1)(1) ⁴⁸	3.092	2.058	9.576	10.203
	AR(1)(1) ³³⁶	3.114	1.999	9.646	9.686
	AR(1)(1)⁴⁸(1)³³⁶	3.090	1.971	9.540	9.632

Lampiran 10. *Output Model AR dari Residual Time Series Regression pada Lima Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya*

CO SUF 6

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,1	0.76017	0.0050326	151.05	<.0001	1
AR2,1	0.08844	0.0079152	11.17	<.0001	336

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	4724.15	4	<.0001	-0.371	0.281	-0.058	0.180	0.018	0.160
12	5742.73	10	<.0001	0.045	0.143	0.023	0.140	0.035	0.127
18	6353.11	16	<.0001	0.070	0.080	0.089	0.071	0.096	0.048
24	6953.37	22	<.0001	0.102	0.056	0.092	0.068	0.066	0.067
30	7456.18	28	<.0001	0.073	0.062	0.078	0.071	0.051	0.081
36	7898.32	34	<.0001	0.045	0.089	0.038	0.093	0.046	0.061
42	8364.62	40	<.0001	0.074	0.035	0.103	0.031	0.090	0.032
48	9954.24	46	<.0001	0.121	-0.004	0.126	-0.056	0.236	-0.062

CO SUF 7

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,1	0.86947	0.0038282	227.12	<.0001	1
AR2,1	0.14022	0.0076959	18.22	<.0001	48
AR3,1	0.06646	0.0077366	8.59	<.0001	336

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	45.36	3	<.0001	-0.047	-0.013	-0.004	-0.016	0.000	0.003
12	101.09	9	<.0001	0.030	0.006	0.025	0.028	0.029	0.010
18	126.42	15	<.0001	0.012	0.019	0.006	0.021	0.012	0.019
24	249.68	21	<.0001	0.032	0.030	0.048	0.041	0.034	0.015
30	367.24	27	<.0001	0.041	0.011	0.024	0.061	0.015	0.026
36	390.53	33	<.0001	0.008	0.023	0.011	0.005	0.012	0.022
42	416.77	39	<.0001	-0.003	0.022	0.025	0.015	0.002	0.014
48	675.88	45	<.0001	0.012	0.020	0.039	0.027	0.110	-0.015

NO₂ SUF 1

Parameter	Estimate	Standard Error	t Value	Approx Pr > t 	Lag
AR1,1	0.87019	0.0037922	229.47	<.0001	1
AR2,1	0.02773	0.0077324	3.59	0.0003	336

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	122.14	4	<.0001	0.027	-0.060	-0.045	-0.011	-0.014	0.021
12	176.48	10	<.0001	0.010	0.010	0.035	0.019	0.002	0.038
18	234.78	16	<.0001	0.025	0.032	0.008	0.022	0.020	0.028
24	274.92	22	<.0001	0.017	0.009	0.030	0.028	0.018	-0.004
30	311.25	28	<.0001	0.021	0.015	0.029	0.021	0.013	0.008
36	372.51	34	<.0001	0.019	0.023	0.021	0.033	0.025	0.024

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
42	427.11	40	<.0001	0.032	0.025	0.029	0.004	0.025	0.010
48	958.62	46	<.0001	0.019	0.019	0.035	0.029	0.163	0.042

NO₂ SUF 6

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,1	0.88612	0.0035788	247.60	<.0001	1
AR2,1	0.04877	0.0077346	6.31	<.0001	48
AR3,1	0.01312	0.0078063	1.68	0.0927	336

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	311.65	3	<.0001	0.106	-0.066	-0.046	-0.021	-0.015	-0.007
12	325.19	9	<.0001	0.010	0.014	-0.002	0.009	0.014	0.014
18	344.67	15	<.0001	0.006	-0.012	-0.006	-0.012	-0.024	-0.014
24	346.52	21	<.0001	0.002	0.004	-0.004	0.004	0.008	0.002
30	348.64	27	<.0001	0.003	-0.004	-0.007	0.002	-0.004	-0.005
36	356.83	33	<.0001	0.003	0.002	0.018	0.010	0.007	0.004
42	375.95	39	<.0001	0.003	0.014	0.019	0.020	0.013	0.004
48	630.41	45	<.0001	0.012	0.040	0.013	0.022	0.112	-0.003

NO₂ SUF 7

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,1	0.87108	0.0037884	229.93	<.0001	1
AR2,1	0.13738	0.0078146	17.58	<.0001	336

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	104.24	4	<.0001	-0.021	-0.055	-0.043	0.003	-0.016	0.025
12	199.00	10	<.0001	0.029	0.036	0.027	0.026	0.037	0.027
18	255.72	16	<.0001	0.014	0.035	0.028	0.010	0.025	0.021
24	360.05	22	<.0001	0.018	0.044	0.041	0.029	0.034	0.015
30	444.53	28	<.0001	0.021	0.030	0.030	0.039	0.024	0.024
36	499.53	34	<.0001	0.032	0.017	0.011	0.036	0.018	0.014
42	623.63	40	<.0001	0.030	0.041	0.034	0.031	0.037	0.036
48	1201.30	46	<.0001	0.007	0.022	0.018	0.035	0.027	0.176

O₃ SUF 1

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,1	0.95700	0.0022268	429.75	<.0001	1

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	316.81	5	<.0001	-0.086	-0.105	0.007	-0.001	-0.001	0.009
12	324.78	11	<.0001	-0.003	-0.007	0.013	0.011	0.009	0.006
18	336.02	17	<.0001	0.006	0.013	0.010	0.010	0.008	0.014
24	337.56	23	<.0001	0.006	0.002	0.002	0.003	-0.006	0.002
30	347.51	29	<.0001	0.012	-0.014	0.010	0.010	0.007	-0.001
36	361.00	35	<.0001	0.006	0.011	0.010	0.008	0.018	0.012
42	382.02	41	<.0001	0.016	0.022	0.009	0.016	0.009	0.009
48	3677.67	47	<.0001	0.020	0.021	-0.079	0.004	0.426	-0.071

O₃ SUF 6

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,1	0.91177	0.0031690	287.71	<.0001	1
AR2,1	0.01795	0.0077344	2.32	0.0203	48

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	234.03	4	<.0001	0.112	-0.013	-0.016	-0.016	0.001	-0.024
12	269.56	10	<.0001	-0.016	-0.040	-0.012	0.005	0.003	-0.009
18	284.87	16	<.0001	-0.008	-0.019	-0.002	-0.008	-0.017	-0.010
24	297.23	22	<.0001	-0.015	-0.016	-0.002	-0.013	-0.004	-0.008
30	310.53	28	<.0001	-0.008	-0.012	-0.004	-0.003	-0.017	-0.015
36	314.12	34	<.0001	-0.005	-0.011	-0.002	0.001	-0.007	-0.001

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
42	331.68	40	<.0001	0.010	0.015	-0.002	0.006	0.009	0.025
48	722.41	46	<.0001	0.015	0.026	0.039	0.034	0.139	-0.001

O₃ SUF 7

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,1	0.85223	0.0040167	212.17	<.0001	1
AR2,1	0.06547	0.0079116	8.28	<.0001	336

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	68.95	4	<.0001	0.056	-0.017	-0.010	-0.007	-0.020	0.010
12	90.15	10	<.0001	-0.009	0.003	0.004	-0.023	-0.013	-0.021
18	112.25	16	<.0001	-0.015	-0.017	-0.013	-0.022	-0.010	-0.008
24	113.54	22	<.0001	-0.003	-0.005	-0.001	-0.003	-0.005	-0.003
30	119.44	28	<.0001	-0.003	-0.004	-0.007	-0.007	-0.007	-0.013
36	139.46	34	<.0001	-0.014	-0.001	-0.016	-0.006	-0.022	-0.014
42	151.11	40	<.0001	-0.012	0.010	0.011	0.003	-0.011	0.014
48	524.58	46	<.0001	0.007	0.027	0.050	0.062	0.058	0.107

PM₁₀ SUF 1

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
ARI,1	0.89956	0.0033524	268.33	<.0001	1

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	54.36	5	<.0001	0.002	-0.011	0.003	-0.004	0.026	-0.049
12	205.33	11	<.0001	-0.041	-0.074	-0.012	0.001	0.012	0.037
18	334.35	17	<.0001	0.062	0.029	0.003	-0.024	0.044	-0.020
24	511.66	23	<.0001	0.034	0.026	0.048	0.027	0.069	0.028
30	568.66	29	<.0001	0.007	0.046	0.020	0.010	0.021	0.015
36	655.88	35	<.0001	-0.017	-0.011	0.018	0.021	0.048	0.041
42	752.82	41	<.0001	-0.003	0.013	0.013	0.071	0.007	0.018
48	830.19	47	<.0001	0.025	0.034	0.022	0.037	0.025	0.017

PM₁₀ SUF 6

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
ARI,1	0.96595	0.0019854	486.52	<.0001	1

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	1140.30	5	<.0001	0.239	-0.096	-0.023	0.007	0.007	0.005
12	1169.76	11	<.0001	0.012	0.018	0.012	0.010	0.022	0.023
18	2227.17	17	<.0001	0.005	-0.011	-0.125	-0.214	-0.023	0.002
24	2234.04	23	<.0001	-0.005	-0.017	-0.006	-0.006	-0.003	-0.004
30	2237.06	29	<.0001	-0.002	-0.004	-0.010	-0.007	0.002	-0.003
36	2245.18	35	<.0001	-0.012	-0.012	-0.007	-0.005	0.008	0.008
42	2246.51	41	<.0001	0.002	0.003	0.003	0.000	0.004	0.006
48	2274.68	47	<.0001	0.004	0.010	0.028	0.018	0.017	0.009

PM₁₀ SUF 7

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
ARI,1	0.92254	0.0029615	311.52	<.0001	1

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	55.90	5	<.0001	-0.049	0.007	0.018	0.003	0.012	-0.021
12	94.20	11	<.0001	0.018	-0.009	0.009	-0.022	0.029	-0.021
18	98.56	17	<.0001	0.013	0.001	0.008	-0.002	0.004	0.004
24	106.50	23	<.0001	0.007	0.005	-0.007	-0.006	0.002	-0.018
30	110.70	29	<.0001	0.004	-0.001	0.006	0.001	0.011	0.008
36	118.09	35	<.0001	0.001	0.007	0.012	0.007	0.011	0.009
42	138.00	41	<.0001	0.008	-0.003	0.002	-0.003	0.025	0.021
48	608.46	47	<.0001	0.028	0.022	0.042	0.010	0.009	0.156

SO₂ SUF 1

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,1	0.66248	0.0058047	114.13	<.0001	1
AR2,1	0.06041	0.0080015	7.55	<.0001	336

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	516.66	4	<.0001	-0.106	0.024	0.077	0.069	0.054	0.072
12	935.77	10	<.0001	0.074	0.058	0.065	0.065	0.064	0.058
18	1234.20	16	<.0001	0.058	0.054	0.058	0.054	0.052	0.048
24	1561.99	22	<.0001	0.072	0.051	0.072	0.041	0.048	0.048
30	1873.46	28	<.0001	0.051	0.051	0.065	0.057	0.056	0.050
36	2167.65	34	<.0001	0.050	0.055	0.054	0.051	0.054	0.057
42	2537.35	40	<.0001	0.057	0.060	0.052	0.074	0.063	0.053
48	6256.25	46	<.0001	0.060	0.045	0.001	0.032	0.455	-0.067

SO₂ SUF 6

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,1	0.90845	0.0032288	281.36	<.0001	1
AR2,1	0.04529	0.0077486	5.84	<.0001	336

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	163.38	4	<.0001	0.007	-0.097	-0.012	0.003	-0.008	0.001
12	183.92	10	<.0001	0.015	0.019	0.001	0.021	0.014	0.005
18	209.01	16	<.0001	0.011	0.010	0.005	0.013	0.028	0.017
24	249.00	22	<.0001	0.030	0.018	0.018	0.008	0.019	0.020
30	284.13	28	<.0001	0.020	0.024	0.022	0.016	0.012	0.015
36	324.26	34	<.0001	0.020	0.016	0.015	0.012	0.004	0.037
42	386.17	40	<.0001	0.023	-0.006	0.036	0.035	0.017	0.015
48	1015.94	46	<.0001	0.040	0.037	-0.026	0.021	0.180	0.025

SO₂ SUF 7

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,1	0.87975	0.0036629	240.18	<.0001	1
AR2,1	0.12730	0.0077093	16.51	<.0001	48
AR3,1	0.04112	0.0078382	5.25	<.0001	336

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	600.37	3	<.0001	0.148	-0.056	-0.057	-0.075	-0.029	-0.027
12	619.78	9	<.0001	-0.019	0.007	0.013	0.012	0.012	0.017
18	643.82	15	<.0001	0.021	0.026	0.011	-0.001	-0.008	-0.011
24	670.15	21	<.0001	-0.006	0.014	0.026	0.012	0.021	0.006
30	680.35	27	<.0001	0.014	0.008	0.010	0.009	0.013	0.002
36	684.71	33	<.0001	0.008	-0.001	0.013	0.001	-0.002	0.005

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
42	725.75	39	<.0001	0.005	0.009	0.017	0.030	0.018	0.028
48	802.44	45	<.0001	0.003	0.039	0.030	0.025	0.035	-0.013

Lampiran 11. *Output Model ARMA dari Residual Time Series Regression pada Lima Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya*

CO SUF 6

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.01410	0.0077422	1.82	0.0686	29
MA1,2	-0.01540	0.0081622	-1.89	0.0592	42
MA1,3	-0.06373	0.01602	-3.98	<.0001	43
MA1,4	-0.18334	0.01923	-9.54	<.0001	46
MA1,5	0.04671	0.01621	2.88	0.0040	47
AR1,1	0.29668	0.0071919	41.25	<.0001	1
AR1,2	0.32908	0.0076411	43.07	<.0001	2
AR1,3	0.07506	0.0079243	9.47	<.0001	4
AR1,4	0.03697	0.0076635	4.82	<.0001	5
AR1,5	0.07820	0.0080174	9.75	<.0001	6
AR1,6	0.02043	0.0080264	2.54	0.0109	7
AR1,7	0.02858	0.0080324	3.56	0.0004	8
AR1,8	-0.02543	0.0077120	-3.30	0.0010	9
AR1,9	0.03729	0.0079751	4.68	<.0001	10
AR1,10	0.03490	0.0074800	4.67	<.0001	12
AR1,11	0.02368	0.0070810	3.34	0.0008	15
AR1,12	-0.02136	0.0070711	-3.02	0.0025	18
AR1,13	0.01525	0.0072107	2.12	0.0344	19
AR1,14	-0.01691	0.0067990	-2.49	0.0129	23
AR1,15	0.01563	0.0069500	2.25	0.0245	34
AR1,16	-0.02811	0.0071355	-3.94	<.0001	35
AR1,17	0.03873	0.0073102	5.30	<.0001	39

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,18	-0.01370	0.0075956	-1.80	0.0712	40
AR1,19	-0.03261	0.01472	-2.21	0.0268	43
AR1,20	-0.20311	0.01798	-11.30	<.0001	46
AR1,21	0.26201	0.01954	13.41	<.0001	47
AR2,1	-0.01418	0.0078757	-1.80	0.0719	336

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	-0.002	-0.001	0.009	-0.000	0.003	-0.012
12	.	0	.	0.010	-0.008	0.010	-0.007	-0.002	0.002
18	.	0	.	0.004	-0.009	-0.002	0.000	0.008	-0.006
24	.	0	.	0.006	-0.008	0.011	-0.005	-0.005	-0.004
30	20.27	3	0.0001	0.001	-0.006	0.008	0.001	-0.003	0.004
36	29.92	9	0.0005	-0.016	0.008	-0.014	-0.003	-0.001	-0.005
42	31.47	15	0.0076	-0.004	-0.002	-0.004	-0.004	-0.004	-0.004
48	34.97	21	0.0284	0.006	-0.008	0.009	0.001	-0.004	0.001

CO SUF 7

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	-0.03418	0.0077927	-4.39	<.0001	7
MA1,2	0.01768	0.0080651	2.19	0.0284	24
MA1,3	0.02350	0.0077336	3.04	0.0024	37
MA1,4	0.01451	0.0077164	1.88	0.0600	41
MA1,5	-0.03253	0.0094590	-3.44	0.0006	47
AR1,1	0.81237	0.0046196	175.85	<.0001	1

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,2	0.03031	0.0044987	6.74	<.0001	9
AR1,3	0.02354	0.0059765	3.94	<.0001	19
AR1,4	0.02338	0.0062502	3.74	0.0002	21
AR1,5	0.03696	0.0077396	4.78	<.0001	28
AR1,6	-0.03681	0.0076566	-4.81	<.0001	29
AR1,7	0.02912	0.0059422	4.90	<.0001	45
AR1,8	0.04162	0.0073065	5.70	<.0001	47
AR2,1	0.07291	0.0088526	8.24	<.0001	48
AR3,1	0.06044	0.0077236	7.83	<.0001	336

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	-0.013	0.005	0.011	-0.005	0.010	0.012
12	.	0	.	0.000	0.011	-0.001	0.006	0.009	-0.004
18	17.85	3	0.0005	-0.003	0.005	-0.007	0.009	-0.001	0.006
24	18.65	9	0.0283	-0.004	0.002	-0.004	-0.003	-0.002	0.001
30	26.24	15	0.0356	0.009	-0.014	0.004	0.001	0.001	0.012
36	31.26	21	0.0694	-0.008	0.006	-0.006	-0.010	-0.006	0.004
42	33.77	27	0.1728	0.001	0.002	0.007	-0.008	-0.001	-0.005
48	36.89	33	0.2936	-0.006	0.001	-0.004	-0.010	-0.000	-0.006

NO₂ SUF 1

Parameter	Estimate	Standard Error	t Value	Approx Pr > t 	Lag
MA1,1	-0.01934	0.0081579	-2.37	0.0177	6
MA1,2	-0.0078918	0.0078499	-1.01	0.3147	7
MA1,3	-0.03004	0.0079659	-3.77	0.0002	12
MA1,4	-0.02634	0.0076079	-3.46	0.0005	14
MA1,5	-0.01632	0.0074580	-2.19	0.0287	16
MA1,6	-0.02303	0.0074171	-3.11	0.0019	18
MA1,7	-0.02444	0.0086071	-2.84	0.0045	23
MA1,8	-0.02512	0.0080797	-3.11	0.0019	25
MA1,9	-0.02325	0.0076504	-3.04	0.0024	27
MA1,10	-0.01727	0.0074192	-2.33	0.0199	32
MA1,11	-0.01951	0.0074929	-2.60	0.0092	39
MA1,12	0.19656	0.01976	9.95	<.0001	45
MA1,13	0.19482	0.01761	11.06	<.0001	46
MA1,14	-0.02369	0.0095406	-2.48	0.0130	47
AR1,1	0.85364	0.0076586	111.46	<.0001	1
AR1,2	-0.08964	0.0084883	-10.56	<.0001	2
AR1,3	0.01040	0.0063081	1.65	0.0992	4
AR1,4	0.02936	0.0074670	3.93	<.0001	9
AR1,5	-0.02032	0.0075244	-2.70	0.0069	10
AR1,6	0.01824	0.0052105	3.50	0.0005	21
AR1,7	-0.02418	0.0060280	-4.01	<.0001	23
AR1,8	0.01420	0.0038164	3.72	0.0002	34
AR1,9	0.22747	0.01826	12.46	<.0001	45
AR1,10	-0.03830	0.01665	-2.30	0.0214	47
AR2,1	-0.05298	0.01000	-5.30	<.0001	48

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	-0.001	-0.004	0.004	0.012	0.001	0.009
12	.	0	.	0.009	0.009	0.005	0.010	-0.005	0.002
18	.	0	.	0.015	0.002	0.000	0.001	0.015	0.000
24	.	0	.	0.010	0.002	0.005	0.001	0.002	0.002
30	26.58	5	<.0001	-0.001	0.011	0.002	0.015	0.008	0.001
36	32.94	11	0.0005	0.012	-0.000	0.010	0.010	-0.003	0.004
42	42.12	17	0.0006	0.012	0.005	-0.003	-0.014	0.012	-0.004
48	46.55	23	0.0026	0.006	0.006	-0.003	0.006	0.012	0.002

NO₂ SUF 6

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	-0.02212	0.0079568	-2.78	0.0054	7
MA1,2	-0.02556	0.0078710	-3.25	0.0012	8
MA1,3	-0.01907	0.0077728	-2.45	0.0142	10
MA1,4	-0.01679	0.0077331	-2.17	0.0299	11
MA1,5	-0.01635	0.0077125	-2.12	0.0341	12
MA1,6	0.01850	0.0076799	2.41	0.0160	17
MA1,7	0.03720	0.01038	3.58	0.0003	45
MA1,8	0.03093	0.0095290	3.25	0.0012	46
MA1,9	-0.03671	0.0089815	-4.09	<.0001	47
AR1,1	0.98603	0.0076743	128.48	<.0001	1
AR1,2	-0.18321	0.01069	-17.14	<.0001	2
AR1,3	0.04131	0.0077914	5.30	<.0001	3

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,4	0.01142	0.0038213	2.99	0.0028	33
AR1,5	0.01173	0.0043346	2.71	0.0068	39
AR1,6	0.04300	0.0074573	5.77	<.0001	44
AR1,7	0.04157	0.0070029	5.94	<.0001	47
AR2,1	-0.03949	0.0090176	-4.38	<.0001	48

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	-0.000	0.002	-0.004	0.006	0.007	0.008
12	.	0	.	0.000	-0.000	0.005	0.000	0.000	0.000
18	8.45	1	0.0036	0.011	-0.009	0.001	-0.007	0.000	-0.007
24	12.64	7	0.0814	0.003	0.008	-0.002	0.005	0.012	0.003
30	14.69	13	0.3273	0.006	0.002	-0.005	0.008	0.000	-0.000
36	17.12	19	0.5820	0.007	0.004	0.008	-0.002	-0.001	0.001
42	19.92	25	0.7508	-0.005	0.010	-0.001	0.001	-0.000	-0.006
48	22.35	31	0.8716	-0.001	-0.012	-0.001	-0.000	0.002	0.001

NO₂ SUF 7

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.02885	0.01072	2.69	0.0071	3
MA1,2	0.03035	0.01048	2.89	0.0038	6
MA1,3	0.02265	0.0096008	2.36	0.0183	7
MA1,4	0.07193	0.01199	6.00	<.0001	34
MA1,5	0.07353	0.01071	6.86	<.0001	35
MA1,6	0.05623	0.0094962	5.92	<.0001	36

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,7	0.03099	0.0087485	3.54	0.0004	37
MA1,8	0.02137	0.0078593	2.72	0.0066	43
MA1,9	0.02415	0.01086	2.22	0.0262	46
MA1,10	0.02717	0.0097827	2.78	0.0055	47
AR1,1	0.80694	0.0076837	105.02	<.0001	1
AR1,2	-0.04502	0.0098693	-4.56	<.0001	2
AR1,3	0.02727	0.0095406	2.86	0.0043	3
AR1,4	0.05500	0.0084545	6.51	<.0001	6
AR1,5	0.02141	0.0045632	4.69	<.0001	20
AR1,6	0.08097	0.0093144	8.69	<.0001	34
AR1,7	0.03707	0.0087636	4.23	<.0001	46
AR2,1	0.13618	0.0088076	15.46	<.0001	48
AR3,1	0.08970	0.0078801	11.38	<.0001	336

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	0.001	0.002	0.002	0.010	-0.010	0.002
12	.	0	.	0.002	-0.002	-0.005	-0.001	0.010	0.004
18	.	0	.	-0.010	0.007	0.004	-0.008	0.005	0.000
24	12.54	5	0.0281	-0.002	0.002	0.001	-0.004	0.005	-0.009
30	15.95	11	0.1432	-0.004	0.006	0.002	0.012	0.000	0.000
36	20.36	17	0.2560	0.007	-0.004	-0.013	0.002	0.002	0.002
42	24.42	23	0.3806	0.002	-0.008	-0.008	-0.009	-0.004	0.001
48	29.07	29	0.4613	0.003	-0.008	-0.004	0.002	0.001	-0.013

O₃ SUF 1

Parameter	Estimate	Standard Error	t Value	Approx Pr > t 	Lag
MA1,1	0.13953	0.0075608	18.45	<.0001	1
MA1,2	0.14150	0.0074106	19.09	<.0001	2
MA1,3	0.04911	0.0074763	6.57	<.0001	3
MA1,4	0.06295	0.0074610	8.44	<.0001	4
MA1,5	0.03046	0.0074508	4.09	<.0001	5
MA1,6	0.01145	0.0074493	1.54	0.1243	6
MA1,7	0.03402	0.0074048	4.59	<.0001	7
MA1,8	0.03431	0.0073472	4.67	<.0001	8
MA1,9	0.01188	0.0072174	1.65	0.0998	11
MA1,10	0.01546	0.0071483	2.16	0.0305	13
MA1,11	0.02037	0.0071385	2.85	0.0043	20
MA1,12	0.01137	0.0072707	1.56	0.1180	22
MA1,13	0.01654	0.0071796	2.30	0.0213	23
MA1,14	0.03093	0.0071079	4.35	<.0001	26
MA1,15	0.01681	0.0070803	2.37	0.0176	30
MA1,16	-0.01445	0.0071596	-2.02	0.0436	35
MA1,17	-0.01262	0.0072907	-1.73	0.0835	37
MA1,18	-0.01752	0.0072895	-2.40	0.0162	38
MA1,19	-0.01439	0.0072540	-1.98	0.0474	40
MA1,20	-0.01070	0.0073238	-1.46	0.1439	43
MA1,21	-0.01382	0.0073322	-1.89	0.0594	44
MA1,22	0.04254	0.0073774	5.77	<.0001	45
MA1,23	-0.31947	0.0072684	-43.95	<.0001	47
AR1,1	0.98304	0.0017439	563.70	<.0001	1

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR2,1	-0.06350	0.0079917	-7.95	<.0001	48
AR3,1	0.03944	0.0079281	4.97	<.0001	336

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	-0.002	-0.011	-0.003	0.006	-0.005	-0.007
12	.	0	.	-0.005	-0.006	-0.012	-0.015	-0.007	-0.014
18	.	0	.	-0.003	-0.010	-0.014	-0.010	-0.008	-0.006
24	.	0	.	-0.013	-0.003	-0.009	-0.007	-0.007	-0.010
30	34.75	4	<.0001	-0.003	-0.003	-0.000	-0.003	-0.009	-0.001
36	36.53	10	<.0001	-0.007	0.001	-0.002	0.004	-0.002	0.006
42	39.53	16	0.0009	-0.001	-0.002	0.005	0.003	0.003	0.011
48	176.23	22	<.0001	0.011	0.004	0.006	0.023	0.086	0.002

O₃ SUF 6

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	-0.05163	0.05917	-0.87	0.3829	1
MA1,2	0.08804	0.05853	1.50	0.1326	2
MA1,3	-0.02120	0.0096049	-2.21	0.0273	5
MA1,4	-0.02382	0.0080607	-2.96	0.0031	10
MA1,5	-0.02117	0.0079612	-2.66	0.0078	11
MA1,6	-0.01575	0.0076372	-2.06	0.0392	37
MA1,7	-0.06869	0.01072	-6.41	<.0001	47
AR1,1	0.95783	0.05840	16.40	<.0001	1

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,2	-0.07883	0.04793	-1.64	0.1000	3
AR1,3	-0.01169	0.0064057	-1.82	0.0681	6
AR1,4	0.01216	0.0041169	2.95	0.0032	38
AR1,5	0.02419	0.0049800	4.86	<.0001	42
AR1,6	0.04781	0.0090395	5.29	<.0001	47
AR2,1	-0.06118	0.0086212	-7.10	<.0001	48

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	0.001	0.000	-0.001	0.005	-0.001	0.006
12	.	0	.	0.014	-0.013	0.010	-0.000	-0.000	0.005
18	14.03	4	0.0072	0.006	-0.006	0.012	0.003	-0.005	0.004
24	18.35	10	0.0493	-0.003	-0.007	0.011	-0.007	0.005	-0.001
30	22.45	16	0.1292	0.003	-0.009	0.005	0.005	-0.009	-0.004
36	26.14	22	0.2458	0.005	-0.004	0.007	0.010	0.001	0.005
42	29.23	28	0.4011	-0.000	0.010	-0.006	-0.000	0.005	-0.006
48	36.21	34	0.3659	-0.012	-0.006	0.015	-0.002	0.003	0.001

O₃ SUF 7

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	-0.01962	0.0079632	-2.46	0.0138	6
MA1,2	-0.01634	0.0076957	-2.12	0.0338	38
MA1,3	0.02987	0.0096444	3.10	0.0020	47
AR1,1	0.88169	0.0076601	115.10	<.0001	1
AR1,2	-0.06635	0.0077753	-8.53	<.0001	2
AR1,3	-0.01678	0.0040712	-4.12	<.0001	10
AR1,4	0.01453	0.0056178	2.59	0.0097	42
AR1,5	0.01707	0.0087057	1.96	0.0499	44
AR1,6	0.02445	0.01028	2.38	0.0174	45
AR1,7	0.02032	0.01029	1.98	0.0483	46
AR1,8	0.02826	0.0087522	3.23	0.0012	47
AR2,1	0.03470	0.0092347	3.76	0.0002	48
AR3,1	0.04571	0.0079173	5.77	<.0001	336

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	0.001	-0.004	0.006	0.007	-0.010	0.000
12	.	0	.	-0.002	0.011	0.011	0.000	0.012	-0.001
18	12.25	5	0.0315	0.003	-0.002	0.001	-0.010	0.001	0.002
24	13.37	11	0.2695	0.005	0.002	0.006	0.002	-0.000	0.001
30	14.58	17	0.6255	0.001	-0.001	-0.003	-0.003	-0.002	-0.007
36	20.79	23	0.5938	-0.008	0.008	-0.008	0.004	-0.012	-0.003
42	26.72	29	0.5869	-0.005	-0.000	0.015	0.006	-0.008	0.003
48	27.71	35	0.8047	-0.004	-0.002	-0.003	-0.005	-0.000	-0.002

PM₁₀ SUF 1

Parameter	Estimate	Standard Error	t Value	Approx Pr > t 	Lag
MA1,1	0.05241	0.0084396	6.21	<.0001	8
MA1,2	-0.02731	0.0080301	-3.40	0.0007	11
MA1,3	0.04725	0.0086749	5.45	<.0001	37
MA1,4	0.04027	0.0084376	4.77	<.0001	38
MA1,5	0.03096	0.0082603	3.75	0.0002	39
MA1,6	0.04427	0.01031	4.30	<.0001	40
MA1,7	0.09422	0.0096317	9.78	<.0001	41
MA1,8	0.06237	0.0091412	6.82	<.0001	42
MA1,9	0.04336	0.0087933	4.93	<.0001	43
MA1,10	0.02886	0.0085280	3.38	0.0007	44
MA1,11	0.03876	0.0084844	4.57	<.0001	45
AR1,1	0.86087	0.0046512	185.09	<.0001	1
AR1,2	0.03228	0.0080700	4.00	<.0001	5
AR1,3	-0.08196	0.0081960	-10.00	<.0001	6
AR1,4	0.04426	0.0078493	5.64	<.0001	12
AR1,5	0.03036	0.01011	3.00	0.0027	13
AR1,6	-0.04421	0.0087357	-5.06	<.0001	14
AR1,7	-0.04280	0.0087472	-4.89	<.0001	16
AR1,8	0.06434	0.01012	6.35	<.0001	17
AR1,9	-0.05668	0.01014	-5.59	<.0001	18
AR1,10	0.06136	0.0087845	6.98	<.0001	19
AR1,11	0.02395	0.0087578	2.73	0.0063	21
AR1,12	-0.02772	0.01016	-2.73	0.0064	22
AR1,13	0.04320	0.01015	4.26	<.0001	23
AR1,14	-0.04501	0.0087838	-5.12	<.0001	24

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,15	0.02601	0.0061808	4.21	<.0001	26
AR1,16	-0.02940	0.0061614	-4.77	<.0001	31
AR1,17	0.02558	0.0072119	3.55	0.0004	33
AR1,18	0.03745	0.0069949	5.35	<.0001	35
AR1,19	0.06899	0.0081761	8.44	<.0001	40
AR2,1	-0.02418	0.0077866	-3.11	0.0019	48

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	0.005	-0.011	0.012	-0.003	0.002	-0.001
12	.	0	.	-0.003	0.005	0.009	0.013	0.007	0.005
18	.	0	.	0.004	0.014	-0.009	0.001	-0.001	-0.002
24	.	0	.	0.000	-0.002	-0.003	-0.003	-0.001	0.007
30	.	0	.	-0.012	0.006	-0.008	-0.011	0.009	-0.002
36	29.39	5	<.0001	-0.003	-0.006	-0.001	-0.004	-0.006	-0.011
42	30.10	11	0.0015	0.001	0.003	0.002	0.002	0.004	0.003
48	35.54	17	0.0053	-0.001	0.002	0.001	-0.010	-0.015	-0.000

PM₁₀ SUF 6

Parameter	Estimate	Standard Error	t Value	Approx Pr > t 	Lag
MA1,1	-0.03790	0.0083130	-4.56	<.0001	3
MA1,2	0.02358	0.0082182	2.87	0.0041	4
MA1,3	-0.02174	0.0085379	-2.55	0.0109	12
MA1,4	0.25222	0.02091	12.06	<.0001	16
MA1,5	0.03881	0.0083294	4.66	<.0001	18
MA1,6	0.02154	0.0078187	2.75	0.0059	31
AR1,1	1.23741	0.0076670	161.39	<.0001	1
AR1,2	-0.44770	0.01215	-36.85	<.0001	2
AR1,3	0.19148	0.0081764	23.42	<.0001	3
AR1,4	-0.01676	0.0050359	-3.33	0.0009	12
AR1,5	-0.07246	0.0089025	-8.14	<.0001	15
AR1,6	0.12305	0.02161	5.69	<.0001	16
AR1,7	-0.04385	0.02040	-2.15	0.0316	17
AR1,8	0.02188	0.0073847	2.96	0.0030	45
AR1,9	-0.01254	0.0073445	-1.71	0.0877	46
AR2,1	-0.02413	0.0077451	-3.12	0.0018	336

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	0.000	-0.001	-0.000	0.003	-0.011	-0.008
12	.	0	.	0.002	0.009	0.001	-0.002	0.007	0.003
18	6.31	2	0.0426	0.001	-0.005	-0.001	0.001	-0.002	0.002
24	9.68	8	0.2881	-0.002	-0.012	-0.000	-0.006	0.004	0.000
30	14.40	14	0.4201	0.003	0.002	-0.003	-0.011	0.004	-0.011
36	16.51	20	0.6847	-0.001	-0.001	-0.002	-0.008	0.006	0.003
42	18.66	26	0.8503	-0.000	0.002	0.005	0.001	0.006	0.007
48	22.36	32	0.8974	0.004	0.004	0.004	-0.010	0.007	-0.005

PM₁₀ SUF 7

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.05223	0.0091381	5.72	<.0001	1
MA1,2	0.02154	0.0077608	2.78	0.0055	24
MA1,3	-0.01645	0.0080221	-2.05	0.0403	45
AR1,1	0.92001	0.0047535	193.54	<.0001	1
AR1,2	-0.03105	0.0082807	-3.75	0.0002	6
AR1,3	0.02870	0.0085364	3.36	0.0008	7
AR1,4	-0.02758	0.0085306	-3.23	0.0012	10
AR1,5	0.04876	0.01041	4.68	<.0001	11
AR1,6	-0.04731	0.01041	-4.54	<.0001	12
AR1,7	0.02611	0.0076834	3.40	0.0007	13
AR1,8	0.02943	0.0032939	8.93	<.0001	41
AR2,1	0.12741	0.0078433	16.24	<.0001	48
AR3,1	0.05355	0.0077335	6.92	<.0001	336

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	-0.000	-0.003	0.006	-0.008	0.003	-0.001
12	.	0	.	0.008	-0.013	0.001	-0.002	-0.001	-0.002
18	10.97	5	0.0519	0.006	-0.010	0.000	-0.011	0.004	-0.004
24	16.63	11	0.1194	0.002	0.000	-0.010	-0.015	-0.001	0.000
30	19.24	17	0.3152	0.002	-0.005	0.004	-0.004	0.008	0.005
36	24.86	23	0.3578	0.001	0.003	0.010	0.004	0.012	0.008
42	26.96	29	0.5738	0.003	-0.002	-0.001	-0.004	-0.008	-0.005
48	34.07	35	0.5126	-0.003	-0.006	0.001	-0.014	-0.004	-0.013

SO₂ SUF 1

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	-0.48858	0.0076018	-64.27	<.0001	1
MA1,2	-0.31807	0.0084230	-37.76	<.0001	2
MA1,3	-0.20137	0.01396	-14.42	<.0001	3
MA1,4	-0.15119	0.01056	-14.32	<.0001	4
MA1,5	-0.11175	0.0096277	-11.61	<.0001	5
MA1,6	-0.02737	0.0074814	-3.66	0.0003	7
MA1,7	-0.03232	0.0082227	-3.93	<.0001	8
MA1,8	-0.03123	0.0085663	-3.65	0.0003	9
MA1,9	-0.03571	0.0086547	-4.13	<.0001	10
MA1,10	-0.03845	0.0086818	-4.43	<.0001	11
MA1,11	-0.03644	0.0086788	-4.20	<.0001	12
MA1,12	-0.03574	0.0086888	-4.11	<.0001	13

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,13	0.02232	0.0074700	2.99	0.0028	45
MA1,14	0.17462	0.01601	10.91	<.0001	46
MA1,15	0.24839	0.01206	20.59	<.0001	47
AR1,1	0.04118	0.01148	3.59	0.0003	3
AR1,2	0.08149	0.0076671	10.63	<.0001	6
AR1,3	0.02275	0.0071898	3.16	0.0016	14
AR1,4	0.0093000	0.0061865	1.50	0.1328	15
AR1,5	0.02645	0.0060662	4.36	<.0001	19
AR1,6	0.02264	0.0061806	3.66	0.0002	21
AR1,7	0.01358	0.0061182	2.22	0.0265	27
AR1,8	0.01296	0.0061522	2.11	0.0352	40
AR1,9	-0.01802	0.0061404	-2.93	0.0033	44
AR1,10	0.17254	0.01336	12.92	<.0001	46
AR1,11	0.55259	0.01260	43.86	<.0001	47
AR2,1	-0.18744	0.0097665	-19.19	<.0001	48

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	-0.001	0.001	0.012	0.007	-0.002	0.006
12	.	0	.	0.004	0.002	-0.000	-0.002	-0.003	-0.001
18	.	0	.	0.002	0.006	0.007	0.011	0.008	-0.002
24	.	0	.	-0.007	0.007	0.008	0.001	0.004	-0.001
30	19.15	3	0.0003	0.008	-0.001	0.008	0.006	0.014	0.004
36	21.62	9	0.0102	0.006	0.007	0.005	0.001	0.004	0.003

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
42	29.04	15	0.0159	0.004	0.007	0.011	0.003	0.012	0.009
48	31.75	21	0.0621	0.004	-0.002	-0.003	0.005	-0.010	-0.002

SO₂ SUF 6

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	-0.04906	0.0095546	-5.13	<.0001	3
MA1,2	-0.04959	0.0088507	-5.60	<.0001	4
MA1,3	-0.03274	0.0081874	-4.00	<.0001	5
MA1,4	-0.03043	0.0079337	-3.84	0.0001	6
MA1,5	0.02163	0.0081283	2.66	0.0078	38
MA1,6	0.33163	0.03562	9.31	<.0001	46
MA1,7	-0.02467	0.0089933	-2.74	0.0061	47
AR1,1	0.88096	0.0076515	115.13	<.0001	1
AR1,2	-0.10642	0.0099095	-10.74	<.0001	2
AR1,3	0.03154	0.0050183	6.29	<.0001	7
AR1,4	0.0095558	0.0036121	2.65	0.0082	17
AR1,5	0.01245	0.0050620	2.46	0.0139	36
AR1,6	0.01330	0.0051766	2.57	0.0102	39
AR1,7	0.01596	0.0055712	2.87	0.0042	43
AR1,8	-0.03776	0.0081860	-4.61	<.0001	45
AR1,9	0.35492	0.03629	9.78	<.0001	46
AR1,10	-0.18432	0.03268	-5.64	<.0001	47
AR2,1	-0.04602	0.0099761	-4.61	<.0001	48

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	-0.006	0.002	0.013	0.006	0.006	0.008
12	.	0	.	0.004	0.011	-0.001	0.012	0.005	0.000
18	.	0	.	0.003	0.004	-0.002	0.004	0.010	0.000
24	18.34	6	0.0054	0.013	-0.001	0.005	-0.005	0.004	0.006
30	21.99	12	0.0377	0.008	0.009	0.007	0.004	0.001	-0.000
36	25.73	18	0.1062	0.006	0.004	0.003	0.002	-0.004	0.012
42	27.19	24	0.2958	-0.001	-0.000	0.007	0.005	-0.003	-0.002
48	32.95	30	0.3246	0.004	0.007	0.001	0.007	0.015	0.000

SO₂ SUF 7

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
MA1,1	0.02611	0.0089326	2.92	0.0035	7
MA1,2	-0.01958	0.0077580	-2.52	0.0116	14
MA1,3	0.01765	0.0079808	2.21	0.0271	43
AR1,1	1.02026	0.0076749	132.93	<.0001	1
AR1,2	-0.21564	0.01097	-19.66	<.0001	2
AR1,3	0.04040	0.01109	3.64	0.0003	3
AR1,4	-0.04024	0.01109	-3.63	0.0003	4
AR1,5	0.04534	0.01109	4.09	<.0001	5
AR1,6	-0.02030	0.01109	-1.83	0.0672	6
AR1,7	0.03117	0.0077288	4.03	<.0001	7
AR1,8	0.01335	0.0036798	3.63	0.0003	21
AR1,9	0.02496	0.0041885	5.96	<.0001	39
AR1,10	0.02411	0.0048722	4.95	<.0001	44

Parameter	Estimate	Standard Error	t Value	Approx Pr > t	Lag
AR1,11	0.02399	0.0051917	4.62	<.0001	47
AR2,1	0.07731	0.0088384	8.75	<.0001	48
AR3,1	0.03199	0.0078423	4.08	<.0001	336

Autocorrelation Check of Residuals									
To Lag	Chi-Square	DF	Pr > ChiSq	Autocorrelations					
6	.	0	.	-0.000	-0.001	-0.001	-0.002	-0.001	-0.001
12	.	0	.	0.000	-0.008	-0.001	0.001	0.003	0.009
18	7.30	2	0.0260	0.011	-0.000	0.006	-0.001	-0.005	-0.009
24	15.56	8	0.0491	-0.006	0.010	0.009	-0.010	0.008	-0.010
30	19.26	14	0.1551	0.007	-0.003	0.006	-0.001	0.007	-0.008
36	23.59	20	0.2608	0.003	-0.010	0.009	-0.005	-0.007	0.001
42	32.73	26	0.1699	0.002	0.005	-0.014	0.003	-0.011	0.013
48	38.76	32	0.1911	0.000	0.004	-0.010	-0.011	-0.009	-0.007

Lampiran 12. Perbandingan *Neuron Optimum* pada Model Hibrida *Time Series Regression* dan FFNN


Variabel	Neuron	RMSE	RMSEP	sMAPE	sMAPEP
CO SUF 1	1	0.1868	0.2770	16.7604	14.4563
	2	0.1830	0.2623	16.7116	13.6774
	3	0.1825	0.2640	16.7437	13.5827
	4	0.1823	0.2601	16.7924	13.5294
	5	0.1786	0.2625	16.7509	14.0196
CO SUF 6	1	0.5585	0.5125	45.5245	13.7532
	2	0.5530	0.4883	43.7638	13.3264
	3	0.5352	0.5337	44.6337	14.9453
	4	0.5255	0.4685	45.2418	12.5800
	5	0.5270	0.5979	43.7309	16.1400
CO SUF 7	1	0.4078	0.0963	42.8775	200.0000
	2	0.4078	0.0910	42.9001	200.0000
	3	0.4021	0.0942	43.0780	200.0000
	4	0.4020	0.0959	43.1302	200.0000
	5	0.3991	0.0940	42.9864	200.0000
NO ₂ SUF 1	1	6.4129	4.5816	22.0063	44.7963
	2	6.2488	4.7016	21.9171	44.8998
	3	6.3382	4.5246	21.9462	43.9457
	4	6.2152	4.6640	21.9206	44.4167
	5	6.2142	4.6333	21.9379	43.9020
NO ₂ SUF 6	1	5.3850	7.1816	37.6287	28.8639
	2	5.3114	6.6669	37.5000	26.6254
	3	5.3069	6.6617	37.4648	26.9341
	4	5.3065	6.6856	37.5294	27.1311
	5	5.3015	6.6320	37.2937	26.9893

Variabel	Neuron	RMSE	RMSEP	sMAPE	sMAPEP
NO ₂ SUF 7	1	7.6029	7.3055	14.9552	14.6151
	2	7.5552	7.0072	15.0749	13.6216
	3	7.5261	7.2916	14.9190	14.8754
	4	7.4520	6.9437	14.9410	13.3266
	5	7.4316	8.1657	14.8463	15.4154
O ₃ SUF 1	1	7.6233	5.7720	12.3694	74.7546
	2	7.3546	5.3121	12.2820	74.5646
	3	7.4856	5.5968	12.2900	74.4613
	4	7.1884	4.4537	12.0530	62.8879
	5	26.9204	33.7080	43.4046	161.2937
O ₃ SUF 6	1	5.0327	6.1641	15.5909	38.5325
	2	5.0095	6.1639	15.6611	37.4199
	3	5.0220	6.1017	15.6009	36.5568
	4	5.0035	6.0848	15.8536	37.2700
	5	5.0286	6.1281	15.5487	37.6279
O ₃ SUF 7	1	5.8592	2.5946	18.3732	17.1470
	2	5.7552	2.5590	18.2221	17.5478
	3	5.7182	2.5477	18.2576	17.4692
	4	5.7135	2.5477	18.2504	16.9119
	5	5.7181	2.5374	18.2387	16.9092
PM ₁₀ SUF 1	1	11.3308	2.9684	19.9326	10.2851
	2	11.2024	2.9493	20.0163	9.8308
	3	11.1534	2.9220	20.0863	9.8722
	4	11.1553	2.9258	20.0645	9.9149
	5	11.0816	2.9428	20.0598	9.8880
PM ₁₀ SUF 6	1	3.2254	0.4258	12.8258	3.1072
	2	2.7461	0.4054	12.4859	2.8622
	3	2.6434	0.3955	12.2632	2.7270


Variabel	Neuron	RMSE	RMSEP	sMAPE	sMAPEP
	4	2.6141	0.4271	12.1694	3.1576
	5	3.2385	0.4315	12.3673	3.1634
PM ₁₀ SUF 7	1	14.2428	3.9137	11.7286	11.8720
	2	14.2361	3.6064	11.8380	11.1378
	3	14.1220	0.6576	11.5246	1.8149
	4	14.1418	0.3517	11.4275	1.0460
	5	14.1526	0.2071	11.6841	0.7413
SO ₂ SUF 1	1	14.5358	7.7634	31.3795	65.3210
	2	13.8503	6.5903	31.3564	56.4923
	3	13.7277	6.3436	31.9041	54.8982
	4	13.7867	7.0465	31.9173	58.2175
	5	13.8102	6.4785	31.7937	55.6806
SO ₂ SUF 6	1	5.2567	2.9954	17.1397	20.7485
	2	5.1278	3.0701	16.6259	20.9296
	3	5.0719	3.0506	16.7240	20.1832
	4	5.0397	2.9954	16.5052	19.9215
	5	4.9555	3.0078	16.3546	20.6503
SO ₂ SUF 7	1	3.0065	1.8603	9.3229	8.7367
	2	2.9640	1.8153	9.2342	8.5547
	3	2.9589	1.7871	9.2409	8.6809
	4	2.9461	1.7978	9.2762	8.5227
	5	3.0147	1.8699	9.4355	8.5753

Lampiran 13. Arsitektur FFNN dari Model Hibrida *Time Series Regression* dan FFNN pada Lima Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya

CO SUF 6




CO SUF 7




Error: 9.259834 Steps: 2627

NO₂ SUF 1




Error: 12.787952 Steps: 126630

NO₂ SUF 6




Error: 15.869457 Steps: 175922

NO₂ SUF 7




Error: 14.326819 Steps: 71530

O₃ SUF 1




Error: 13.172527 Steps: 438071

O₃ SUF 6




Error: 11.057921 Steps: 8972

O₃ SUF 7




Error: 4.118284 Steps: 11119


PM₁₀ SUF 1



PM₁₀ SUF 6




PM₁₀ SUF 7




Error: 8.684139 Steps: 14812

SO₂ SUF 1




Error: 9.685508 Steps: 525808

SO₂ SUF 6



SO₂ SUF 7



Error: 8.594873 Steps: 87149

Lampiran 14. Perbandingan *Neuron* Optimum pada Model Hibrida *Time Series Regression* dan LSTM

Variabel	Neuron	RMSE	RMSEP	sMAPE	sMAPEP
CO SUF 1	1	0.1870	0.2847	16.9426	14.5522
	2	0.1922	0.2584	19.5148	15.0229
	3	0.1861	0.2733	17.2227	14.5607
	4	0.1874	0.2670	17.2488	14.9304
	5	0.1862	0.2674	17.2597	14.4926
CO SUF 6	1	0.6063	0.4003	52.1072	10.4308
	2	0.5633	0.4331	47.9369	10.8773
	3	0.5549	0.4686	46.2698	12.3384
	4	0.5565	0.4545	44.7318	11.7911
	5	0.5583	0.4470	47.2490	11.4973
CO SUF 7	1	0.4113	0.0884	42.4306	200.0000
	2	0.4166	0.0584	40.6829	200.0000
	3	0.4354	0.0059	39.9924	200.0000
	4	0.4107	0.1451	48.6856	200.0000
	5	0.4155	0.1448	49.4579	200.0000
NO ₂ SUF 1	1	6.4119	4.6189	22.1412	45.1244
	2	6.5233	4.3877	24.0164	47.2477
	3	6.4563	4.4183	22.9500	43.9924
	4	6.6802	4.4219	25.2822	46.5628
	5	6.3991	4.5690	22.0596	45.3175
NO ₂ SUF 6	1	5.4188	7.3617	37.2772	28.9898
	2	5.5832	7.9119	40.0156	31.5015
	3	5.3927	7.1489	37.0003	27.7578
	4	5.3897	7.2359	37.2996	28.4307
	5	5.4129	7.3414	36.3889	29.7774

Variabel	Neuron	RMSE	RMSEP	sMAPE	sMAPEP
NO ₂ SUF 7	1	7.7581	7.5793	17.0327	15.7987
	2	7.7370	6.9874	16.7045	13.8811
	3	8.0412	7.1925	18.6245	14.0729
	4	7.8915	7.0679	19.9380	14.0364
	5	7.6383	7.1882	15.1009	14.2449
O ₃ SUF 1	1	7.7285	4.1278	14.2884	63.6623
	2	7.6880	4.7114	13.4359	71.9764
	3	7.5649	5.7371	12.8884	77.0838
	4	7.5506	5.4385	12.3558	76.0865
	5	7.5913	4.8989	12.2006	65.5308
O ₃ SUF 6	1	5.0518	5.9624	16.5294	39.1539
	2	5.0990	5.8968	16.7259	35.9954
	3	5.0594	5.8910	16.8930	38.5245
	4	5.3419	6.9076	20.4236	36.4109
	5	5.0792	6.3202	16.3995	36.3275
O ₃ SUF 7	1	5.9282	2.8861	20.0874	20.5904
	2	5.8817	2.5459	18.2784	17.5888
	3	5.9005	2.4455	18.0847	16.1432
	4	6.0025	2.2462	21.1920	15.0178
	5	6.0025	2.2463	21.1898	15.0127
PM ₁₀ SUF 1	1	11.3165	2.9417	20.3820	10.0112
	2	11.3254	2.9560	20.4804	10.1452
	3	11.4391	3.2035	22.3377	11.8579
	4	11.3599	2.8908	22.4253	9.5777
	5	11.8175	5.0215	31.5044	17.1590
PM ₁₀ SUF 6	1	3.5322	1.3966	20.3430	12.0856
	2	3.4929	0.7606	16.2494	5.9692
	3	3.3269	0.8702	15.4979	7.1022

Variabel	Neuron	RMSE	RMSEP	sMAPE	sMAPEP
	4	3.4255	1.0418	18.5078	9.8919
	5	3.3479	0.5612	13.9022	4.8440
PM ₁₀ SUF 7	1	14.4329	2.3620	13.0360	8.2092
	2	15.7930	7.4364	18.2096	24.3830
	3	14.5380	3.3801	13.7983	11.6253
	4	14.5658	3.4795	13.9204	12.0970
	5	14.4124	2.1981	13.1627	7.8136
SO ₂ SUF 1	1	14.2154	6.6352	34.2690	56.1296
	2	14.3236	6.6472	35.4831	57.0855
	3	14.3796	5.8679	39.3595	51.7775
	4	14.2412	6.1659	36.7685	53.2617
	5	14.0897	7.8228	29.7740	67.3969
SO ₂ SUF 6	1	5.3994	2.8077	19.3611	18.6682
	2	5.6828	3.2994	18.5868	28.1444
	3	5.4074	2.8932	19.7127	19.4175
	4	5.3288	3.1427	16.1763	23.7136
	5	5.7897	2.8505	25.6937	19.5077
SO ₂ SUF 7	1	3.0481	1.8326	9.4207	9.4860
	2	3.1357	1.8583	10.8013	11.0472
	3	3.0782	1.9898	10.7912	8.7836
	4	3.0276	1.9322	9.8056	9.0778
	5	3.0430	1.8352	9.3650	9.5058

Lampiran 15. Output LSTM dari Model Hibrida *Time Series Regression* dan LSTM pada Lima Parameter Kualitas Udara di Tiga Stasiun SUF Kota Surabaya

CO SUF 1

```
{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1, 6), 'dtype': 'float32', 'return_sequences': False, 'return_state': False, 'go_backwards': False, 'stateful': False, 'unroll': False, 'units': 5, 'activation': 'tanh', 'recurrent_activation': 'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed': None}}, 'recurrent_initializer': {'class_name': 'Orthogonal', 'config': {'gain': 1.0, 'seed': None}}, 'bias_initializer': {'class_name': 'Zeros', 'config': {}}, 'unit_forget_bias': True, 'kernel_regularizer': None, 'recurrent_regularizer': None, 'bias_regularizer': None, 'activity_regularizer': None, 'kernel_constraint': None, 'recurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0, 'recurrent_dropout': 0.0, 'implementation': 1} [array([[ 8.68099570e-01, 1.11182749e+00, 5.35141826e-01, -9.97373536e-02, 6.63439929e-01, -8.73206854e-02, -4.78037119e-01, -2.95728445e-04, -3.54920447e-01, -3.68818521e-01, 1.03340137e+00, -1.23485684e+00, 1.08409441e+00, 4.57907796e-01, -8.54797661e-01, 1.06268251e+00, 9.42887902e-01, 6.50925934e-01, -3.07095170e-01, 5.89566350e-01], [ 3.98810692e-02, -4.24237996e-02, -1.30759981e-02, -8.17343771e-01, -1.97054401e-01, -4.73796129e-02, -4.89169359e-03, 2.02811003e-01, 9.28427577e-02, 1.53220773e-01, 3.21099460e-01, 3.18807304e-01, -1.39456794e-01, 4.79664281e-03, -6.30801842e-02, -4.24522310e-01, -3.53189260e-01, -2.70267487e-01, -7.76627958e-01, -4.17288184e-01], [ 1.62225887e-01, -3.54665607e-01, -3.82601053e-01, -4.80232805e-01, -9.12974238e-01, -4.11327273e-01, -3.50971818e-01, 2.11634219e-01, 2.57812619e-01, -7.48287141e-02, 1.91666752e-01, -2.58576572e-01, -1.43631592e-01, 2.17518926e-01, 1.57057360e-01, -2.06678420e-01, -4.44349855e-01, 3.42804827e-02, -7.22312033e-01, -8.44964743e-01], [ 3.32712859e-01, 1.61428422e-01, 1.49180651e-01, -6.24709487e-01, -2.19950870e-01, 4.58004773e-01, -2.48855025e-01, 2.11879671e-01, 3.77394795e-01, -3.47462654e-01, 2.64543723e-02, 7.33583495e-02, 7.75199533e-02, 1.16193965e-01, -5.44868350e-01, -2.49546587e-01, 7.59456575e-01, 1.38176218e-01, -5.73167026e-01, -2.76679933e-01], [-3.51804085e-02, 4.26031888e-01, 1.59422845e-01, -5.39145947e-01, -2.37023279e-01, -4.32067186e-01, 2.78089702e-01, 4.48838055e-01, 2.85212338e-01, -3.94939393e-01, 2.71543473e-01, -1.71418041e-01, -3.33409578e-01, 2.33636066e-01, 2.13289171e-01, 8.09193030e-02, 7.06724167e-01, 2.05222562e-01, -8.54635656e-01, -4.42832075e-02], [-4.45107222e-01, -1.72836147e-02, 9.36657116e-02, -8.75668406e-01, -1.07460427e+00, 2.15810895e-01, 4.05606627e-02, 1.50399268e-01, -1.81113690e-01, -1.27742529e-01, 1.74021974e-01, 3.75052482e-01, 4.48371381e-01, -3.92179824e-02, 5.33482432e-01, -2.36184165e-01, 5.36919117e-01, -5.02219200e-01, -6.99102283e-01, -2.87309617e-01]], dtype=float32),
```

```

array([[ -0.19502647, -0.11766353, -0.2091057 , -0.07414206, 0.2104231
, -0.17554195, 0.1331939 , 0.19254029, -0.6808049 , 0.0228696 , -
0.00799542, -0.09402898, 0.03917344, 0.34188852, 0.0898625 , -
0.21057948, -0.14237814, 0.15418458, 0.07697924, 0.27433053], [-
0.40956342, -0.387628 , 0.3160286 , -0.06731085, -0.22597058, -
0.09914427, 0.26732412, -0.36454418, -0.00151767, -0.03797069,
0.04280493, 0.19495293, 0.34027818, -0.03139111, 0.19635597, -
0.20405263, 0.17135224, 0.05234374, 0.14648469, -0.14331992], [-
0.1018487 , -0.15790077, 0.23064071, -0.07212225, 0.10435078, 0.3077141
, 0.14377782, 0.18532777, 0.00789372, -0.13587615, 0.33400774,
0.04201511, -0.21418495, 0.16989745, -0.3263934 , -0.24610054,
0.06090693, 0.17974024, -0.5473686 , -0.19074549], [-0.03535502, -
0.26338255, -0.18268858, -0.32899106, 0.21480972, -0.18155822, -
0.416624 , -0.4153166 , -0.07406035, 0.01818663, -0.2835144 , -
0.01412864, 0.04152709, -0.22246008, -0.38509777, -0.1057838 , -
0.08809126, 0.03834176, -0.23428966, -0.03712576], [-0.04871237, -
0.2781039 , -0.25314048, 0.20102029, -0.11198268, -0.0988622 , -
0.19645576, 0.29811674, -0.24689929, -0.25862923, 0.08655382,
0.19551487, 0.22090916, -0.16097338, 0.11733126, 0.48229218,
0.09174158, 0.06652057, -0.21806727, -0.3331175 ]], dtype=float32),
array([ 0.11047163, 0.28500977, -0.05433249, -0.8010876 , -0.35698286,
1. , 1. , 1. , 1. , 1. , -0.02067736, 0.1257393 , -0.10975986, -
0.24943462, 0.16520731, 0.09046774, 0.3046917 , -0.06326234, -0.7245788
, -0.32274246], dtype=float32)] {'name': 'dense_1', 'trainable': True,
'units': 1, 'activation': 'linear', 'use_bias': True,
'kernel_initializer': {'class_name': 'VarianceScaling', 'config':
{'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed':
None}}, 'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'kernel_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'bias_constraint': None} [array([[ 1.0360404 , [-0.48817298], [
0.84153503], [ 0.04340629], [-0.26727742]], dtype=float32),
array([0.06610986], dtype=float32)]

```

CO SUF 6

```

{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1,
20), 'dtype': 'float32', 'return_sequences': False, 'return_state':
False, 'go_backwards': False, 'stateful': False, 'unroll': False,
'units': 1, 'activation': 'tanh', 'recurrent_activation':
'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class_name':
'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg',
'distribution': 'uniform', 'seed': None}}, 'recurrent_initializer':
{'class_name': 'Orthogonal', 'config': {'gain': 1.0, 'seed': None}},
'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'unit_forget_bias': True, 'kernel_regularizer': None,
'recurrent_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'recurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0,
'recurrent_dropout': 0.0, 'implementation': 1} [array([[ 3.65091234e-

```

```

01, 1.88235283e-01, -1.00657868e+00, 2.54807264e-01], [ 6.29788280e-
01, -9.08862352e-02, -1.27634752e+00, 5.43336153e-01], [ 1.07786886e-
01, -3.83878469e-01, -3.04666311e-01, 1.79768175e-01], [ 5.21907210e-
01, -3.51164222e-01, 8.52815434e-02, 7.79884696e-01], [ 2.61347920e-
01, -2.87535191e-02, -2.11139560e-01, 4.07739162e-01], [ 3.82366806e-
01, -8.20418596e-02, -4.58972034e-04, 2.39140227e-01], [ 2.41118103e-
01, -4.93142605e-02, -1.81253683e-02, 5.04036307e-01], [ 1.48151144e-
01, 1.59477234e-01, 1.57469332e-01, 3.52264464e-01], [ 3.59799832e-01,
1.57854080e-01, -1.11597739e-01, 5.40507548e-02], [-1.24298654e-01, -
1.14197373e-01, -1.48245916e-01, 2.20098749e-01], [ 1.86616033e-01, -
7.45249987e-02, -1.88013054e-02, 3.08343023e-01], [-4.66981322e-01, -
4.28122997e-01, 1.29683381e-02, -3.34066413e-02], [ 1.11651152e-01, -
7.78841972e-02, -8.32818672e-02, -1.95666045e-01], [-4.82499927e-01, -
9.58944559e-02, -7.50196800e-02, -4.19569314e-01], [-3.36995512e-01,
2.78946757e-01, -1.83579102e-01, -2.81558961e-01], [-1.24960944e-01, -
1.86675310e-01, 7.86386728e-02, -7.76741728e-02], [-3.85537863e-01,
4.76706505e-01, -2.19898373e-01, -2.68862080e-02], [-7.24481046e-02, -
3.61650586e-01, 4.91163693e-02, -3.38171661e-01], [-3.65112931e-01,
6.57737255e-02, -1.97167635e-01, -6.68631971e-01], [ 6.79733098e-01,
3.66781950e-02, -3.48080605e-01, -7.59830922e-02]], dtype=float32),
array([[ -0.5285954 , -0.79616123, -0.02723205, 0.29321092],
dtype=float32), array([ -0.1526238 , 1. , 0.14870425, -0.11117636],
dtype=float32)] {'name': 'dense_1', 'trainable': True, 'units': 1,
'activation': 'linear', 'use_bias': True, 'kernel_initializer':
{'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode':
'fan_avg', 'distribution': 'uniform', 'seed': None}},
'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'kernel_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'bias_constraint': None} [array([[ -1.163493]], dtype=float32),
array([0.04291504], dtype=float32)]

```

CO SUF 7

```

{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1,
5), 'dtype': 'float32', 'return_sequences': False, 'return_state':
False, 'go_backwards': False, 'stateful': False, 'unroll': False,
'units': 3, 'activation': 'tanh', 'recurrent_activation':
'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class_name':
'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg',
'distribution': 'uniform', 'seed': None}}, 'recurrent_initializer':
{'class_name': 'Orthogonal', 'config': {'gain': 1.0, 'seed': None}},
'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'unit_forget_bias': True, 'kernel_regularizer': None,
'recurrent_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'recurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0,
'recurrent_dropout': 0.0, 'implementation': 1} [array([[ 0.6389224 ,
0.9043754 , 0.3027314 , -0.0417105 , 0.17067409, -0.10798895, -1.541628
, 0.7538923 , -1.2478387 , 0.01688629, 0.6423676 , 0.11058339],

```

```
[ 0.58451533, -0.28224576, 0.66532326, 0.5120567 , 0.04344237, -
0.03416425, -0.16414088, 0.24207163, 0.2669954 , 0.30049664,
0.41941723, 0.4952685 ], [ 1.1680835 , 0.02834428, 0.42767042,
0.2508151 , 0.11481804, 0.18948722, 0.29967144, 0.61398536, -
0.07344473, 1.2056018 , -0.08484025, -0.04494317], [-0.01399075, -
0.31895655, -0.24739796, -0.19302824, 0.1874032 , -0.0885489 ,
0.00472398, 0.40928784, -0.02917108, -0.01704126, -0.6202576 ,
0.3567924 ], [ 0.6128916 , -0.06124072, 0.21432643, -0.12302408, -
0.31255504, 0.11393958, 0.3891322 , -0.1793701 , -0.0683765 , 0.7023258
, -0.03143792, 0.31148386]], dtype=float32), array([[ 0.12336798, -
0.26256737, 0.4248357 , 0.36498597, -0.49594355, 0.03308986,
0.09538739, -0.18153313, 0.13894424, 0.31577802, 0.42475548, -
0.11658525], [-0.58244365, 0.13638154, -0.22785917, -0.17269391, -
0.5485349 , 0.01708786, -0.28578395, 0.14437146, -0.16227052,
0.29424682, 0.00560439, 0.20922232], [ 0.15805283, 0.48719367,
0.05391592, -0.148451 , 0.17000327, 0.43492323, -0.0042397 , 0.3855691
, -0.03018465, 0.36444333, 0.3029014 , -0.34712657]], dtype=float32),
array([ 0.24804553, -0.0095696 , 0.03860832, 1. , 1. , 1. , 0.15190463,
0.00212088, 0.16344146, 0.30126056, -0.00809395, 0.09790935],
dtype=float32)] {'name': 'dense_1', 'trainable': True, 'units': 1,
'activation': 'linear', 'use_bias': True, 'kernel_initializer':
{'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode':
'fan_avg', 'distribution': 'uniform', 'seed': None}},
'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'kernel_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'bias_constraint': None} [array([[[-0.35880598], [ 1.1165835 ], [-
0.8587344 ]], dtype=float32), array([0.05812861], dtype=float32)]
```

NO₂ SUF 1

```
{'name': 'lstm_2', 'trainable': True, 'batch_input_shape': (None, 1,
5), 'dtype': 'float32', 'return_sequences': False, 'return_state':
False, 'go_backwards': False, 'stateful': False, 'unroll': False,
'units': 3, 'activation': 'tanh', 'recurrent_activation':
'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class_name':
'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg',
'distribution': 'uniform', 'seed': None}}, 'recurrent_initializer':
{'class_name': 'Orthogonal', 'config': {'gain': 1.0, 'seed': None}},
'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'unit_forget_bias': True, 'kernel_regularizer': None,
'recurrent_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'recurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0,
'recurrent_dropout': 0.0, 'implementation': 1} [array([[ 0.7286362 ,
0.89993185, 0.60490316, -0.0417105 , 0.17067409, -0.10798895, -1.412274
, 1.0111517 , -1.2489641 , -0.04342154, 0.70314914, 0.28709185], [-
0.14673625, -0.55226064, -0.20102331, 0.5120567 , 0.04344237, -
0.03416425, -0.19703624, 0.06750265, 0.30485147, -0.57345 , 0.10865736,
-0.48775393], [-0.14268617, -0.00439622, -0.09738547, 0.2508151 ,
```

```

0.11481804, 0.18948722, 0.39549798, 0.40950596, 0.01515118, -
0.08576006, -0.07434488, -0.6665646 ], [ 0.24012813, 0.12099344, -
0.1596262 , -0.19302824, 0.1874032 , -0.0885489 , -0.05619784,
0.49428263, -0.14209424, 0.21234262, -0.17688592, 0.4444651 ], [
0.86916524, 0.00599593, 0.06544388, -0.12302408, -0.31255504,
0.11393958, 0.50627166, -0.15793821, -0.08087601, 0.85245764,
0.02162051, 0.11896838]], dtype=float32), array([[ 0.12336798, -
0.26256737, 0.4248357 , 0.36498597, -0.49594355, 0.03308986,
0.09538739, -0.18153313, 0.13894424, 0.31577802, 0.42475548, -
0.11658525], [-0.58244365, 0.13638154, -0.22785917, -0.17269391, -
0.5485349 , 0.01708786, -0.28578395, 0.14437146, -0.16227052,
0.29424682, 0.00560439, 0.20922232], [ 0.15805283, 0.48719367,
0.05391592, -0.148451 , 0.17000327, 0.43492323, -0.0042397 , 0.3855691
, -0.03018465, 0.36444333, 0.3029014 , -0.34712657]], dtype=float32),
array([ 0.2701208 , 0.08381489, 0.16020572, 1. , 1. , 1. , 0.22306879,
-0.02268727, 0.23654495, 0.23969127, 0.119693 , 0.16297883],
dtype=float32)] {'name': 'dense_2', 'trainable': True, 'units': 1,
'activation': 'linear', 'use_bias': True, 'kernel_initializer':
{'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode':
'fan_avg', 'distribution': 'uniform', 'seed': None}},
'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'kernel_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'bias_constraint': None} [array([[[-0.2865967 ], [ 1.213038 ], [-
0.93362373]], dtype=float32), array([[0.09089406], dtype=float32)]

```

NO₂ SUF 6

```

{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1,
3), 'dtype': 'float32', 'return_sequences': False, 'return_state':
False, 'go_backwards': False, 'stateful': False, 'unroll': False,
'units': 3, 'activation': 'tanh', 'recurrent_activation':
'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class_name':
'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg',
'distribution': 'uniform', 'seed': None}}, 'recurrent_initializer':
{'class_name': 'Orthogonal', 'config': {'gain': 1.0, 'seed': None}},
'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'unit_forget_bias': True, 'kernel_regularizer': None,
'recurrent_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'recurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0,
'recurrent_dropout': 0.0, 'implementation': 1} [array([[ 0.72194624,
0.88282347, 0.4875361 , -0.04440421, 0.18169641, -0.114963 , -1.286767
, 0.9614591 , -1.2005168 , 0.02794747, 0.6485212 , 0.2403383 ], [
0.07875641, -0.49662277, -0.07092714, 0.545126 , 0.04624796, -
0.03637064, -0.04273022, 0.01681937, 0.37246644, -0.25400472,
0.17516498, -0.26192057], [-0.11971427, 0.13582796, 0.11686036,
0.26701307, 0.12223315, 0.20172453, 0.5044035 , 0.41468698, 0.01639194,
0.10635429, 0.05357135, -0.3799071 ]], dtype=float32), array([[

```

```

0.12336798, -0.26256737, 0.4248357, 0.36498597, -0.49594355,
0.03308986, 0.09538739, -0.18153313, 0.13894424, 0.31577802,
0.42475548, -0.11658525], [-0.58244365, 0.13638154, -0.22785917, -
0.17269391, -0.5485349, 0.01708786, -0.28578395, 0.14437146, -
0.16227052, 0.29424682, 0.00560439, 0.20922232], [ 0.15805283,
0.48719367, 0.05391592, -0.148451, 0.17000327, 0.43492323, -0.0042397
, 0.3855691, -0.03018465, 0.36444333, 0.3029014, -0.34712657]],
dtype=float32), array([0.27176303, 0.13209115, 0.44109684, 1., 1.,
1., 0.282132, 0.05487624, 0.15368427, 0.28798836, 0.15861297,
0.41600147], dtype=float32)] {'name': 'dense_1', 'trainable': True,
'units': 1, 'activation': 'linear', 'use_bias': True,
'kernel_initializer': {'class_name': 'VarianceScaling', 'config':
{'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed':
None}}, 'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'kernel_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'bias_constraint': None} [array([[[-0.2979295], [ 1.2655479], [-
1.1651622]], dtype=float32), array([0.08937304], dtype=float32)]

```

NO₂ SUF 7

```

{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1,
10), 'dtype': 'float32', 'return_sequences': False, 'return_state':
False, 'go_backwards': False, 'stateful': False, 'unroll': False,
'units': 2, 'activation': 'tanh', 'recurrent_activation':
'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class_name':
'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg',
'distribution': 'uniform', 'seed': None}}, 'recurrent_initializer':
{'class_name': 'Orthogonal', 'config': {'gain': 1.0, 'seed': None}},
'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'unit_forget_bias': True, 'kernel_regularizer': None,
'recurrent_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'recurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0,
'recurrent_dropout': 0.0, 'implementation': 1} [array([[
1.4301304e+00, 1.6428030e+00, -2.0551479e-01, -4.0535331e-02, -
1.6613714e+00, -2.0757957e+00, 6.0294342e-01, 1.3565844e+00], [-
5.6087708e-01, -5.4382962e-01, -1.5242815e-02, -4.1330189e-01,
5.8888733e-01, -8.3244674e-02, -4.5866851e-02, 4.3414813e-01], [-
3.6942619e-01, 7.0818834e-02, -4.0107945e-01, 7.8860283e-02,
1.3474828e-01, -1.0986571e-01, -1.7627382e-01, -9.1863632e-02], [-
4.1140604e-01, 1.8216674e-01, -5.8791041e-03, 2.4374843e-01, -
5.2591536e-02, -6.8748936e-02, -1.3308534e-01, 4.7057834e-01], [-
6.4401948e-01, -2.1567056e-01, -1.5587521e-01, -5.0060278e-01, -
4.5558402e-01, -8.0911852e-02, -8.1605142e-01, -6.2397325e-01], [-
2.0943828e-01, -9.2149258e-02, -1.3413763e-01, 2.6894122e-01, -
3.8931385e-01, -4.5262137e-01, -7.7794510e-01, 3.1454229e-01], [-
1.7105419e-02, -3.4691662e-01, -1.6542405e-01, -1.1955789e-01, -
1.2280421e-01, 3.6248100e-01, 6.1219338e-02, -4.5360082e-01], [-
5.7799888e-01, 3.9662400e-01, -1.0416314e-01, -1.3275933e-01,

```

```

3.9205346e-01, -5.0835317e-04, -2.2352421e-01, 4.8159286e-01], [-
6.1200917e-01, 6.4181536e-01, -2.9908651e-01, 2.5464767e-01,
7.2819787e-01, -9.0598978e-02, -5.7720459e-01, 3.2100552e-01], [
3.4141633e-01, 2.4760240e-01, -4.3334758e-01, -3.8486362e-01,
1.6429649e-01, -2.4218957e-01, 6.6821027e-01, -1.2261567e-01]],
dtype=float32), array([[ 0.10285524, 0.02719793, -0.12311766,
0.22590087, 0.68737066, -0.21384801, 0.4281773 , 0.47004965], [-
0.3293994 , -0.5659455 , -0.08715995, 0.33737484, -0.20980512, -
0.59293926, 0.14901614, -0.1788354 ]], dtype=float32), array([0.305791
, 0.48590276, 1. , 1. , 0.0740756 , 0.22150603, 0.3466912 , 0.47702897],
dtype=float32)] {'name': 'dense_1', 'trainable': True, 'units': 1,
'activation': 'linear', 'use_bias': True, 'kernel_initializer':
{'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode':
'fan_avg', 'distribution': 'uniform', 'seed': None}},
'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'kernel_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'bias_constraint': None} [array([[[-0.4943366 ], [-0.72678274]],
dtype=float32), array([0.07652853], dtype=float32)]

```

O₃ SUF 1

```

{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1,
7), 'dtype': 'float32', 'return_sequences': False, 'return_state':
False, 'go_backwards': False, 'stateful': False, 'unroll': False,
'units': 1, 'activation': 'tanh', 'recurrent_activation':
'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class_name':
'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg',
'distribution': 'uniform', 'seed': None}}, 'recurrent_initializer':
{'class_name': 'Orthogonal', 'config': {'gain': 1.0, 'seed': None}},
'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'unit_forget_bias': True, 'kernel_regularizer': None,
'recurrent_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'recurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0,
'recurrent_dropout': 0.0, 'implementation': 1} [array([[ 1.3083756 ,
0.2780419 , -1.4755468 , 1.0242751 ], [ 0.3394527 , -0.13424784,
0.2000304 , 0.34313896], [-0.04792926, -0.5670261 , -0.22871846,
0.02990639], [ 0.041771 , -0.51870394, -0.01753032, 0.30265936], [-
0.2880218 , -0.04247177, -0.04444524, -0.13820788], [ 0.16874315, -
0.12118387, -0.04349415, -0.0843935 ], [ 0.16538739, -0.072842 ,
0.12045904, 0.51665324]], dtype=float32), array([[[-0.5285954 , -
0.79616123, -0.02723205, 0.29321092]], dtype=float32),
array([0.08328239, 1. , 0.13407566, 0.22825736], dtype=float32)]
{'name': 'dense_1', 'trainable': True, 'units': 1, 'activation':
'linear', 'use_bias': True, 'kernel_initializer': {'class_name':
'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg',
'distribution': 'uniform', 'seed': None}}, 'bias_initializer':
{'class_name': 'Zeros', 'config': {}}, 'kernel_regularizer': None,
'bias_regularizer': None, 'activity_regularizer': None,

```

```
{'kernel_constraint': None, 'bias_constraint': None} [array([[ -1.4760484]], dtype=float32), array([0.10988994], dtype=float32)]
```

O₃ SUF 6

```
{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1, 2), 'dtype': 'float32', 'return_sequences': False, 'return_state': False, 'go_backwards': False, 'stateful': False, 'unroll': False, 'units': 2, 'activation': 'tanh', 'recurrent_activation': 'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed': None}}, 'recurrent_initializer': {'class_name': 'Orthogonal', 'config': {'gain': 1.0, 'seed': None}}, 'bias_initializer': {'class_name': 'Zeros', 'config': {}}, 'unit_forget_bias': True, 'kernel_regularizer': None, 'recurrent_regularizer': None, 'bias_regularizer': None, 'activity_regularizer': None, 'kernel_constraint': None, 'recurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0, 'recurrent_dropout': 0.0, 'implementation': 1} [array([[ 1.097058 , 1.3781546 , -0.275727 , -0.05438387, 1.026394 , -1.3862925 , 0.14628902, 1.2436131 ], [-0.51577324, -0.675221 , -0.02045035, -0.5545027 , -0.28018498, -0.29154938, 0.24339445, 0.737537 ]], dtype=float32), array([[ 0.10285524, 0.02719793, -0.12311766, 0.22590087, 0.68737066, -0.21384801, 0.4281773 , 0.47004965], [-0.3293994 , -0.5659455 , -0.08715995, 0.33737484, -0.20980512, -0.59293926, 0.14901614, -0.1788354 ]], dtype=float32), array([ 0.8772953 , 0.3928837 , 1. , 1. , -0.3188921 , -0.00872109, 0.949701 , 0.55163014], dtype=float32)] {'name': 'dense_1', 'trainable': True, 'units': 1, 'activation': 'linear', 'use_bias': True, 'kernel_initializer': {'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed': None}}, 'bias_initializer': {'class_name': 'Zeros', 'config': {}}, 'kernel_regularizer': None, 'bias_regularizer': None, 'activity_regularizer': None, 'kernel_constraint': None, 'bias_constraint': None} [array([[ 0.8521645], [-0.8154507]], dtype=float32), array([0.17381667], dtype=float32)]
```

O₃ SUF 7

```
{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1, 2), 'dtype': 'float32', 'return_sequences': False, 'return_state': False, 'go_backwards': False, 'stateful': False, 'unroll': False, 'units': 5, 'activation': 'tanh', 'recurrent_activation': 'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed': None}}, 'recurrent_initializer':
```



```

{'class_name': 'Orthogonal', 'config': {'gain': 1.0, 'seed': None}},
'bias_initializer': {'class_name': 'Zeros', 'config': {}},

'unit_forget_bias': True, 'kernel_regularizer': None,
'recurrent_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'recurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0,
'recurrent_dropout': 0.0, 'implementation': 1] [array([[ 4.9962977e-
01,  8.4709853e-01,  2.7510214e-01,  2.3060767e-01,  3.0913824e-01, -
9.4927579e-02, -5.1968110e-01, -3.2150745e-04, -3.8583916e-01, -
4.0094799e-01,  9.5486313e-01, -1.3863424e+00,  1.2214963e+00, -
4.3374628e-01, -7.5963140e-01,  6.9492507e-01,  6.1912721e-01,
3.8939729e-01, -6.3005134e-02,  1.9704631e-01], [-4.0141878e-01, -
4.5802438e-01, -2.7571276e-01, -5.9123909e-01, -6.6461289e-01, -
5.1507056e-02, -5.3178072e-03,  2.2047877e-01,  1.0093069e-01,
1.6656852e-01,  2.9172352e-01,  2.4045710e-01, -4.6386745e-02,
6.0870814e-01, -2.8689910e-02, -9.5154965e-01, -8.8893402e-01, -
5.9814620e-01, -6.2362540e-01, -9.2641944e-01]], dtype=float32),
array([[-0.19502647, -0.11766353, -0.2091057, -0.07414206, 0.2104231
, -0.17554195, 0.1331939, 0.19254029, -0.6808049, 0.0228696, -
0.00799542, -0.09402898, 0.03917344, 0.34188852, 0.0898625, -
0.21057948, -0.14237814, 0.15418458, 0.07697924, 0.27433053], [-
0.40956342, -0.387628, 0.3160286, -0.06731085, -0.22597058, -
0.09914427, 0.26732412, -0.36454418, -0.00151767, -0.03797069,
0.04280493, 0.19495293, 0.34027818, -0.03139111, 0.19635597, -
0.20405263, 0.17135224, 0.05234374, 0.14648469, -0.14331992], [-
0.1018487, -0.15790077, 0.23064071, -0.07212225, 0.10435078, 0.3077141
, 0.14377782, 0.18532777, 0.00789372, -0.13587615, 0.33400774,
0.04201511, -0.21418495, 0.16989745, -0.3263934, -0.24610054,
0.06090693, 0.17974024, -0.5473686, -0.19074549], [-0.03535502, -
0.26338255, -0.18268858, -0.32899106, 0.21480972, -0.18155822, -
0.416624, -0.4153166, -0.07406035, 0.01818663, -0.2835144, -
0.01412864, 0.04152709, -0.22246008, -0.38509777, -0.1057838, -
0.08809126, 0.03834176, -0.23428966, -0.03712576], [-0.04871237, -
0.2781039, -0.25314048, 0.20102029, -0.11198268, -0.0988622, -
0.19645576, 0.29811674, -0.24689929, -0.25862923, 0.08655382,
0.19551487, 0.22090916, -0.16097338, 0.11733126, 0.48229218,
0.09174158, 0.06652057, -0.21806727, -0.3331175 ]], dtype=float32),
array([ 0.00447461, 0.5052912, 0.3099444, -1.381018, -0.2010254,
1., 1., 1., 1., 1., 0.04582215, -0.00379574, 0.01871336, -
0.01474146, 0.09839104, -0.04977503, 0.43850487, 0.2650349, -1.2893721
, -0.22685763], dtype=float32)] {'name': 'dense_1', 'trainable': True,
'units': 1, 'activation': 'linear', 'use_bias': True,
'kernel_initializer': {'class_name': 'VarianceScaling', 'config':
{'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed':
None}}, 'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'kernel_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'bias_constraint': None} [array([[ 0.88628286], [-0.5617826 ]], [
1.1387242 ], [ 0.03647766], [-0.32250154]], dtype=float32), array([-
0.00362821], dtype=float32)]

```

PM₁₀ SUF 1

```

{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1, 3), 'dtype':
'float32', 'return_sequences': False, 'return_state': False, 'go_backwards': False,
'stateful': False, 'unroll': False, 'units': 4, 'activation': 'tanh', 'recurrent_activation': 'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed': None}}, 'recurrent_initializer': {'class_name': 'Orthogonal', 'config': {'gain': 1.0, 'seed': None}}, 'bias_initializer': {'class_name': 'Zeros', 'config': {}}, 'unit_forget_bias': True, 'kernel_regularizer': None, 'recurrent_regularizer': None, 'bias_regularizer': None, 'activity_regularizer': None, 'kernel_constraint': None, 'recurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0, 'recurrent_dropout': 0.0, 'implementation': 1}
[array([[ 1.9445191e-01, -1.3833944e-01,  2.9100114e-01,  6.2300986e-01,
  1.6144150e-01, -1.0214731e-01, -5.5920553e-01, -3.4594536e-04,
  8.8369474e-02,  1.9817735e-01,  1.1441602e+00, -1.2791061e+00,
  2.5428095e-01, -6.2646723e-01,  5.4284537e-01,  1.2480748e+00],
 [-3.3148208e-01, -7.0952684e-01, -2.3177662e-01, -3.6691036e-03,
  6.8247914e-02, -9.2207074e-02,  1.7914718e-01, -1.7975584e-01,
 -2.1445195e-01,  1.8615578e-01,  3.0923092e-01,  9.0415768e-02,
 -2.7473459e-01, -2.5608858e-01,  4.3718633e-01,  1.8792778e-01,
 [-5.5555791e-01, -7.4966800e-01, -9.8946132e-02, -7.0138919e-01,
 -4.9144280e-01, -1.2834677e-01, -2.6016131e-01, -1.8258643e-01,
 -2.0796841e-02, -2.1431862e-01,  2.6451641e-01,  6.0435850e-02,
 -7.1981239e-01, -1.1288116e+00, -3.6233607e-01,  8.6877726e-02]],
 dtype=float32), array([[ -0.17617251, -0.19658914, -0.39012647,  0.08372848,
-0.02308262,
  0.01299367, -0.32674885, -0.11666136, -0.22822423, -0.2043311 ,
  0.46286932,  0.16909331, -0.44279933,  0.08047321,  0.23243937,
 -0.23827969],
 [ 0.08660343, -0.42268744,  0.00994206,  0.13964099,  0.02841771,
 -0.20661362, -0.14430282, -0.48644593, -0.02023174, -0.07676803,
  0.0358225 , -0.13958728,  0.50495106,  0.06580411,  0.38008708,
  0.24988906],
 [-0.42879516, -0.06104 , -0.10597127, -0.1213974 , -0.40142143,
 -0.18245745,  0.01378008,  0.12598825, -0.12244142, -0.04163726,
 -0.21751621,  0.41246885,  0.19250245, -0.53336424,  0.12973201,
  0.05843278],
 [ 0.04886275,  0.04668917,  0.15640222,  0.5073533 , -0.32711133,
  0.04542294,  0.13108167,  0.05289675,  0.4339154 , -0.15059823,
  0.17547204,  0.3351336 , -0.18170321,  0.14934203,  0.05931591,
  0.41426212]], dtype=float32), array([-1.3312669 , -2.077124 ,  0.346325
28,  0.42854577,  1.
  1.
  1.
  1.
  0.03452253, -0.22991341,
 -0.04099942,  0.00232422, -1.3572631 , -1.7569071 ,  0.32796305,
  0.5177847 ], dtype=float32)]
{'name': 'dense_1', 'trainable': True, 'units': 1, 'activation': 'linear', 'use_bias': True, 'kernel_initializer': {'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed': None}}, 'bias_initializer': {'class_name': 'Zeros', 'config': {}}, 'kernel_regularizer': None, 'bias_regularizer': None, 'activity_regularizer': None, 'kernel_constraint': None, 'bias_constraint': None}
[array([[ 1.2986409e-03],
 [ 1.7230049e-01],
 [ 5.3507662e-01],
 [-1.3567507e+00]], dtype=float32), array([0.02436055], dtype=float32)]

```

PM₁₀ SUF 6

```

{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1,
4), 'dtype': 'float32', 'return_sequences': False, 'return_state':
False, 'go_backwards': False, 'stateful': False, 'unroll': False,

```

```

'units': 5, 'activation': 'tanh', 'recurrent_activation':
'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class_name':
'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg',
'distribution': 'uniform', 'seed': None}}, 'recurrent_initializer':
{'class_name': 'Orthogonal', 'config': {'gain': 1.0, 'seed': None}},
'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'unit_forget_bias': True, 'kernel_regularizer': None,
'recurrent_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'recurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0,
'recurrent_dropout': 0.0, 'implementation': 1] [array([[ 5.9759039e-
01, 7.9974216e-01, 2.8949660e-01, -1.0337560e-01, 4.1630110e-01, -
9.0886235e-02, -4.9755681e-01, -3.0779839e-04, -3.6941290e-01, -
3.8387847e-01, 1.1711664e+00, -1.6683295e+00, 1.3395227e+00,
2.8314823e-01, -1.0699724e+00, 7.3446888e-01, 5.4377288e-01,
4.1316432e-01, -3.5884422e-01, 2.9581416e-01], [-2.3896898e-01, -
1.2936385e-01, 5.3142784e-03, -4.6736205e-01, -4.1102257e-01, -
4.9314260e-02, -5.0914288e-03, 2.1109235e-01, 9.6633792e-02,
1.5947723e-01, -1.6957391e-02, 4.6060976e-01, -3.4062821e-01, -
4.6988329e-01, 2.0501706e-01, -7.8926951e-01, -5.3858846e-01, -
2.8711179e-01, 4.5750740e-01, -6.5597159e-01], [ 3.3942571e-01,
3.0618322e-01, 1.8523014e-01, -9.1831394e-02, -2.8409967e-01, -
4.2812300e-01, -3.6530304e-01, 2.2027588e-01, 2.6833987e-01, -
7.7884197e-02, 1.1663347e-01, -3.3621821e-01, -1.1218154e-01, -
5.2142102e-02, 3.8101561e-02, -1.5357377e-01, 1.0103768e-01,
5.5946094e-01, -3.4895444e-01, -2.5903893e-01], [-6.3889101e-02, -
1.1756229e-01, 9.6439786e-02, -4.8508126e-01, -3.2705405e-01,
4.7670650e-01, -2.5901651e-01, 2.2053134e-01, 3.9280498e-01, -
3.6165059e-01, -1.3773991e-01, 5.7718135e-02, -5.6144356e-04,
6.2086798e-02, -4.3376487e-01, -6.9699383e-01, 4.4051325e-01,
9.0390466e-02, -5.5128646e-01, -4.0189764e-01]], dtype=float32),
array([[ -0.19502647, -0.11766353, -0.2091057, -0.07414206, 0.2104231
, -0.17554195, 0.1331939, 0.19254029, -0.6808049, 0.0228696, -
0.00799542, -0.09402898, 0.03917344, 0.34188852, 0.0898625, -
0.21057948, -0.14237814, 0.15418458, 0.07697924, 0.27433053], [-
0.40956342, -0.387628, 0.3160286, -0.06731085, -0.22597058, -
0.09914427, 0.26732412, -0.36454418, -0.00151767, -0.03797069,
0.04280493, 0.19495293, 0.34027818, -0.03139111, 0.19635597, -
0.20405263, 0.17135224, 0.05234374, 0.14648469, -0.14331992], [-
0.1018487, -0.15790077, 0.23064071, -0.07212225, 0.10435078, 0.3077141
, 0.14377782, 0.18532777, 0.00789372, -0.13587615, 0.33400774,
0.04201511, -0.21418495, 0.16989745, -0.3263934, -0.24610054,
0.06090693, 0.17974024, -0.5473686, -0.19074549], [-0.03535502, -
0.26338255, -0.18268858, -0.32899106, 0.21480972, -0.18155822, -
0.416624, -0.4153166, -0.07406035, 0.01818663, -0.2835144, -
0.01412864, 0.04152709, -0.22246008, -0.38509777, -0.1057838, -
0.08809126, 0.03834176, -0.23428966, -0.03712576], [-0.04871237, -
0.2781039, -0.25314048, 0.20102029, -0.11198268, -0.0988622, -
0.19645576, 0.29811674, -0.24689929, -0.25862923, 0.08655382,
0.19551487, 0.22090916, -0.16097338, 0.11733126, 0.48229218,
0.09174158, 0.06652057, -0.21806727, -0.3331175 ]], dtype=float32),
array([ 0.06561583, 0.6015567, 0.27197662, -2.0015092, -0.06030016,

```

```

1. , 1. , 1. , 1. , 1. , 0.01761919, 0.05753074, -0.01521982,
0.01501336, 0.06103243, 0.01005086, 0.5417949 , 0.2340086 , -1.8109548
, -0.0857909 ], dtype=float32) {'name': 'dense_1', 'trainable': True,
'units': 1, 'activation': 'linear', 'use_bias': True,
'kernel_initializer': {'class_name': 'VarianceScaling', 'config':
{'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed':
None}}, 'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'kernel_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'bias_constraint': None} [array([[ 0.9147341 ], [-0.5980656 ]], [
1.0797462 ], [-0.00258537], [-0.4122163 ]], dtype=float32),
array([0.01776959], dtype=float32)]

```

PM₁₀ SUF 7

```

{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1, 3), 'dtype':
'float32', 'return_sequences': False, 'return_state': False, 'go_backwards': Fals
e, 'stateful': False, 'unroll': False, 'units': 5, 'activation': 'tanh', 'recurre
nt_activation': 'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class n
ame': 'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distributio
n': 'uniform', 'seed': None}}, 'recurrent_initializer': {'class name': 'Orthogona
l', 'config': {'gain': 1.0, 'seed': None}}, 'bias_initializer': {'class name': 'Z
eros', 'config': {}}, 'unit_forget_bias': True, 'kernel_regularizer': None, 'recu
rrent_regularizer': None, 'bias_regularizer': None, 'activity_regularizer': None,
'kernel_constraint': None, 'recurrent_constraint': None, 'bias_constraint': None,
'dropout': 0.0, 'recurrent_dropout': 0.0, 'implementation': 1}
[array([[ 4.8094842e-01,  6.7780906e-01, -9.9873357e-02, -2.0650676e-02,
-6.0085642e-01, -9.2840999e-02, -5.0825816e-01, -3.1441450e-04,
-3.7735820e-01, -3.9213488e-01,  1.0119116e+00, -1.5929023e+00,
 1.1803609e+00,  2.2624169e-01, -5.7350624e-01,  6.4576042e-01,
 3.6357215e-01,  1.3734580e-02, -1.7308599e+00, -7.0532578e-01],
[-5.3981483e-02,  5.3278439e-02, -4.2603578e-02, -1.9877246e-01,
-1.0257034e+00, -5.0374895e-02, -5.2009225e-03, -2.1563250e-01,
9.8712206e-02,  1.6290724e-01,  3.6034563e-01,  1.8917334e-01,
-5.9714176e-02,  9.4192475e-01,  8.7694608e-02, -6.1210436e-01,
-4.0663832e-01, -3.6001185e-01, -1.7920064e+00, -1.2970017e+00],
[ 2.3411590e-01,  2.6477331e-01, -8.9997798e-02,  4.7243023e-01,
-9.6863514e-01, -4.3733102e-01, -3.7315995e-01,  2.2501355e-01,
 2.7411127e-01, -7.9559326e-02,  4.9676046e-02, -2.1850418e-01,
-1.8568979e-01,  1.0417937e+00,  3.7815142e-01, -2.0062327e-01,
 3.1212108e-02,  2.7988002e-01, -1.3236464e+00, -9.4361120e-01]],
dtype=float32), array([[ -0.19502647, -0.11766353, -0.2091057 , -0.07414206,
0.2104231 ,
-0.17554195,  0.1331939 ,  0.19254029, -0.6808049 ,  0.0228696 ,
-0.00799542, -0.09402898,  0.03917344,  0.34188852,  0.0898625 ,
-0.21057948, -0.14237814,  0.15418458,  0.07697924,  0.27433053],
[-0.40956342, -0.387628 ,  0.3160286 , -0.06731085, -0.22597058,
-0.09914427,  0.26732412, -0.36454418, -0.00151767, -0.03797069,
 0.04280493,  0.19495293,  0.34027818, -0.03139111,  0.19635597,
-0.20405263,  0.17135224,  0.05234374,  0.14648469, -0.14331992],
[-0.1018487 , -0.15790077,  0.23064071, -0.07212225,  0.10435078,
0.3077141 ,  0.14377782,  0.18532777,  0.00789372, -0.13587615,
0.33400774,  0.04201511, -0.21418495,  0.16989745, -0.3263934 ,
-0.24610054,  0.06090693,  0.17974024, -0.5473686 , -0.19074549],
[-0.03535502, -0.26338255, -0.18268858, -0.32899106,  0.21480972,
-0.18155822, -0.416624 , -0.4153166 , -0.07406035,  0.01818663,
-0.2835144 , -0.01412864,  0.04152709, -0.22246008, -0.38509777,
-0.1057838 , -0.08809126,  0.03834176, -0.23428966, -0.03712576],
[-0.04871237, -0.2781039 , -0.25314048,  0.20102029, -0.11198268,

```

```

-0.0988622 , -0.19645576, 0.29811674, -0.24689929, -0.25862923,
0.08655382, 0.19551487, 0.22090916, -0.16097338, 0.11733126,
0.48229218, 0.09174158, 0.06652057, -0.21806727, -0.3331175 ],
dtype=float32), array([ 0.1227883 , 0.57711 , 0.320025 , -0.13085203,
-0.8097183 ,
1. , 1. , 1. , 1. , 1. ,
0.08832586, 0.06904703, -0.01532425, -0.1910473 , 0.06288046,
0.05885793, 0.46489865, 0.27471438, -1.2655545 , -0.8389636 ],
dtype=float32)]
{'name': 'dense_1', 'trainable': True, 'units': 1, 'activation': 'linear', 'use_bias': True, 'kernel_initializer': {'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed': None}}, 'bias_initializer': {'class_name': 'Zeros', 'config': {}}, 'kernel_regularizer': None, 'bias_regularizer': None, 'activity_regularizer': None, 'kernel_constraint': None, 'bias_constraint': None}
[[array([[ 0.9526799 ],
[-0.53352416],
[ 1.0953254 ],
[-1.0554765 ],
[-0.01976073]], dtype=float32), array([0.01215929], dtype=float32)]

```

SO₂ SUF 1

```

{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1, 2), 'dtype': 'float32', 'return_sequences': False, 'return_state': False, 'go_backwards': False, 'stateful': False, 'unroll': False, 'units': 3, 'activation': 'tanh', 'recurrent_activation': 'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed': None}}, 'recurrent_initializer': {'class_name': 'Orthogonal', 'config': {'gain': 1.0, 'seed': None}}, 'bias_initializer': {'class_name': 'Zeros', 'config': {}}, 'unit_forget_bias': True, 'kernel_regularizer': None, 'recurrent_regularizer': None, 'bias_regularizer': None, 'activity_regularizer': None, 'kernel_constraint': None, 'recurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0, 'recurrent_dropout': 0.0, 'implementation': 1} [[array([[ -0.21771362, 0.29581234, -1.0309707, -0.04596275, 0.18807364, -0.11899799, -2.1024575, -0.18062374, -1.865403, -1.492168, -0.08104613, -1.49816 ], [ 1.5327808, 0.2757173, 1.0724607, 0.56425905, 0.04787117, -0.03764719, -0.36146265, 0.53036076, -0.11213636, 1.0317621, 0.88276523, 0.80056036]], dtype=float32), array([[ 0.12336798, -0.26256737, 0.4248357, 0.36498597, -0.49594355, 0.03308986, 0.09538739, -0.18153313, 0.13894424, 0.31577802, 0.42475548, -0.11658525], [-0.58244365, 0.13638154, -0.22785917, -0.17269391, -0.5485349, 0.01708786, -0.28578395, 0.14437146, -0.16227052, 0.29424682, 0.00560439, 0.20922232], [ 0.15805283, 0.48719367, 0.05391592, -0.148451, 0.17000327, 0.43492323, -0.0042397, 0.3855691, -0.03018465, 0.36444333, 0.3029014, -0.34712657]], dtype=float32), array([ 0.40332046, -0.49266797, 0.2939502, 1., 1., 1., 0.23950386, -0.05922607, -0.07301357, 0.19150981, -0.68832564, 0.17914583], dtype=float32)] {'name': 'dense_1', 'trainable': True, 'units': 1, 'activation': 'linear', 'use_bias': True, 'kernel_initializer': {'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed': None}},

```

```
'bias_initializer': {'class_name': 'Zeros', 'config': {}},
'kernel_regularizer': None, 'bias_regularizer': None,
'activity_regularizer': None, 'kernel_constraint': None,
'bias_constraint': None} [array([[[-0.52842194], [ 0.5784818 ], [-1.1798931 ]], dtype=float32), array([0.01978978], dtype=float32)]
```

SO₂ SUF 6

```
{'name': 'lstm_1', 'trainable': True, 'batch_input_shape': (None, 1, 15), 'dtype': 'float32', 'return_sequences': False, 'return_state': False, 'go_backwards': False, 'stateful': False, 'unroll': False, 'units': 1, 'activation': 'tanh', 'recurrent_activation': 'hard_sigmoid', 'use_bias': True, 'kernel_initializer': {'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed': None}}, 'recurrent_initializer': {'class_name': 'Orthogonal', 'config': {'gain': 1.0, 'seed': None}}, 'bias_initializer': {'class_name': 'Zeros', 'config': {}}, 'unit_forget_bias': True, 'kernel_regularizer': None, 'recurrent_regularizer': None, 'bias_regularizer': None, 'activity_regularizer': None, 'kernel_constraint': None, 'recurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0, 'recurrent_dropout': 0.0, 'implementation': 1} [array([[ 1.421763 , 0.21155816, -2.1249347 , 1.0907803 ], [-0.44891533, -0.10214731, 0.05739457, -0.62145394], [-0.26629636, -0.43144214, -0.1251763 , -0.2597052 ], [ 0.10411372, -0.39467448, -0.00312645, 0.29733253], [-0.15693103, -0.03231615, -0.08750534, -0.09753768], [ 0.04716908, -0.09220707, 0.06661326, -0.18933941], [ 0.08007712, -0.05542445, -0.02441793, 0.25664136], [ 0.46482927, 0.17923695, -0.20076658, 0.5976854 ], [-0.0652564 , 0.17741269, 0.22790796, -0.45989153], [-0.2949321 , -0.12834677, -0.09915552, 0.04330853], [ 0.1133343 , -0.08375886, 0.0348401 , 0.21223085], [-0.4189647 , -0.4811687 , -0.03595365, 0.0461535 ], [ 0.4092298 , -0.08753428, -0.06671699, -0.01232182], [ 0.30093536, 0.10777605, -0.11044925, 0.35237917], [-0.15915696, 0.31350905, 0.16002405, -0.03060057]], dtype=float32), array([[[-0.5285954 , -0.79616123, -0.02723205, 0.29321092]], dtype=float32), array([ 0.10105126, 1. , -0.00482398, 0.10638671], dtype=float32)] {'name': 'dense_1', 'trainable': True, 'units': 1, 'activation': 'linear', 'use_bias': True, 'kernel_initializer': {'class_name': 'VarianceScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'uniform', 'seed': None}}, 'bias_initializer': {'class_name': 'Zeros', 'config': {}}, 'kernel_regularizer': None, 'bias_regularizer': None, 'activity_regularizer': None, 'kernel_constraint': None, 'bias_constraint': None} [array([[[-1.3974179]], dtype=float32), array([0.00716575], dtype=float32)]
```

SO₂ SUF 7

```

{'name': 'lstm_1', 'trainable': True, 'batch input shape': (None, 1, 5
), 'dtype': 'float32', 'return sequences': False, 'return state': Fal
se, 'go backwards': False, 'stateful': False, 'unroll': False, 'units
': 1, 'activation': 'tanh', 'recurrent_activation': 'hard_sigmoid', '
use_bias': True, 'kernel_initializer': {'class_name': 'VarianceScalin
g', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution': 'unif
orm', 'seed': None}}, 'recurrent_initializer': {'class_name': 'Orthog
onal', 'config': {'gain': 1.0, 'seed': None}}, 'bias_initializer': {'
class_name': 'Zeros', 'config': {}}, 'unit_forget_bias': True, 'kerne
l_regularizer': None, 'recurrent_regularizer': None, 'bias_regularize
r': None, 'activity_regularizer': None, 'kernel_constraint': None, 'r
ecurrent_constraint': None, 'bias_constraint': None, 'dropout': 0.0, '
recurrent_dropout': 0.0, 'implementation': 1}
[array([[ 1.4369161 ,  0.307387  , -1.7899663 ,  1.0061318 ],
        [-0.32429007, -0.14841658,  0.2572616 , -0.501043  ],
        [-0.39812812, -0.62687093, -0.11912614, -0.3849631 ],
        [ 0.2681164 , -0.5734488 ,  0.16592269,  0.5457169 ],
        [-0.20641415, -0.04695427, -0.10471231, -0.11966647]],
        dtype=float32), array([[ -0.5285954 , -0.79616123, -0.02723205,
0.29321092]],
        dtype=float32), array([0.34062144, 1.          , 0.1068676 , 0.38
412693], dtype=float32)]
{'name': 'dense_1', 'trainable': True, 'units': 1, 'activation': 'lin
ear', 'use_bias': True, 'kernel_initializer': {'class_name': 'Varianc
eScaling', 'config': {'scale': 1.0, 'mode': 'fan_avg', 'distribution'
: 'uniform', 'seed': None}}, 'bias_initializer': {'class_name': 'Zero
s', 'config': {}}, 'kernel_regularizer': None, 'bias_regularizer': No
ne, 'activity_regularizer': None, 'kernel_constraint': None, 'bias co
nstraint': None}
[array([[ -1.6657584]], dtype=float32), array([0.07647384], dtype=floa
t32)]

```

Lampiran 16. Nilai Ramalan ISPU

Pukul	SUF 1 CO	SUF 6 CO	SUF 7 CO	SUF 1 NO₂	SUF 6 NO₂	SUF 7 NO₂
19:30:00	13.23	21.61	0.00	2.02	0.00	8.90
20:00:00	11.86	22.53	0.00	2.10	0.00	8.39
20:30:00	10.86	29.24	0.00	1.11	0.00	7.16
21:00:00	13.79	30.48	0.00	1.75	0.00	7.13
21:30:00	16.49	29.99	0.00	1.97	0.00	5.38
22:00:00	16.50	29.76	0.19	1.73	0.00	5.68
22:30:00	15.41	29.30	0.00	2.31	0.00	7.19
23:00:00	15.44	31.16	0.00	2.31	0.00	7.48
23:30:00	18.12	32.46	0.00	1.61	0.00	7.46
00:00:00	19.42	31.37	0.00	0.66	0.00	8.49
00:30:00	17.83	29.26	0.00	0.66	0.00	7.09
01:00:00	16.31	32.95	0.00	0.95	0.00	6.70
01:30:00	15.18	30.16	0.00	1.25	0.00	6.02
02:00:00	14.01	32.37	0.00	1.11	0.00	5.60
02:30:00	13.29	29.53	0.00	1.23	0.00	5.80
03:00:00	12.38	32.89	0.00	0.94	0.00	5.61
03:30:00	11.78	30.50	0.00	1.11	0.00	5.89
04:00:00	11.43	33.42	0.00	1.10	0.00	5.47
04:30:00	11.50	33.72	0.00	1.22	0.00	5.26
05:00:00	11.94	30.40	0.00	1.29	0.00	5.23
05:30:00	12.34	39.23	0.00	1.32	0.00	5.05
06:00:00	13.34	29.98	0.00	1.06	0.00	5.35
06:30:00	14.20	35.02	0.00	0.99	0.00	5.51
07:00:00	14.68	32.19	1.99	1.14	0.04	6.41
07:30:00	14.99	32.91	0.40	1.32	0.01	7.24
08:00:00	16.06	33.76	0.00	1.45	0.00	8.25

Pukul	SUF 1 CO	SUF 6 CO	SUF 7 CO	SUF 1 NO₂	SUF 6 NO₂	SUF 7 NO₂
08:30:00	16.93	32.57	0.00	1.35	0.00	8.10
09:00:00	16.59	35.84	0.00	1.28	0.00	7.86
09:30:00	15.41	31.40	0.00	1.28	0.00	7.52
10:00:00	15.05	37.59	0.00	1.40	0.00	6.94
10:30:00	13.89	35.36	0.00	1.26	0.00	6.90
11:00:00	12.76	36.76	0.00	1.21	0.00	6.71
11:30:00	12.50	36.35	0.00	1.42	0.00	6.90
12:00:00	12.49	36.89	0.00	1.63	0.00	6.59
12:30:00	11.83	38.32	0.00	1.50	0.00	6.20
13:00:00	11.24	34.78	0.00	1.31	0.00	5.81
13:30:00	10.75	35.17	0.00	1.29	0.00	5.68
14:00:00	11.00	39.07	0.00	1.26	0.00	6.47
14:30:00	11.41	34.07	0.00	1.38	0.00	7.54
15:00:00	10.81	36.56	0.00	1.30	0.00	7.65
15:30:00	10.46	34.24	0.00	1.28	0.00	9.22
16:00:00	10.26	40.58	0.00	1.10	0.00	9.35
16:30:00	10.42	33.74	0.00	1.01	0.00	9.02
17:00:00	11.11	40.82	0.00	1.01	0.00	7.70
17:30:00	11.37	38.35	0.00	0.96	0.00	8.54
18:00:00	12.40	41.03	0.00	1.03	0.00	8.96
18:30:00	12.58	36.14	0.00	1.16	0.00	8.44
19:00:00	12.96	42.50	0.00	1.19	0.00	9.30

Pukul	SUF 1 O₃	SUF 6 O₃	SUF 7 O₃	SUF 1 PM₁₀	SUF 6 PM₁₀	SUF 7 PM₁₀
19:30:00	6.99	9.63	6.85	31.15	9.52	31.59
20:00:00	3.96	8.56	5.36	31.68	10.45	29.89
20:30:00	1.41	2.68	5.53	23.84	11.47	30.78

Pukul	SUF 1 O₃	SUF 6 O₃	SUF 7 O₃	SUF 1 PM₁₀	SUF 6 PM₁₀	SUF 7 PM₁₀
21:00:00	1.60	2.99	6.32	22.16	11.19	26.10
21:30:00	1.62	4.60	6.25	22.59	11.36	24.56
22:00:00	1.56	5.09	5.05	24.87	10.00	29.01
22:30:00	2.61	6.09	2.42	22.03	9.96	29.47
23:00:00	1.68	3.17	2.41	17.83	10.06	24.84
23:30:00	0.62	3.72	2.67	18.57	10.18	23.09
00:00:00	0.41	3.82	2.27	17.21	9.88	23.08
00:30:00	1.47	2.89	2.58	16.65	10.26	22.95
01:00:00	4.45	2.99	2.65	12.53	10.48	25.47
01:30:00	2.64	3.12	2.74	13.92	10.25	28.92
02:00:00	3.80	3.45	2.70	13.51	10.39	34.54
02:30:00	4.34	2.80	2.29	14.81	10.25	41.63
03:00:00	3.16	3.04	2.10	15.44	10.20	47.22
03:30:00	2.20	2.98	1.87	14.16	9.41	53.13
04:00:00	2.07	2.84	1.84	12.06	9.26	57.29
04:30:00	1.13	2.60	1.67	15.83	9.38	60.85
05:00:00	0.90	2.75	1.56	19.49	10.42	63.14
05:30:00	0.84	1.95	1.44	20.69	10.77	66.05
06:00:00	0.46	2.05	1.37	26.20	11.47	69.95
06:30:00	0.49	2.46	1.44	29.75	12.13	71.73
07:00:00	0.81	4.09	1.72	30.39	13.18	74.46
07:30:00	2.20	5.63	2.41	28.19	13.98	78.76
08:00:00	4.70	7.90	4.03	28.09	14.26	79.49
08:30:00	9.05	10.94	6.81	35.80	14.53	81.02
09:00:00	13.04	13.91	10.06	33.87	15.10	84.26
09:30:00	17.79	16.76	13.78	32.65	15.45	85.46
10:00:00	18.26	22.20	16.44	30.20	14.96	86.76

Pukul	SUF 1 O₃	SUF 6 O₃	SUF 7 O₃	SUF 1 PM₁₀	SUF 6 PM₁₀	SUF 7 PM₁₀
10:30:00	21.74	26.23	18.07	26.14	15.03	86.98
11:00:00	22.48	28.08	18.50	23.78	15.05	88.60
11:30:00	23.38	29.16	17.48	23.48	15.03	88.89
12:00:00	19.65	29.66	17.33	25.82	15.23	86.52
12:30:00	21.60	30.55	16.34	24.96	14.64	84.58
13:00:00	22.51	29.81	16.23	24.51	13.88	84.98
13:30:00	20.76	28.01	15.75	22.74	13.22	85.98
14:00:00	16.32	25.22	15.12	18.26	13.06	83.90
14:30:00	10.46	23.10	13.45	16.82	12.11	81.17
15:00:00	11.36	23.03	11.62	17.60	11.28	76.16
15:30:00	10.12	23.73	9.92	18.79	11.02	71.24
16:00:00	9.08	21.13	8.93	19.46	10.76	65.86
16:30:00	10.76	23.00	7.02	16.46	10.29	63.89
17:00:00	8.85	23.48	17.53	19.89	9.80	50.07
17:30:00	7.16	18.99	5.65	22.73	9.75	56.09
18:00:00	4.66	16.49	4.71	22.48	9.62	55.80
18:30:00	3.24	12.53	4.12	23.63	9.34	56.24
19:00:00	3.26	12.18	3.25	23.41	9.27	55.98

Pukul	SUF 1 SO₂	SUF 6 SO₂	SUF 7 SO₂
19:30:00	2.12	3.65	11.06
20:00:00	4.03	3.90	8.06
20:30:00	9.55	6.05	8.81
21:00:00	10.16	8.40	7.36
21:30:00	8.44	10.05	7.06
22:00:00	6.37	5.66	7.47
22:30:00	5.49	5.62	8.50

Pukul	SUF 1 SO₂	SUF 6 SO₂	SUF 7 SO₂
23:00:00	6.71	6.16	9.47
23:30:00	9.33	5.95	9.27
00:00:00	12.88	5.37	9.90
00:30:00	17.76	5.81	10.74
01:00:00	25.04	7.72	10.49
01:30:00	45.31	8.65	10.94
02:00:00	32.82	9.16	10.84
02:30:00	26.72	10.31	10.79
03:00:00	22.44	10.65	10.94
03:30:00	19.37	10.88	12.30
04:00:00	17.10	10.67	11.12
04:30:00	15.38	10.63	11.34
05:00:00	14.08	11.44	11.18
05:30:00	13.12	10.01	11.00
06:00:00	12.40	11.11	11.03
06:30:00	11.86	12.85	11.39
07:00:00	11.53	15.93	12.66
07:30:00	11.29	17.64	14.66
08:00:00	11.07	17.64	15.34
08:30:00	10.89	14.71	14.84
09:00:00	10.72	11.88	12.58
09:30:00	10.56	10.15	11.29
10:00:00	10.43	8.59	10.14
10:30:00	10.36	7.10	9.77
11:00:00	10.31	6.57	9.47
11:30:00	10.25	6.33	9.24
12:00:00	10.19	6.04	9.13

Pukul	SUF 1 SO₂	SUF 6 SO₂	SUF 7 SO₂
12:30:00	10.38	5.98	9.08
13:00:00	10.61	6.02	9.06
13:30:00	11.00	5.85	8.96
14:00:00	11.57	6.21	9.07
14:30:00	11.46	6.00	9.11
15:00:00	11.19	6.09	9.52
15:30:00	11.16	6.09	9.68
16:00:00	11.04	6.36	10.00
16:30:00	10.86	6.58	11.89
17:00:00	10.74	6.65	6.89
17:30:00	10.60	6.57	9.48
18:00:00	10.45	6.87	9.79
18:30:00	10.33	6.94	10.09
19:00:00	10.51	6.82	10.28

Lampiran 17. *Syntax Uji White*

```

#uji white
library(tseries)
#Uji White Pada SO2 SUF 7#
data=Data_Median
x<-data$`SUF 7_SO2`
zt<-as.ts(x)
Z1<-zt
lagz1<-c(12)
maxlag<-max(lagz1)
laginputZ1<-matrix(NA,(length(Z1)-maxlag),length(lagz1))
for (j in 1:length(lagz1)){
  laginputZ1[,j]<-Z1[(maxlag-lagz1[j]+1):(length(Z1)-lagz1[j])]}
head(laginputZ1)
Z11<-data.frame(cbind(Z1[(maxlag+1):length(Z1)],laginputZ1,
                      zt[(maxlag+1):length(Z1)]))
head(bandaraZ11)
ujiZ1=list()
statuji.Z1<-c()
p.Z1<-c()
#dibuat replikasi sampai 10 kali pada data
for (i in 1:10)
{
  ujiZ1[[i]]<-white.test(Z11[, -1], Z11[, 1], type="F")
  statuji.Z1[i]<-ujiZ1[[i]]$statistic
  p.Z1[i]<-ujiZ1[[i]]$p.value
}
hasilZ1<-cbind(statuji.Z1,p.Z1)
hasilZ1

```

Lampiran 18. *Syntax* FFNN

```

CO21 <- read.csv("D:/Dari
D/Kuliah/VIII/Analisis/Minitab/Metode/Ramalan/CO21.csv")
CO21=CO21[,-1]
correlations <- cor(CO21$yt,CO21, use = "complete.obs",
method = "pearson")
correlations1 <- as.list(cor(CO21$yt,CO21, use = "complete.obs",
method = "pearson"))
data1=CO21[,c(1,2,8,9,10,11,19,20,21,27,28,29,30,38,39,40,58,5
9)]
data=data1[386:16992,]
data1=data1[386:nrow(data1),]
write.csv(data1,"CO21n.csv")
tail(data1)

#scale data for nn
max=apply(data,2,max)
min=apply(data,2,min)
scaled=as.data.frame(scale(data1,center=min,scale=max-min))
head(scaled)
#creating train and test
nrow(data1)
trainNN=scaled[1:16597,]
testNN=scaled[16598:16645,]

library(neuralnet)
allvars=colnames(data1)
predictorvarss=allvars[!allvars%in%"yt"]
predictorvarss=paste(predictorvarss,collapse = "+")
form=as.formula(paste("yt~",predictorvarss,collapse="+"))

#n2
set.seed(1234)
NN2=neuralnet(formula = form,trainNN,hidden=2,linear.output =
T,act.fct = "logistic",stepmax=1e+06)

```

```

summary(NN2)
win.graph()
plot(NN2)

bobot2=NN2$weights
Trainp2=as.data.frame(NN2$net.result[1])
Trainp12=(Trainp2*(max(data$yt)-min(data$yt))+min(data$yt))

Testp2=matrix(nrow=48,ncol=1)
for (i in 1:48){
Testp2[i]=compute(NN2, testNN[i,-1])$net.result
if(is.na(testNN[i+1,2])){testNN[i+1,2]=Testp2[i+1-1]}
if(is.na(testNN[i+1,3])){testNN[i+1,3]=Testp2[i+1-23]}
if(is.na(testNN[i+1,4])){testNN[i+1,4]=Testp2[i+1-24]}
if(is.na(testNN[i+1,5])){testNN[i+1,5]=Testp2[i+1-25]}
if(is.na(testNN[i+1,6])){testNN[i+1,6]=Testp2[i+1-26]}
if(is.na(testNN[i+1,7])){testNN[i+1,7]=Testp2[i+1-44]}
if(is.na(testNN[i+1,8])){testNN[i+1,8]=Testp2[i+1-48]}
if(is.na(testNN[i+1,9])){testNN[i+1,9]=Testp2[i+1-49]}
if(is.na(testNN[i+1,10])){testNN[i+1,10]=Testp2[i+1-71]}
if(is.na(testNN[i+1,11])){testNN[i+1,11]=Testp2[i+1-72]}
if(is.na(testNN[i+1,12])){testNN[i+1,12]=Testp2[i+1-73]}
if(is.na(testNN[i+1,13])){testNN[i+1,13]=Testp2[i+1-74]}
if(is.na(testNN[i+1,14])){testNN[i+1,14]=Testp2[i+1-92]}
if(is.na(testNN[i+1,15])){testNN[i+1,15]=Testp2[i+1-336]}
if(is.na(testNN[i+1,16])){testNN[i+1,16]=Testp2[i+1-337]}
if(is.na(testNN[i+1,17])){testNN[i+1,17]=Testp2[i+1-384]}
if(is.na(testNN[i+1,18])){testNN[i+1,18]=Testp2[i+1-385]}
}
Testp2
Testp12=(Testp2*(max(data$yt)-min(data$yt))+min(data$yt))
write.csv(Trainp12,"PTrainCO1-2.csv")
write.csv(Testp12,"PTestCO1-2.csv")

```


Lampiran 19. *Syntax* LSTM

```

import pandas as pd
import matplotlib.pyplot as plt
dataset1 = pd.read_csv('D:\Dari D\Kuliah\VIII\Analisis\Minitab\
Metode\Ramalan\CO6\CO26n.csv')
aa=dataset1["yt"]
plt.plot(aa)
plt.show()

import numpy as np
import matplotlib.pyplot as plt
import pandas as pd
import math
from keras.models import Sequential
from keras.layers import Dense
from keras.layers import LSTM
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import mean_squared_error

np.random.seed(7)
dataframe = dataset1.drop(["Unnamed: 0"],axis=1)
dataset = dataframe.values
dataset = dataset.astype('float32')

train_size = 16932
test_size = len(dataset) - train_size
trainX, testX = np.array(dataset[0:train_size,1:14]), np.array(datas
et[train_size:len(dataset),1:14])
trainY, testY = np.array(dataset[0:train_size,0]), np.array(dataset[
train_size:len(dataset),0])
print(len(trainX), len(testX))
trainX = np.reshape(trainX, (trainX.shape[0], 1, trainX.shape[1]))
testX = np.reshape(testX, (testX.shape[0], 1, testX.shape[1]))

```




```
e.iloc[i+1,4]=testp2[0][(i+1)-17]
if d.iloc[i+1,5]==True:
    e.iloc[i+1,5]=testp2[0][(i+1)-18]
if d.iloc[i+1,6]==True:
    e.iloc[i+1,6]=testp2[0][(i+1)-42]
if d.iloc[i+1,7]==True:
    e.iloc[i+1,7]=testp2[0][(i+1)-43]
if d.iloc[i+1,8]==True:
    e.iloc[i+1,8]=testp2[0][(i+1)-46]
if d.iloc[i+1,9]==True:
    e.iloc[i+1,9]=testp2[0][(i+1)-47]
if d.iloc[i+1,10]==True:
    e.iloc[i+1,10]=testp2[0][(i+1)-48]
if d.iloc[i+1,11]==True:
    e.iloc[i+1,11]=testp2[0][(i+1)-49]
if d.iloc[i+1,12]==True:
    e.iloc[i+1,12]=testp2[0][(i+1)-50]

testPred = np.reshape(testp2, (48,1))

hasiltrain=(pd.DataFrame(trainPredict)*(20.511-0))+0
hasiltest=(pd.DataFrame(testPred)*(20.511-0))+0

hasiltrain.to_csv("PTrainCO6-2.csv")
hasiltest.to_csv("PTestCO6-2.csv")
```

Lampiran 20. Surat Keterangan Sumber Data



PEMERINTAH KOTA SURABAYA
DINAS LINGKUNGAN HIDUP
 Jalan Jemerto Nomor 25-27 Surabaya 60272
 Telepon (031) 5312144, Pessawat. 390, 343, 570, 148, 513 Faksimile (031) 5472924

SURAT KETERANGAN
 Nomor : 800/1002.8/436.7.12/2019

Yang bertanda tangan di bawah ini :

Nama : Ir. Aditya Wasita, MM
 Jabatan : Sekretaris Dinas Lingkungan Hidup Kota Surabaya

Menerangkan dengan sesungguhnya bahwa Mahasiswa Departemen Statistika FMKSD ITS Surabaya dibawah ini :

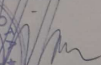
Nama : Hendri Prabowo
 NRP : 0621154000068


Benar telah melakukan survey di Dinas Lingkungan Hidup Kota Surabaya mulai tanggal 20 Februari 2019 s.d. 20 Mei 2019 untuk keperluan Tugas Akhir Semester genap 2018/2019.

Terkait dengan keperluan tugas akhir kami menyampaikan bahwa :

1. Tidak Keberatan nama "Dinas Lingkungan Hidup" dicantumkan dalam Tugas Akhir mahasiswa Statistika yang akan disimpan di Perpustakaan ITS dan dibaca di lingkungan ITS.
2. Tidak Keberatan bahwa hasil analisis data dari instansi kami dipublikasikan dalam E journal ITS yaitu Jurnal Sains dan Seni ITS.
3. Keberatan apabila data mentah yang kami berikan disebarluaskan kepada orang/ instansi/ lembaga lain tanpa izin dari Dinas Lingkungan Hidup Kota Surabaya

Demikian surat keterangan ini untuk dipergunakan sebagaimana mestinya.

Surabaya, 8 Juli 2019
 a.n. Kepala Dinas
 Sekretaris

 Ir. Aditya Wasita, MM
 Pembina Tk. I
 NIP.196302081993011001



<http://lh.surabaya.go.id>, email: lh@surabaya.go.id

BIODATA PENULIS



Penulis dilahirkan di Madiun, 5 Agustus 1997 dengan nama lengkap Hendri Prabowo, biasa dipanggil Hendri. Penulis menempuh pendidikan formal di MI Nurul Ulum Sidorejo, SMPN 1 Dolopo, dan SMAN 1 Geger. Kemudian penulis diterima sebagai mahasiswa Departemen Statistika ITS pada tahun 2015. Selama masa perkuliahan, penulis aktif di Professional Statistics (PSt) Himpunan

Mahasiswa Statistika ITS (HIMASTA-ITS) sebagai staff HRD periode 2016-2017 dan tim ahli pada periode 2017-2018. Selain itu penulis juga aktif di Forum Studi Islam Statistika (FORSIS) sebagai staff Syiar periode 2016-2017 dan Sekretaris Jenderal pada periode 2017-2018. Selain itu selama perkuliahan penulis juga pernah menjadi asisten dosen untuk beberapa mata kuliah seperti Pengantar Metode Statistika, Pengendalian Kualitas Statistika, Komputasi Statistika, Data Mining Statistika dan Analisis Data. Bagi pembaca yang ingin berdiskusi, memberikan saran, dan kritik mengenai Tugas Akhir ini dapat disampaikan melalui email hendriprabowo88@gmail.com atau melalui nomor 081259990133.