



ITS
Institut
Teknologi
Sepuluh Nopember

TUGAS AKHIR - KS141501

**VISUALISASI DARI KLASTERISASI DAN PERAMALAN
KUALITAS UDARA KOTA SURABAYA
MENGUNAKAN METODE KLASTERISASI K-MEANS
DAN PERAMALAN ARTIFICIAL NEURAL NETWORK**

***VISUALIZATION OF AIR QUALITY CLUSTERING AND
FORECASTING IN SURABAYA CITY USING K-MEANS
CLUSTERING METHOD AND ARTIFICIAL NEURAL
NETWORK FORECASTING METHOD***

ERVI RITYA ZULVIMA

NRP 5213 100 002

Dosen Pembimbing 1

Edwin Riksakomara

Dosen Pembimbing 2

Irmasari Hafidz, S.Kom, M.Sc.

Tugas Akhir - KS 141501

VISUALISASI DARI KLASTERISASI DAN PERAMALAN KUALITAS UDARA KOTA SURABAYA MENGGUNAKAN METODE KLASTERISASI K-MEANS DAN PERAMALAN ARTIFICIAL NEURAL NETWORK

**ERVI RITYA ZULVIMA
NRP 5213100002**

Dosen Pembimbing :

**Edwin Riksakomara, S. Kom., M. T.
Irmasari Hafidz, S.Kom, M.Sc.**

**DEPARTEMEN SISTEM INFORMASI
Fakultas Teknologi Informasi
Institut Teknologi Sepuluh Nopember
Surabaya 2017**

Final Project - KS 141501

**VISUALIZATION OF AIR QUALITY
CLUSTERING AND FORECASTING IN
SURABAYA CITY USING K-MEANS
CLUSTERING METHOD AND ARTIFICIAL
NEURAL NETWORK FORECASTING METHOD**

**ERVI RITYA ZULVIMA
NRP 5213100002**

**Supervisor
Edwin Riksakomara, S. Kom., M. T.
Irmasari Hafidz, S.Kom, M.Sc.**

**DEPARTEMEN SISTEM INFORMASI
Fakultas Teknologi Informasi
Institut Teknologi Sepuluh Nopember
Surabaya 2016**

LEMBAR PENGESAHAN

**VISUALISASI DARI KLASTERISASI DAN
PERAMALAN KUALITAS UDARA SURABAYA
MENGUNAKAN METODE KLASTERISASI K-
MEANS DAN PERAMALAN ARTIFICIAL
NEURAL NETWORK**

TUGAS AKHIR

Disusun Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer
pada
Departemen Sistem Informasi
Fakultas Teknologi Informasi
Institut Teknologi Sepuluh Nopember

Oleh :

ERVI RITYA ZULVIMA
NRP. 5213100002

Surabaya, 2017
Kepala Departemen Sistem Informasi



Aris Triyanto, M. Kom.

NIP. 196503101991021001

LEMBAR PERSETUJUAN

**VISUALISASI DARI KLASTERISASI DAN
PERAMALAN KUALITAS UDARA SURABAYA
MENGUNAKAN METODE KLASTERISASI K-
MEANS DAN PERAMALAN ARTIFICIAL
NEURAL NETWORK**

TUGAS AKHIR

Disusun Untuk Memenuhi Salah Satu Syarat
Memperoleh Gelar Sarjana Komputer
pada
Departemen Sistem Informasi
Fakultas Teknologi Informasi
Institut Teknologi Sepuluh Nopember

Oleh :

ERVI RITYA ZULVIMA

NRP. 5213100002

Disetujui Tim Penguji : Tanggal Ujian : 7 Juli 2017
Periode Wisuda: September 2017

Edwin Riksakomara, S. Kom., M. T.

(Pembimbing I)

Irmasari Hafidz, S.Kom, M.Sc.

(Pembimbing II)

Wiwik Anggraeni, S.Si., M.Kom

(Penguji I)

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

(Penguji II)

ABSTRAK

Kualitas udara merupakan suatu hal serius yang perlu selalu dipantau mengingat dampak buruk berkepanjangan berpengaruh pada pemanasan global dan gangguan kesehatan terkait pernapasan. Indonesia adalah salah satu negara yang seringkali memiliki status kualitas udara yang buruk. Kota Surabaya adalah salah satu kota besar yang memerlukan pengawasan terkait kadar polutan udara. Badan Lingkungan Hidup Kota Surabaya adalah dinas yang memantau kualitas udara pada beberapa wilayah di Kota Surabaya. Penanganan reaktif seringkali telah dilakukan, namun penanganan antisipatif adalah hal yang lebih penting dilakukan untuk mencegah terjadinya dampak yang buruk yakni dengan mengetahui kelompok titik rawan polusi berdasarkan kondisi Surabaya dan prediksi kadar polutan udara di masa depan.

Mengetahui titik rawan polusi dapat menggunakan teknik clustering untuk mengetahui kluster standar indeks yang tepat sesuai kondisi Kota Surabaya dan kemudian diketahui wilayah rawan polusi di Surabaya dengan algoritma K-means.

Prediksi kualitas udara di masa yang akan datang dapat dilakukan melalui peramalan dan klasifikasi. Peramalan kualitas udara adalah salah satu cara efektif dalam melindungi kesehatan publik dan lingkungan dengan menyediakan peringatan dini melawan polusi udara. Masukan dari peramalan adalah menggunakan data histori kualitas udara Kota Surabaya yang dapat dianalisa menggunakan metode Backpropagation Neural Network. Setelah hasil peramalan terbentuk dilakukan pengklasifikasian kelas status polusi dengan metode Naive Bayes untuk memprediksi hasil peramalan ke depan memiliki status polusi seperti apa.

Luaran dari penelitian ini menghasilkan kluster titik rawan polusi di Kota Surabaya, model peramalan ANN dan model klasifikasi Naive Bayes. Hasil clustering menunjukkan daerah

paling rawan polusi pada tahun 2016 adalah wilayah stasiun pemantau udara wilayah Surabaya Selatan dimana menyesuaikan dengan indeks rentang kondisi Surabaya. Luaran dari peramalan ANN berupa model terbaik ANN dan hasil nilai peramalan kadar polutan untuk mengetahui kualitas di masa yang akan datang. Untuk hasil nilai MAPE dari model peramalan ANN terdiri dari 3 model yakni nilai MAPE wilayah Surabaya Pusat sebesar 24.6%, MAPE model wilayah Surabaya Timur sebesar 34.2%, dan MAPE wilayah Surabaya Timur senilai 27,4%. Luaran hasil peramalan dilakukan proses klasifikasi dengan metode Naive Bayes pada setiap unsur polutan yang memiliki akurasi model masing-masing yakni akurasi model CO sebesar 100%, akurasi model NO₂ sebesar 99,4%, akurasi model O₃ senilai 100%, akurasi model PM₁₀ sebesar 99.1% dan akurasi model SO₂ sebesar 99,1%. Hasil klasifikasi dari hasil peramalan menunjukkan bahwa status polusi wilayah Surabaya Timur dan Surabaya Selatan memiliki status polusi sangat tidak baik dengan presentase 100% pada tahun 2017. Sedangkan presentase status polusi sangat tidak baik pada wilayah Surabaya Pusat sebesar 80% dan sisanya memiliki status polusi sedang sebesar 19% serta status polusi tidak baik sebesar 1% pada tahun 2017. Kemudian pada penelitian tugas akhir ini juga dibuat sebuah visualisasi dashboard berbasis website agar perusahaan dapat dengan mudah membaca hasil analisis dalam bentuk grafik dan menggunakan model yang dihasilkan pada penelitian tugas akhir ini untuk meramalkan kadar polutan udara di periode selanjutnya. Penelitian tugas akhir ini diharapkan dapat menjadi salah satu elemen pendukung keputusan terkait penanganan antisipatif dalam mengatasi polusi udara yang buruk.

Kata kunci : klasterisasi, K-Means, peramalan, Artificial Neural Network, klasifikasi, Naive Bayes, kualitas udara, visualisasi dashboard berbasis web

ABSTRACT

Air quality is a serious matter that needs to be constantly monitored given the prolonged adverse effects of global warming and respiratory-related health problems. Indonesia is one country that often has poor air quality status. The city of Surabaya is one of the major cities that require surveillance related air pollutant levels. Surabaya City Environment Agency is a service that monitors air quality in some areas in Surabaya City. Reactive handling has often been done, but anticipatory treatment is more important to prevent the adverse effects of knowing pollution-prone clusters based on Surabaya conditions and predicted future air pollutant levels.

To know the point of pollution prone can use clustering technique to know the correct standard index cluster according to Surabaya City condition and then known pollution prone area in Surabaya with K-means algorithm.

Predicted air quality in the future can be done through forecasting and classification. Air quality forecasting is an effective way of protecting public health and the environment by providing early warning against air pollution. Input from forecasting is using Surabaya City air quality history data which can be analyzed using Backpropagation Neural Network method. After forecasting results are formed classification of pollution status class with Naive Bayes method to predict forecasting results to have a pollution status like what.

The results of this study resulted in clusters of pollution prone points in Surabaya, ANN forecasting model and Naive Bayes classification model. The clustering result shows the most pollution-prone areas in 2016 is the area of the air station of the South Surabaya region which is in accordance with the index of Surabaya's condition range. Output from ANN forecasting is the best model of ANN and the result of forecasting value of pollutant to know the quality in the future.

For MAPE value of ANN forecasting model consists of 3 models, namely MAPE Central Surabaya area of 24.6%, MAPE model of East Surabaya region of 34.2%, and MAPE East Surabaya area valued at 27.4%. The output of forecasting result is classification process using Naive Bayes method on each pollutant element which has the accuracy of each model that is accurate from 100% CO model, 99.2% NO2 model accuracy, 100% O3 model accuracy, PM10 model accuracy equal to 99.1% and SO2 model accuracy of 99.1%. The result of classification of forecasting result shows that the pollution status of East Surabaya and South Surabaya has very bad pollution status with 100% percentage in 2017. While the percentage of pollution status is very bad in Central Surabaya area 80% and the rest have medium pollution status 19% and bad pollution status of 1% by 2017. Then in this final project research also created a website-based dashboard visualization so that the environment department can easily read the results of analysis in the form of graphs and using the model produced in this final project to predict air pollutant levels in the next period. This final project research is expected to be one of the supporting elements of decision related to anticipatory handling in overcoming bad air pollution.

Keywords: clustering, K-Means, forecasting, Artificial Neural Network, classification, Naive Bayes, air quality, web-based dashboard visualization

KATA PENGANTAR

Puji syukur kepada Allah SWT, atas segala rahmat dan hidayah-Nya, sehingga penulis dapat menyelesaikan buku tugas akhir dengan judul :

VISUALISASI DARI KLASTERISASI DAN PERAMALAN KUALITAS UDARA SURABAYA MENGGUNAKAN METODE KLASTERISASI K-MEANS DAN PERAMALAN ARTIFICIAL NEURAL NETWORK

yang merupakan salah satu syarat kelulusan pada Jurusan Sistem Informasi, Fakultas Teknologi Informasi, Institut Teknologi Sepuluh Nopember Surabaya.

Dalam pengerjaan tugas akhir yang berlangsung selama satu semester, penulis ingin mengucapkan terima kasih yang sebesar-besarnya kepada yang senantiasa terlibat secara langsung memberikan bantuan dan dukungan dalam pengerjaan tugas akhir ini :

- Kedua orang tua yang selalu hadir senantiasa mendoakan dan memberikan kasih sayang serta semangat tiada henti untuk menyelesaikan tugas akhir ini.
- Bapak Dr. Ir. Aris Tjahyanto, M.Kom, selaku Ketua Jurusan Sistem Informasi ITS, yang telah menyediakan fasilitas terbaik untuk kebutuhan penelitian mahasiswa.
- Bapak Edwin Riksakomara, S.Kom., M.T dan Ibu Irmasari Hafidz S.Kom, M.Sc, selaku dosen pembimbing yang telah banyak meluangkan waktu untuk membimbing, mengarahkan, dan mendukung dalam penyelesaian tugas akhir.
- Teman-teman “Friendzone” yang selalu mendukung, memberikan motivasi dan memberikan semangat dalam pengerjaan tugas akhir ini.

- Febry Angga Gunawan yang selalu memberikan motivasi terhebat dan selalu mengarahkan ke cara pola pikir yang positif serta bagaimana menghargai waktu dan kemampuan diri sendiri.
- Teman-teman saya Maulana Dhawangkara, Stezar Priansya, dan Master Harun yang selalu memberikan saya pencerahan
- Teman saya Moch. Yusuf Habibi rekan sesama topik yang enak diajak *brainstorming* dan sudah banyak membantu
- Anissa Veronika Angelie dan Nabilah Sofiani satu tim hore-hore yang enak diajak diskusi dan saling bertukar ilmu
- Tetha Valianta dan Alvin Rakhman teman sepersatu bimbingan yang menghibur dan sambat-sambat humoris
- Teman-teman seperjuangan pada laboratorium RDIB, laboratorium ADDI dan BERLTRANIS, yang selalu memberikan semangatnya untuk menyelesaikan tugas akhir dengan tepat waktu.

Penulis menyadari bahwa tugas akhir ini masih belum sempurna dan memiliki banyak kekurangan di dalamnya. Oleh karena itu, kritik dan saran sangat penulis butuhkan demi kesempurnaan tugas akhir ini. Semoga buku tugas akhir ini bermanfaat bagi seluruh pembaca.

Surabaya, 2017

Penulis

DAFTAR ISI

ABSTRAK	i
ABSTRACT	iii
KATA PENGANTAR	v
DAFTAR ISI	vii
DAFTAR GAMBAR	xv
DAFTAR TABEL	xxiv
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	5
1.3 Batasan Masalah.....	5
1.4 Tujuan Tugas Akhir	6
1.5 Manfaat Tugas Akhir	7
1.6 Relevansi Tugas Akhir	7
1.7 Sistematika Penulisan.....	8
BAB II TINJAUAN PUSTAKA.....	11
2.1 Penelitian Sebelumnya	11
2.2 Dasar Teori.....	18
2.2.1 Air Quality Management Kota Surabaya	18

2.2.2	Kualitas Udara	19
2.2.3	Data Meteorologi Kota Surabaya	24
2.2.4	Metode K-means <i>Clustering</i>	24
2.2.5	Uji Korelasi	26
2.2.6	Peramalan	27
2.2.7	Klasifikasi Naive Bayes.....	33
2.2.8	Uji Performa	34
BAB III METODOLOGI		39
3.1	Tahapan Metodologi.....	39
3.1.1	Studi Literatur.....	40
3.1.2	Tahapan <i>Clustering</i>	40
3.1.3	Tahapan Peramalan.....	43
3.1.4	Tahapan Klasifikasi	47
3.1.5	Tahapan Visualisasi	48
3.1.6	Analisa Hasil <i>Clustering</i> dan Peramalan	49
3.1.7	Pembuatan Buku Tugas Akhir.....	49
BAB IV PERANCANGAN		51
4.1	Pengumpulan Data.....	51
4.1.1	Parameter yang Diukur	51

4.1.2	Pemantauan Kualitas Udara Otomatis.....	52
4.2	Persiapan Data untuk <i>Clustering</i>	53
4.2.1	Interpolasi Data <i>Clustering</i>	54
4.2.2	Integrasi Data	58
4.2.3	Pembersihan Data.....	62
4.2.4	Normalisasi Min-Max	63
4.3	Persiapan Data untuk Peramalan	64
4.3.1	Interpolasi Data Peramalan	65
4.3.2	Uji Korelasi	66
4.3.3	Penentuan Data.....	67
4.3.4	Model Artificial Neural Network.....	67
4.3.5	Penentuan <i>Input Node</i>	69
4.3.6	Penentuan <i>Hidden Node</i>	70
4.3.7	Penentuan Parameter	70
4.4	Persiapan Data untuk Klasifikasi	71
BAB V IMPLEMENTASI.....		73
5.1	Lingkungan Implementasi.....	73
5.2	Persiapan Data <i>Clustering</i>	74
5.2.1	Penghapusan <i>Outlier</i> Metode Tukey.....	74

5.2.2	Normalisasi Min-Max.....	76
5.3	Clustering dengan K-Means	79
5.3.1	<i>Clustering</i> Seluruh Stasiun Pemantau di Surabaya	80
5.3.2	<i>Clustering</i> Setiap Stasiun Pemantau Udara Bagian Surabaya Pusat, Surabaya Timur dan Surabaya Selatan	83
5.4	Uji Performa <i>Clustering</i>	92
5.4.1	Sum Square Error (SSE).....	93
5.4.1	Dunn Index	95
5.4.2	Silhouette.....	97
5.5	Persiapan Data Peramalan	99
5.5.1	Interpolasi Data Meteorologi.....	99
5.5.2	Uji Korelasi Data Meteorologi terhadap Data Polutan Udara	100
5.6	Peramalan dengan Artificial Neural Network	101
5.6.1	Pembuatan Model Peramalan ANN.....	101
5.6.2	Penerapan Model Peramalan ANN.....	103
5.7	Klasifikasi dengan Metode Naive Bayes	104
5.7.1	Pembuatan Model Klasifikasi.....	105

5.7.2	Penerapan Model Klasifikasi.....	107
5.8	Visualisasi Dashboard.....	109
5.8.1	<i>Leaflet Map</i>	109
5.8.2	<i>Calendar Heatmap</i>	110
5.8.3	<i>Doughnut Chart</i>	111
5.8.4	Box Plot.....	113
5.8.5	<i>Bar Chart</i>	113
5.8.6	<i>Line Chart</i>	114
5.8.7	Shiny Dashboard	115
BAB VI HASIL DAN PEMBAHASAN		121
6.1	Perbandingan Performa Setiap Model <i>Clustering</i>	121
6.1.1	Model 1 - Hasil <i>Clustering</i> Seluruh Wilayah Surabaya	121
6.1.2	Model 2 - Hasil <i>clustering</i> wilayah Surabaya Pusat	122
6.1.3	Model 3 - Hasil <i>clustering</i> wilayah Surabaya Timur	123
6.1.4	Model 4 - Hasil <i>clustering</i> wilayah Surabaya Selatan	123
6.3	Analisis Hasil <i>Clustering</i>	126

6.3.1	Unsur CO.....	126
6.3.2	Unsur NO ₂	131
6.3.3	Unsur O ₃	135
6.3.4	Unsur PM ₁₀	140
6.3.5	Unsur SO ₂	145
6.3.6	Perbandingan Titik Rawan Polusi Setiap Bagian Wilayah Surabaya.....	149
6.4	Pembuatan Model Klasifikasi dengan Metode Naive Bayes	150
6.4.1	Klasifikasi Unsur Karbon Monoksida.....	150
6.4.2	Klasifikasi Unsur Nitrogen Dioksida.....	152
6.4.3	Klasifikasi Unsur Ozon.....	153
6.4.4	Klasifikasi Unsur Partikulat Matter.....	154
6.4.5	Klasifikasi Unsur Sulfur Dioksida.....	156
6.5	Analisis Uji Korelasi.....	158
6.6	Analisis Hasil Peramalan.....	159
6.6.1	Pembentukan Model.....	159
6.6.2	Hasil Perbandingan Model.....	189
6.6.3	Hasil Peramalan dari Penerapan Model.....	194
6.7	Klasifikasi Hasil Peramalan.....	209

6.7.1	Klasifikasi Hasil Peramalan Wilayah Surabaya Pusat	210
6.7.2	Klasifikasi Hasil Peramalan Wilayah Surabaya Timur	211
6.7.3	Klasifikasi Hasil Peramalan Wilayah Surabaya Selatan	213
6.8	Analisis Hasil Visualisasi.....	215
6.8.1	<i>Leaflet Map</i> Status Polusi.....	215
6.8.2	<i>Calendar Heatmap</i> Status Polusi	215
6.8.3	Box Plot Rentang Index <i>Cluster</i>	218
6.8.4	Doughnut Chart Persentase Status Polusi	221
6.8.5	<i>Bar Chart</i> Prediksi Klasifikasi Status Polusi	223
6.9	Kesimpulan Hasil Percobaan	223
6.9.1	Kesimpulan Hasil Percobaan <i>Clustering</i>	226
6.9.2	Kesimpulan Hasil Percobaan Peramalan.....	227
6.9.3	Kesimpulan Hasil Percobaan Klasifikasi	228
BAB VII KESIMPULAN DAN SARAN		229
7.1	Kesimpulan	229
7.2	Saran.....	230
DAFTAR PUSTAKA		231

BIODATA PENULIS.....	235
LAMPIRAN A	A-1
LAMPIRAN B.....	B-1
LAMPIRAN C.....	C-1
LAMPIRAN D	B-1

DAFTAR GAMBAR

Gambar 2.1 Indeks Standar Pencemar Udara (ISPU) [14].....	20
Gambar 2.2 Jaringan Syaraf Manusia [20].....	28
Gambar 2.3. Jaringan syaraf tiruan (Artificial Neural Network) [20]	28
Gambar 2.4. Arsitektur jaringan syaraf tiruan (Artificial Neural Network) [18].....	30
Gambar 2.5. Backpropagation Neural Network dengan satu hidden layer [20]	31
Gambar 3.1 Metodologi Pengerjaan Secara Umum	39
Gambar 3.2. Rincian Metodologi Pengerjaan Tahap <i>Clustering</i>	40
Gambar 3.3. Kerangka Kerja Teknis Tahap <i>Clustering</i>	41
Gambar 3.4. Rincian Metodologi Tahap Peramalan	43
Gambar 3.5. Kerangka Kerja Teknis Tahap Peramalan	43
Gambar 3.6 Rincian Metodologi Tahap Klasifikasi.....	47
Gambar 3.7 Rincian Metodologi Tahap Visualisasi	48
Gambar 4.1 Dokumentasi yang diperoleh dari Badan Lingkungan Hidup Surabaya.....	53
Gambar 4.2 Laporan harian kualitas udara Kota Surabaya untuk tiap parameter	53
Gambar 4.3 Kerangka kerja proses persiapan data untuk <i>Clustering</i>	54
Gambar 4.4 Data mentah laporan harian kualitas udara	54

Gambar 4.5 Proses interpolasi menggunakan SPSS.....	54
Gambar 4.6 Fungsi Multiple Imputation	55
Gambar 4.7 Penentuan Variabel untuk Multiple Imputation..	55
Gambar 4.8 Penentuan Method pada fitur Multiple Imputation	55
Gambar 4.9 Pengaturan constraint fungsi multiple imputation pada SPSS.....	56
Gambar 4.10 Hasil interpolasi menggunakan multiple imputation di SPSS.....	57
Gambar 4.11 Hasil interpolasi ke format excel	57
Gambar 4.12 Integrasi data untuk proses <i>clustering</i>	58
Gambar 4.13 Folder data hasil interpolasi.....	59
Gambar 4.14 File hasil interpolasi setiap parameter dalam setiap bulan	59
Gambar 4.15 File hasil interpolasi Bulan Januari pada setiap parameter	59
Gambar 4.16 Data integrasi 5 parameter kualitas udara di Surabaya (semua stasiun pemantau).....	60
Gambar 4.17 Integrasi Data pada Stasiun Pemantau Wilayah Surabaya Pusat (SUF1-Taman Prestasi).....	61
Gambar 4.18 Integrasi Data pada Stasiun Pemantau Wilayah Surabaya Timur (SUF 6-Wonorejo).....	61
Gambar 4.19 Integrasi Data pada Stasiun Pemantau Wilayah Surabaya Selatan (SUF 7-Kebonsari).....	62

Gambar 4.20 Penghapusan <i>outlier</i> yakni pembersihan untuk proses <i>clustering</i>	62
Gambar 4.21 Kerangka kerja normalisasi data untuk clustering	64
Gambar 4.22 Kerangka kerja proses persiapan data peramalan	65
Gambar 4.23 Proporsi data <i>missing</i> pada data meteorologi ...	66
Gambar 4.24 Model <i>Artificial Neural Network</i>	68
Gambar 4.25 Kerangka kerja proses persiapan data klasifikasi	71
Gambar 4.26 Tabel data persiapan klasifikasi.....	72
Gambar 5.1 Deteksi outlier metode Tukey pada R	75
Gambar 5.2 Data outlier hasil penghapusan outlier dengan metode Tukey	75
Gambar 5.3 Penghilangan baris data not available hasil penghapusan nilai outlier	76
Gambar 5.4 Data siap untuk normalisasi.....	77
Gambar 5.5 Data hasil normalisasi min-max seluruh stasiun pemantau udara Surabaya.....	78
Gambar 5.6 Data hasil normalisasi min-max pada stasiun pemantau udara wilayah Surabaya Pusat	79
Gambar 5.7 Histogram perbandingan data tanpa normalisasi dengan data normalisasi pada stasiun pemantau udara bagian Surabaya Pusat (Suf1-Taman Prestasi)	79

Gambar 5.8 Hasil titik centroid pada setiap cluster dari data normalisasi.....81

Gambar 5.9 Tabel hasil clustering 5 parameter pada seluruh stasiun pemantau udara di Surabaya.....82

Gambar 5.10 Hasil titik centroid pada setiap cluster parameter CO di seluruh Surabaya dari data normalisasi.....83

Gambar 5.11 Tabel hasil clustering parameter CO pada seluruh stasiun pemantau udara di Surabaya.....83

Gambar 5.12 Hasil titik centroid pada setiap cluster dari data normalisasi lima parameter di Surabaya Pusat (suf1).....84

Gambar 5.13 Tabel hasil clustering 5 parameter pada stasiun pemantau udara di Surabaya Pusat (suf1).....85

Gambar 5.14 Hasil titik centroid pada setiap cluster parameter CO pada Surabaya Pusat (suf1) dari data normalisasi.....86

Gambar 5.15 Tabel hasil clustering parameter CO pada stasiun pemantau Surabaya bagian pusat (Suf1-Taman Prestasi).....86

Gambar 5.16 Hasil titik centroid pada setiap cluster parameter NO2 pada Surabaya bagian Pusat (suf1-Taman Prestasi)87

Gambar 5.17 Tabel hasil clustering parameter NO2 pada stasiun pemantau udara Surabaya Pusat (suf1-Taman Prestasi).....88

Gambar 5.18 Hasil titik centroid pada setiap cluster parameter O3 di wilayah Surabaya bagian pusat (suf1-Taman Prestasi) 89

Gambar 5.19 Tabel hasil clustering parameter O3 pada stasiun pemantau udara wilayah Surabaya bagian pusat89

Gambar 5.20 Hasil titik centroid pada setiap cluster parameter PM10 pada Surabaya bagian Pusat (suf1-Taman Prestasi)	90
Gambar 5.21 Tabel hasil clustering parameter PM10 pada stasiun pemantau wilayah Surabaya Pusat (suf1-Taman Prestasi).....	91
Gambar 5.22 Hasil titik centroid pada setiap cluster parameter SO2 pada stasiun pemantau Surabaya Pusat	92
Gambar 5.23 Tabel hasil clustering parameter SO2 pada stasiun pemantau udara wilayah Surabaya Pusat	92
Gambar 5.24 Objek data pada R	93
Gambar 5.25 Tabel hasil nilai SSE	94
Gambar 5.26 Hasil perbandingan nilai SSE pada R.....	95
Gambar 5.27 Hasil <i>internal validation clustering</i> menggunakan <i>clValid</i> pada R.....	96
Gambar 5.28 Validasi internal Indeks Dunn	97
Gambar 5.29 Rangkuman hasil uji performa <i>silhouette index</i>	98
Gambar 5.30 Validasi internal <i>silhouette</i>	98
Gambar 5.31 <i>Confussion Matrix</i> Model 1 Unsur PM10	107
Gambar 5.32 Uji Akurasi Model pada Data <i>Training</i> dan <i>Testing</i> Model 1 Unsur PM10	107
Gambar 5.33 Hasil Prediksi Kelas pada Setiap Unsur Polutan Udara untuk Wilayah Surabaya Pusat	108
Gambar 5.34 Komponen Visualisasi <i>Leaflet Map</i>	110
Gambar 5.35 Komponen Visualisasi <i>Calendar Heatmap</i>	111

Gambar 5.36 Komponen visualisasi <i>donut chart</i> Wilayah Surabaya Selatan	112
Gambar 5.37 Box Plot Rentang Indeks Cluster Wilayah Surabaya	113
Gambar 5.38 Komponen Visualisasi <i>Bar Chart</i> untuk Klasifikasi.....	114
Gambar 5.39 Komponen Visualisasi <i>Line Chart</i> untuk Peramalan	114
Gambar 5.40 Komponen Visual <i>Leaflet Map</i> pada Menu Dashboard.....	115
Gambar 5.41 Komponen Visual <i>Calendar Heatmap</i> pada Menu Dashboard.....	116
Gambar 5.42 Komponen Visual <i>Donut Chart</i> pada Menu Dashboard.....	116
Gambar 5.43 Sub Menu Klasifikasi Setiap Unsur Polutan dengan Komponen Visual <i>Bar Chart</i>	117
Gambar 5.44 Sub Menu Klasifikasi Seluruh Unsur Polutan dengan Komponen Visual <i>Bar Chart</i>	117
Gambar 5.45 Menu Peramalan Menggunakan Komponen Visual <i>Line Chart</i>	118
Gambar 5.46 Sub Menu Data Aktual pada Menu Data Tabel	118
Gambar 5.47 Sub Menu Data <i>Clustering</i> pada Menu Data Tabel	119

Gambar 5.48 Sub Menu Data Prediksi pada Menu Data Tabel	119
Gambar 6.1 Hasil Peramalan 5 Unsur Polutan Udara Wilayah Surabaya Pusat	195
Gambar 6.2 Plot grafik peramalan unsur polutan Karbon Monoksida wilayah Surabaya Pusat.....	196
Gambar 6.3 Plot grafik peramalan unsur polutan Nitrogen Dioksida wilayah Surabaya Pusat	197
Gambar 6.4 Plot grafik peramalan unsur polutan Ozon wilayah Surabaya Pusat	197
Gambar 6.5 Plot grafik peramalan unsur polutan Partikulat Matter wilayah Surabaya Pusat	198
Gambar 6.6 Plot grafik peramalan unsur polutan Sulfur Dioksida wilayah Surabaya Pusat	198
Gambar 6.7 Hasil Peramalan 5 Unsur Polutan Udara Wilayah Surabaya Timur	199
Gambar 6.8 Plot grafik peramalan unsur polutan Karbon Monoksida wilayah Surabaya Timur	201
Gambar 6.9 Plot grafik peramalan unsur polutan Nitrogen Dioksida wilayah Surabaya Timur	201
Gambar 6.10 Plot grafik peramalan unsur polutan Ozon wilayah Surabaya Timur	202
Gambar 6.11 Plot grafik peramalan unsur polutan Partikulat Matter wilayah Surabaya Timur.....	203

Gambar 6.12 Plot grafik peramalan unsur polutan Sulfur Dioksida wilayah Surabaya Timur	204
Gambar 6.13 Hasil Peramalan 5 Unsur Polutan Udara Wilayah Surabaya Selatan	205
Gambar 6.14 Plot grafik peramalan unsur polutan Karbon Monoksida wilayah Surabaya Timur.....	206
Gambar 6.15 Plot grafik peramalan unsur polutan Nitrogen Dioksida wilayah Surabaya Selatan	207
Gambar 6.16 Plot grafik peramalan unsur polutan Ozon wilayah Surabaya Selatan	207
Gambar 6.17 Plot grafik peramalan unsur polutan Partikulat Matter wilayah Surabaya Selatan	208
Gambar 6.18 Plot grafik peramalan unsur polutan Sulfur Dioksida wilayah Surabaya Selatan	209
Gambar 6.19 Persentase Status Polusi Hasil Peramalan Wilayah Surabaya Pusat.....	211
Gambar 6.20 Persentase Status Polusi Hasil Peramalan Wilayah Surabaya Timur	213
Gambar 6.21 Persentase Status Polusi Hasil Peramalan Wilayah Surabaya Selatan	214
Gambar 6.22 Interpretasi <i>Leaflet Map</i> Status Polusi	215
Gambar 6.23 <i>Calendar Heatmap</i> status polusi Wilayah Surabaya Pusat.....	216

Gambar 6.24 <i>Calendar Heatmap</i> status polusi Wilayah Surabaya Timur	217
Gambar 6.25 <i>Calendar Heatmap</i> status polusi Wilayah Surabaya Selatan	217
Gambar 6.26 Interpretasi <i>Box Plot</i>	218
Gambar 6.27 <i>Box Plot</i> Rentang Indeks Unsur Polutan CO..	218
Gambar 6.28 <i>Box Plot</i> Rentang Indeks Unsur Polutan NO ₂	219
Gambar 6.29 <i>Box Plot</i> Rentang Indeks Unsur Polutan O ₃ ..	219
Gambar 6.30 <i>Box Plot</i> Rentang Indeks Unsur Polutan PM ₁₀	220
Gambar 6.31 <i>Box Plot</i> Rentang Indeks Unsur Polutan SO ₂	220
Gambar 6.32 <i>Doughnut chart</i> persentase status polusi Wilayah Surabaya Pusat	221
Gambar 6.33 <i>Doughnut chart</i> persentase status polusi Wilayah Surabaya Timur	222
Gambar 6.34 <i>Doughnut chart</i> persentase status polusi Wilayah Surabaya Selatan	222
Gambar 6.35 Interpretasi Hasil Visual <i>Bar Chart</i> Prediksi Klasifikasi Status Polusi Udara	223

DAFTAR TABEL

Tabel 2.1. Perbandingan Penelitian Sebelumnya	11
Tabel 2.2.....	18
Tabel 2.3. Parameter Polutan Udara yang Diukur.....	21
Tabel 2.4. Atribut Dataset Meteorologi.....	24
Tabel 2.5 Interpretasi Uji Korelasi	26
Tabel 2.6 Interpretasi Kemampuan Model Peramalan Berdasarkan Nilai MAPE.....	37
Tabel 4.1 Parameter yang digunakan	52
Tabel 4.2 Lokasi stasiun pemantauan Kualitas Udara di Kota Surabaya	52
Tabel 4.3 Tabel jumlah <i>input node</i> setiap periode waktu.....	69
Tabel 5.1 Lingkungan Perangkat Keras Implementasi.....	73
Tabel 5.2 Lingkungan Perangkat Lunak Implementasi.....	73
Tabel 5.3 Ringkasan Percobaan Clustering.....	80
Tabel 6.1 Performa nilai Model 1 (clustering seluruh wilayah Surabaya).....	121
Tabel 6.2 Performa nilai model 2 (clustering wilayah Surabaya Pusat).....	122
Tabel 6.3 Performa nilai model 3 (clustering wilayah Surabaya Timur).....	123
Tabel 6.4 Performa nilai model 4 (clustering wilayah Surabaya Selatan).....	124
Tabel 6.5 Tabel perbandingan performa setiap model	125

Tabel 6.6 Ringkasan perbandingan performa model 1 (seluruh wilayah Surabaya) dan model 2,3,4 (setiap bagian wilayah Surabaya) pada masing-masing parameter.....	125
Tabel 6.7 Hasil <i>Clustering</i> Unsur CO	126
Tabel 6.8 Karakterisasi <i>Cluster</i> Unsur CO untuk Wilayah Surabaya Pusat	126
Tabel 6.9 Karakterisasi Cluster Unsur CO untuk Wilayah Surabaya Timur	128
Tabel 6.10 Karakterisasi Cluster Unsur CO untuk Wilayah Surabaya Selatan	129
Tabel 6.11 Perbandingan Status Polusi Unsur CO pada Setiap Bagian Wilayah Surabaya	130
Tabel 6.12 Hasil <i>Clustering</i> Unsur NO ₂	131
Tabel 6.13 Karakterisasi Cluster Unsur NO ₂ untuk Wilayah Surabaya Pusat	131
Tabel 6.14 Karakterisasi Cluster Unsur NO ₂ untuk Wilayah Surabaya Timur	132
Tabel 6.15 Karakterisasi Cluster Unsur NO ₂ untuk Wilayah Surabaya Selatan	134
Tabel 6.16 Perbandingan Status Polusi Unsur NO ₂ pada Setiap Bagian Wilayah Surabaya	135
Tabel 6.17 Hasil <i>Clustering</i> Unsur O ₃	135
Tabel 6.18 Karakterisasi Cluster Unsur O ₃ untuk Wilayah Surabaya Pusat	136

Tabel 6.19 Karakterisasi Cluster Unsur O ₃ untuk Wilayah Surabaya Timur	137
Tabel 6.20 Karakterisasi Cluster Unsur O ₃ untuk Wilayah Surabaya Selatan	138
Tabel 6.21 Perbandingan Status Polusi Unsur O ₃ pada Setiap Bagian Wilayah Surabaya	140
Tabel 6.22 Hasil <i>Clustering</i> Unsur PM ₁₀	140
Tabel 6.23 Karakterisasi Cluster Unsur PM ₁₀ untuk Wilayah Surabaya Pusat.....	140
Tabel 6.24 Karakterisasi <i>Cluster</i> Unsur PM ₁₀ untuk Wilayah Surabaya Timur	142
Tabel 6.25 Karakterisasi <i>Cluster</i> Unsur PM ₁₀ untuk Wilayah Surabaya Selatan	143
Tabel 6.26 Perbandingan Status Polusi Unsur PM ₁₀ pada Setiap Bagian Wilayah Surabaya	144
Tabel 6.27 Justifikasi Kelompok Hasil <i>Clustering</i> Unsur SO ₂	145
Tabel 6.28 Karakterisasi Cluster Unsur SO ₂ untuk Wilayah Surabaya Pusat.....	145
Tabel 6.29 Karakterisasi Cluster Unsur SO ₂ untuk Wilayah Surabaya Timur	147
Tabel 6.30 Karakterisasi Cluster Unsur SO ₂ untuk Wilayah Surabaya Selatan	148

Tabel 6.31 Perbandingan Status Polusi Unsur SO ₂ pada Setiap Bagian Wilayah Surabaya	149
Tabel 6.32 Perbandingan Rawan Polusi Pada Setiap Unsur Polutan dan Setiap Wilayah Surabaya	150
Tabel 6.33 Perbandingan Akurasi Model Unsur Karbon Monoksida (CO).....	151
Tabel 6.34 Confussion matrix data testing unsur polutan udara CO	151
Tabel 6.35 Statistik Hasil Klasifikasi dengan data testing 20% unsur polutan CO	152
Tabel 6.36 Perbandingan Akurasi Model Unsur Nitrogen Dioksida (NO ₂).....	152
Tabel 6.37 Confussion matrix data testing unsur polutan udara NO ₂	153
Tabel 6.38 Statistik Hasil Klasifikasi dengan data testing 30% unsur polutan NO ₂	153
Tabel 6.39 Perbandingan Akurasi Model Unsur Ozon (O ₃)	154
Tabel 6.40 Confussion matrix data testing unsur polutan udara O ₃	154
Tabel 6.41 Perbandingan Akurasi Model Unsur Partikulat Matter (PM ₁₀).....	155
Tabel 6.42 Confussion matrix data testing unsur polutan udara PM ₁₀	155

Tabel 6.43 Statistik Hasil Klasifikasi dengan data testing 30% unsur polutan PM10	156
Tabel 6.44 Perbandingan Akurasi Model Unsur Sulfur Dioksida (SO ₂)	157
Tabel 6.45 Confussion matrix data testing unsur polutan udara SO ₂	157
Tabel 6.46 Statistik Hasil Klasifikasi dengan data testing 30% unsur polutan SO ₂	158
Tabel 6.47 Hasil uji korelasi data meteorologi terhadap data polutan udara	158
Tabel 6.48 Hasil Percobaan Model 1 periode 5 <i>Nodes Input</i> Stasiun Surabaya Pusat.....	160
Tabel 6.49 Hasil Percobaan Model 1 periode 5 <i>Nodes Input</i> Stasiun Surabaya Timur	161
Tabel 6.50 Hasil Percobaan Model 1 periode 5 <i>Nodes Input</i> Stasiun Surabaya Selatan.....	162
Tabel 6.51 Hasil Percobaan Model 2 periode 10 <i>Nodes Input</i> Stasiun Surabaya Pusat.....	163
Tabel 6.52 Hasil Percobaan Model 2 periode 10 <i>Nodes Input</i> Stasiun Surabaya Timur	164
Tabel 6.53 Hasil Percobaan Model 2 periode 10 <i>Nodes Input</i> Stasiun Surabaya Selatan.....	165
Tabel 6.54 Hasil Percobaan Model 3 periode 15 <i>Nodes Input</i> Stasiun Surabaya Pusat.....	166

Tabel 6.55 Hasil Percobaan Model 3 periode 15 <i>Nodes Input</i> Stasiun Surabaya Timur	167
Tabel 6.56 Hasil Percobaan Model 3 periode 15 <i>Nodes Input</i> Stasiun Surabaya Selatan	168
Tabel 6.57 Hasil Percobaan Model 4 periode 20 <i>Nodes Input</i> Stasiun Surabaya Pusat	169
Tabel 6.58 Hasil Percobaan Model 4 periode 20 <i>Nodes Input</i> Stasiun Surabaya Timur	170
Tabel 6.59 Hasil Percobaan Model 4 periode 20 <i>Nodes Input</i> Stasiun Surabaya Selatan	171
Tabel 6.60 Hasil Percobaan Model 5 periode 25 <i>Nodes Input</i> Stasiun Surabaya Pusat	172
Tabel 6.61 Hasil Percobaan Model 5 periode 25 <i>Nodes Input</i> Stasiun Surabaya Timur	173
Tabel 6.62 Hasil Percobaan Model 5 periode 25 <i>Nodes Input</i> Stasiun Surabaya Selatan	174
Tabel 6.63 Hasil Percobaan Model 6 periode 30 <i>Nodes Input</i> Stasiun Surabaya Pusat	175
Tabel 6.64 Hasil Percobaan Model 6 periode 30 <i>Nodes Input</i> Stasiun Surabaya Timur	176
Tabel 6.65 Hasil Percobaan Model 6 periode 30 <i>Nodes Input</i> Stasiun Surabaya Selatan	177
Tabel 6.66 Hasil Percobaan Model 7 periode 35 <i>Nodes Input</i> Stasiun Surabaya Pusat	178

Tabel 6.67 Hasil Percobaan Model 7 periode 35 Nodes Input Stasiun Surabaya Timur	179
Tabel 6.68 Hasil Percobaan Model 7 periode 35 Nodes Input Stasiun Surabaya Selatan.....	180
Tabel 6.69 Hasil Percobaan Model 8 periode 40 Nodes Input Stasiun Surabaya Pusat.....	181
Tabel 6.70 Hasil Percobaan Model 8 periode 40 Nodes Input Stasiun Surabaya Timur	182
Tabel 6.71 Hasil Percobaan Model 8 periode 40 Nodes Input Stasiun Surabaya Selatan.....	183
Tabel 6.72 Hasil Percobaan Model 9 periode 45 Nodes Input Stasiun Surabaya Pusat.....	184
Tabel 6.73 Hasil Percobaan Model 9 periode 45 Nodes Input Stasiun Surabaya Timur	185
Tabel 6.74 Hasil Percobaan Model 9 periode 45 Nodes Input Stasiun Surabaya Selatan.....	186
Tabel 6.75 Hasil Percobaan Model 10 periode 50 Nodes Input Stasiun Surabaya Pusat.....	187
Tabel 6.76 Hasil Percobaan Model 10 periode 50 Nodes Input Stasiun Surabaya Timur	188
Tabel 6.77 Hasil Percobaan Model 10 periode 50 Nodes Input Stasiun Surabaya Selatan.....	189
Tabel 6.78 Perbandingan MAPE <i>training</i> dan <i>testing</i> untuk Model Stasiun Pemantau Wilayah Surabaya Pusat	190

Tabel 6.79 Perbandingan MAPE <i>training</i> dan <i>testing</i> untuk Model Stasiun Pemantau Wilayah Surabaya Timur.....	191
Tabel 6.80 Perbandingan MAPE <i>training</i> dan <i>testing</i> untuk Model Stasiun Pemantau Wilayah Surabaya Selatan.....	193
Tabel 6.81 Ringkasan Hasil Peramalan Unsur Polutan Wilayah Surabaya Pusat	195
Tabel 6.82 Ringkasan Hasil Peramalan Unsur Polutan Wilayah Surabaya Timur	200
Tabel 6.83 Ringkasan Hasil Peramalan Unsur Polutan Wilayah Surabaya Selatan	205
Tabel 6.84 Klasifikasi Hasil Peramalan Wilayah Surabaya Pusat	210
Tabel 6.85 Klasifikasi Hasil Peramalan Wilayah Surabaya Timur.....	212
Tabel 6.86 Klasifikasi Hasil Peramalan Wilayah Surabaya Selatan.....	214

BAB I

PENDAHULUAN

Pada bab pendahuluan akan diuraikan proses identifikasi masalah penelitian yang meliputi latar belakang masalah, perumusan masalah, batasan masalah, tujuan tugas akhir, dan manfaat kegiatan tugas akhir. Berdasarkan uraian pada bab ini, diharapkan gambaran umum permasalahan dan pemecahan masalah pada tugas akhir dapat dipahami.

1.1 Latar Belakang

Polusi atau pencemaran udara merupakan perubahan komposisi dari zat udara sehingga kualitas udara dari zat tersebut menjadi berkurang atau tidak bisa lagi digunakan sesuai fungsinya [1]. Kualitas udara yang telah tercemar umumnya mengandung zat udara pencemar dengan komposisi seperti CO_x , NO_x , SO_x , SPM (*suspended particular matter*), O_x , dan berbagai logam berat. Tingkat konsentrasi zat pencemar yang berlebihan hingga melampaui ambang batas toleransi yang diperkenankan akan memberikan dampak negatif yang berbahaya terhadap lingkungan, baik bagi manusia, tumbuh-tumbuhan, hewan, dan rusaknya benda-benda (material) serta berpengaruh pada kualitas air hujan (hujan asam) [2]. Kualitas udara yang buruk atau polusi udara yang secara terus menerus tinggi dapat berdampak buruk bagi bumi dan juga kesehatan. Dampak negatif jangka panjang dari kualitas udara yang buruk adalah penipisan ozon yang memicu pemanasan global, sedangkan dampak jangka pendek yang langsung ke manusia adalah masalah kesehatan pernafasan [3]. Oleh karena itu kualitas udara menjadi suatu hal yang penting untuk perlu selalu dipantau.

WHO telah membuat model kualitas udara baru tahun 2016 yang menegaskan bahwa 92% dari populasi dunia tinggal di tempat di mana tingkat kualitas udara melebihi batas toleransi. Model tersebut didasarkan pada data yang diperoleh dari pengukuran satelit, model transportasi udara dan monitor

stasiun tanah selama lebih dari 3000 lokasi [4]. Sedangkan di Indonesia sendiri seringkali terjadi kebakaran hutan dan peningkatan populasi kendaraan bermotor sebesar 81% pada tahun 2012 memicu peningkatan gas CO₂ yang mempengaruhi kualitas udara [5]. Oleh karena itu kualitas udara di Indonesia perlu selalu dipantau sebagai pengendalian untuk tindakan pencegahan dampak negatif dari kualitas udara yang buruk.

Pemantauan dan pengelolaan kualitas udara di Indonesia dilakukan oleh Kementerian Lingkungan Hidup melalui sistem yang disebut dengan *Air Quality Management System (AQMS)*. AQMS telah diterapkan pada 10 kota di Indonesia, yaitu Jakarta, Bandung, Semarang, Surabaya, Denpasar, Medan, Pekanbaru, Palangkaraya, Jambi, dan Pontianak. Setiap kota dilengkapi dengan stasiun tetap *monitoring*, stasiun pemantauan ponsel, pusat regional dan pusat kalibrasi regional. Kementerian Lingkungan Hidup juga menyediakan informasi mengenai kualitas udara yang dikelola oleh Badan Pengelola Lingkungan Hidup Daerah.

Salah satu Badan Lingkungan Hidup (BLH) Daerah yang ada di Jawa Timur yakni Kota Surabaya. BLH Surabaya selalu melakukan pemantauan kualitas udara setiap hari dan juga memberikan informasi kualitas udara ke masyarakat melalui beberapa stasiun *public display data* di jalan-jalan sekitar Surabaya. Adanya penyebaran informasi melalui *public display* diharapkan mampu memberikan penyadaran kepada penduduk Surabaya terhadap kondisi kekinian kualitas udara di Surabaya. Namun *public display* hanya terdapat di lokasi-lokasi tertentu yang tidak bisa dilihat kapan saja oleh masyarakat. Visualisasi kualitas udara perlu dipublikasikan tidak sebatas di jalan-jalan, namun perlu juga dipublikasikan melalui situs berbasis website yang dapat diakses masyarakat kapan pun. Sehingga diharapkan penduduk Surabaya mengerti dan mampu melakukan pencegahan untuk meminimalisir emisi gas dari penggunaan

kendaraan bermotor, pembakaran limbah, dan pembuangan gas dari pabrik.

Pengendalian sebagai pencegahan akan dampak kualitas udara Kota Surabaya juga perlu ditetapkan sebagai prioritas yang harus dilakukan oleh Badan Lingkungan Hidup Kota Surabaya. Tindakan pencegahan oleh BLH dapat dilakukan dengan mengetahui bagaimana kualitas udara ke depan dan mengetahui titik rawan polusi di Kota Surabaya.

Pengendalian yang pertama adalah dengan mengetahui titik rawan polusi di Kota Surabaya yang dapat dilakukan ketika indeks standar kualitas telah terklaster sesuai dengan kondisi Kota Surabaya. Untuk mengetahui hal tersebut diperlukan pengukuran terhadap kualitas udara yang dimodelkan dengan melakukan klasterisasi daerah ke dalam kelas tertentu berdasarkan keadaan polusi udara. Pada penelitian ini menggunakan metode *unsupervised* dimana metode tersebut mampu menggambarkan kesesuaian untuk mempelajari, melakukan generalisasi, dan pemodelan relasi non linear. Proses *clustering* memerlukan penentuan jumlah klaster yang optimal. Namun pada penelitian ini ditentukan jumlah klaster sesuai dengan standar kebijakan *Air Quality Index* yakni sebanyak enam klaster yang digunakan untuk memproses *clustering*. Keluaran yang dihasilkan dari proses *clustering* mampu direpresentasikan dengan lokasi daerah stasiun pemantauan udara, waktu dan pengelompokan terhadap kelas tertentu. Desain parameter terbentuk berdasarkan polutan-polutan tertentu yang menjadi faktor yang berpengaruh terhadap kualitas udara. Terdapat beberapa parameter yang tidak terpilih dimana menunjukkan korelasi yang lemah dengan parameter lainnya. Sehingga didapatkan data dimana menunjukkan karakteristik daerah berdasarkan parameter tertentu [6].

Pengendalian yang kedua dapat dilakukan ketika mengetahui kualitas udara Kota Surabaya di masa depan melalui proses peramalan. Peramalan kualitas udara adalah untuk mendapatkan hasil kualitas udara ke depan dengan parameter Partikulat (PM_{10}), Sulfur Dioksida (SO_2), Carbon Monoksida (CO), Ozon (O_3) dan Nitrogen Dioksida (NO_2) yang kemudian diketahui hasil status kualitas udara di masa depan. Masukan dari proses peramalan adalah berupa data meteorologi seperti suhu udara, tekanan udara stasiun, kecepatan angin, visibilitas serta menggunakan data historis laporan harian konsentrasi polutan dari BLH Kota Surabaya. Metode yang digunakan dalam proses peramalan adalah Metode Artificial Neural Network. Sebagian besar penelitian sebelumnya mengenai peramalan kualitas udara menggunakan metode Artificial Neural Network memiliki tingkat error yang lebih kecil dibandingkan dengan metode lain [7]. Metode *Artificial Neural Network* merupakan jaringan yang terdiri atas sekelompok unit pemroses yang dimodelkan yang menyerupai jaringan saraf manusia dengan melakukan pembenaran pada bobot dan *bias* berdasarkan *error* yang terjadi. Setelah itu akan didapat *neural network* yang baik dan siap untuk melakukan proses yang berulang-ulang [8]. Hasil dari proses peramalan dengan metode ANN kemudian diketahui bagaimana ISPU (Indeks Standar Pencemar Udara) di masa depan, sehingga dapat mendorong pengendalian dengan tindakan pencegahan melalui penetapan kebijakan.

Tujuan penelitian tugas akhir ini yaitu membuat model peramalan dengan metode *Artificial Neural Network* (ANN) yang dapat meramalkan kualitas udara di Kota Surabaya ke depan dan memperoleh klaster titik rawan polusi di Kota Surabaya dengan metode K-means. Hasil keduanya kemudian divisualisasikan pada dashboard berbasis web melalui *R Shiny*.

Oleh karena itu harapan penulis dengan adanya hasil penelitian serta visualisasinya diharapkan mampu merepresentasikan

bagaimana kualitas udara dan titik rawan polusi di wilayah kota Surabaya. Sehingga mampu menjadi gambaran situasi kualitas udara saat ini dan ke depan dalam membantu instansi pemerintahan bahan acuan dalam proses pengambilan keputusan serta pengendalian untuk tindakan pencegahan Kota Surabaya melalui penetapan kebijakan.

1.2 Rumusan Masalah

Berdasarkan uraian latar belakang di atas, maka rumusan permasalahan yang menjadi fokus dan yang akan diselesaikan dalam Tugas Akhir ini antara lain :

1. Bagaimana metode K-Means dapat diterapkan dalam melakukan *clustering* kualitas udara berdasarkan parameter-parameter tertentu yang ada di stasiun pemantau kualitas udara di Kota Surabaya?
2. Bagaimana metode *Artificial Neural Network* dapat diterapkan dalam melakukan peramalan kualitas udara Kota Surabaya?
3. Bagaimana melakukan visualisasi model klasterisasi dan peramalan terbaik dari kualitas udara Kota Surabaya menjadi aplikasi berbasis web?

1.3 Batasan Masalah

Dari perumusan masalah yang telah dipaparkan sebelumnya, maka yang menjadi batasan dalam tugas akhir ini adalah sebagai berikut:

1. Klasterisasi yang dilakukan berfokus pada kluster indeks kualitas udara atau titik daerah polusi di beberapa stasiun pemantau kualitas udara Kota Surabaya, sedangkan peramalan berfokus pada status indeks pencemar polutan udara ke depan dimana kedua proses dilakukan secara terpisah dan berurutan.
2. Data yang akan digunakan pada pengerjaan klasterisasi adalah data 5 zat partikulat kualitas udara yang meliputi Karbon Monoksida (CO), Partikulat (PM₁₀), Nitrogen

Dioksida (NO_2), dan Ozon (O_3) pada tahun 2016 dengan periode waktu yang digunakan adalah per hari

3. Data yang akan digunakan dalam proses peramalan adalah data 5 zat parameter per hari pada tahun 2016 dan data meteorologi (suhu udara, kelembapan, curah hujan) Kota Surabaya dari *NOAA Satellite and Information Service* pada tahun 2016.
4. Hasil luaran dari proses *clustering* adalah *cluster* indeks pencemar polutan udara dari tiga stasiun pemantau udara di Kota Surabaya dan hasil luaran proses peramalan berupa nilai pada masing-masing lima parameter polutan udara yang kemudian disimpulkan status kualitas udara berdasarkan indeks pencemar polutan udara dari proses *clustering*.
5. Penelitian ini menggunakan software R-Studio untuk melakukan *clustering* K-Means dan peramalan ANN.
6. Aplikasi berbasis web dibuat menggunakan R *Shiny* dan hanya menampilkan visualisasi kualitas udara Kota Surabaya, hasil klasterisasi titik daerah dan waktu rawan polusi, serta peramalan kualitas udara ke depan di Kota Surabaya.

1.4 Tujuan Tugas Akhir

Terdapat beberapa tujuan yang ingin dicapai berdasarkan latar belakang permasalahan dan rumusan masalah yang telah dipaparkan sebelumnya, antara lain sebagai berikut :

1. Menerapkan teknik *clustering* dengan menggunakan algoritma K-Means kualitas udara Kota Surabaya berdasarkan lima parameter polutan udara.
2. Membuat model yang dapat digunakan untuk melakukan peramalan indeks pencemar kualitas udara yang ditunjukkan oleh nilai-nilai pada lima parameter kualitas udara Kota Surabaya dengan metode *Artificial Neural Network*.

3. Membuat model klasifikasi untuk memprediksi kategori status polusi udara berdasarkan hasil peramalan polusi udara.
4. Membuat sebuah aplikasi berbasis web sebagai alat visualisasi untuk peramalan kualitas udara ke depan dan klaster titik daerah & waktu rawan polusi serta prediksi status polusi udara dari hasil peramalan di Kota Surabaya.

1.5 Manfaat Tugas Akhir

Terdapat beberapa manfaat yang dapat diberikan berdasarkan tujuan yakni sebagai berikut:

1. Bagi Badan Lingkungan Hidup Surabaya :
 - Mengetahui prediksi kualitas udara ke depan, sehingga dapat dilakukan penanganan dan pencegahan terhadap kasus kualitas udara yang buruk secara cepat
 - Mengetahui titik daerah dan waktu rawan polusi yang ada di Kota Surabaya sebagai bahan evaluasi untuk proses pengendalian dalam mengawasi kualitas udara Kota Surabaya.
2. Bagi masyarakat, hasil visualisasi dapat diakses kapan pun & dimana pun serta dapat dijadikan pengetahuan oleh masyarakat melalui hasil analisa data yang divisualisasikan mengenai daerah & waktu rawan polusi dan prediksi kualitas udara ke depan di Surabaya.
3. Bagi pengembangan keilmuan, dapat dijadikan sebagai pengetahuan dalam peramalan kualitas udara ke depan serta klasterisasi kualitas udara untuk mengetahui tingkat kualitas udaranya pada daerah tertentu sehingga dapat dijadikan pustaka untuk penelitian berikutnya.

1.6 Relevansi Tugas Akhir

Topik pada tugas akhir ini adalah mengenai peramalan kualitas udara kota Surabaya pada tahun 2017 dan klasterisasi kualitas udara untuk titik rawan polusi serta visualisasi hasil peramalan kualitas udara dan kualitas udara aktual sehingga masih

berkaitan dengan topik yang berada pada Laboratorium Rekayasa Data dan Inteligensi Bisnis.

Pada tugas akhir yang akan diambil menerapkan atau berkaitan dengan mata kuliah pada jurusan sistem informasi ITS. Matakuliah yang dimaksud adalah sebagai berikut :

- Pemrograman Berbasis Web
- Teknik Peramalan
- Sistem Cerdas
- Analisa dan Desain Perangkat Lunak

1.7 Sistematika Penulisan

Pada penulisan tugas akhir, terdapat sistematika penulisan yang digunakan. Sistematika ini terbagi menjadi tujuh bab yang akan dijabarkan sebagai berikut:

BAB I PENDAHULUAN

Bab ini memuat hal-hal yang melatarbelakangi pengerjaan tugas akhir ini yang meliputi latar belakang masalah, perumusan masalah, batasan masalah, perumusan masalah, tujuan, manfaat penelitian, relevansi dan yang terakhir adalah sistematika penulisan tugas akhir.

BAB II TINJAUAN PUSTAKA

Bab ini menjelaskan tentang studi sebelumnya yang mendukung tugas akhir serta teori-teori yang berhubungan dengan manajemen kualitas udara, kualitas udara, k-means *clustering*, uji korelasi, peramalan, *artificial neural network*, *backpropagation neural network*, dan uji performa yang akan digunakan untuk menyelesaikan permasalahan pada tugas akhir.

BAB III METODOLOGI PENELITIAN

Bab ini menjelaskan mengenai alur pengerjaan tugas akhir yang berawal tahapan *clustering* yang terdiri dari persiapan data *clustering*, proses *clustering*, uji performa *clustering* dan analisa hasil *clustering*. Kemudian dilanjutkan dengan tahapan peramalan yakni persiapan data peramalan, pembuatan model peramalan, penerapan model peramalan, uji performa hasil peramalan dan analisa data hasil peramalan. Selanjutnya tahap visualisasi terdiri dari desain visualisasi dan visualisasi berbasis website. Tahap terkahir adalah analisis hasil *clustering*, peramalan dan klasifikasi serta diakhiri dengan pembuatan laporan tugas akhir.

BAB IV PERANCANGAN

Pada bab ini akan dibahas mengenai perancangan pengoalahan data dengan melakukan pengumpulan data, persiapan data untuk *clustering*, peramalan dan klasifikasi. Persiapan data untuk *clustering* terdiri dari interpolasi data, integrasi data, pembersihana data dan normalisasi min-max. Persiapan data untuk peramalan terdiri dari interpolasi data meteorologi, uji korelasi, penentuan data, perancangan model ANN, penentuan *input node*, penentuan *hidden node*, dan penentuan parameter.

BAB V IMPLEMENTASI

Pada bab ini tentang pengoalah data yang didapat dari tahap sebelumnya dan implemntasi proses *clustering*, proses peramalan, proses klasifikasi dan proses visualisasi dashboard dengan menggunakan R.

BAB VI HASIL DAN PEMBAHASAN

Pada bab ini akan ditampilkan hasil *clustering*, uji performa hasil *clustering* berdasarkan metode K-Means, analisis uji korelasi, analisis hasil peramalan yang terdiri dari hasil pembentukan model dan penerapan model dan analisis hasil klasifikasi yang terdiri dari pembuatan model dan analisis hasil

klasifikasi hasil peramalan yang diharapkan dapat menjadi penyelesaian permasalahan.

BAB VII PENUTUP

Pada bab ini akan dijelaskan kesimpulan dan saran untuk penelitian sebelumnya dari pengerjaan tugas akhir yang menjawab rumusan masalah yang telah dijabarkan pada bab Pendahuluan.

BAB II TINJAUAN PUSTAKA

Bab ini akan menjelaskan mengenai penelitian sebelumnya dan dasar teori yang dijadikan acuan atau landasan dalam pengerjaan tugas akhir ini. Landasan teori akan memberikan gambaran secara umum dari landasan penjabaran tugas akhir ini.

2.1 Penelitian Sebelumnya

Beberapa penelitian sebelumnya yang berhubungan dengan topik yang diambil dapat dilihat pada Tabel 2.1.

Tabel 2.1. Perbandingan Penelitian Sebelumnya

	Penelitian 1 [9]	Penelitian 2 [10]
Judul	<i>Air Pollution Analysis Using Enhanced K-Means Clustering Algorithm for Real Time Sensor Data</i>	<i>An improved K-means Algorithm and Its Application in the Evaluation of Air Quality Level</i>
Metode	K-Means dan Fuzzy C-Mean	Kombinasi metode K-means dan hirarki
Penulis	Kingsy Grace, Manimegalai, Geetha Devasena, Rajathi, Usha, Raabiathul Baseria	Guo Xiaojie, Chen Liang, Zhou Hang, Huang Jun
Tujuan	Menentukan <i>Air Quality Index</i> secara akurat menggunakan perbandingan metode K-Means dan Fuzzy C-Means	Mengevaluasi kualitas udara dengan menggunakan metode kombinasi antara K-means dan hirarki

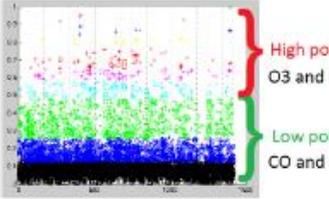
Hasil Penelitian	<ul style="list-style-type: none"> • Hasil akurasi berdasarkan 5 dataset yang berbeda dengan perbandingan antara metode K-Means dan PFCM (Fuzzy C Means) menunjukkan hasil bahwa metode K-Means lebih akurat daripada PFCM 	<ul style="list-style-type: none"> • Hasil rata-rata <i>distance</i> yang memiliki koefisien asosiasi yang paling besar yakni 0.866 • Hasil jumlah cluster berdasarkan <i>tree diagram</i> menunjukkan jumlah cluster seharusnya adalah 5 cluster.
	<ul style="list-style-type: none"> • Efisiensi waktu dari metode PFCM lebih baik dibandingkan dengan metode K-Means 	<ul style="list-style-type: none"> • Berdasarkan hasil dari kelima cluster didapatkan mayoritas sampel terkumpul pada cluster 1, cluster 2, dan cluster 4
Persamaan	Menggunakan algoritma K-Means dalam menentukan Indeks Kualitas Udara	Menggunakan metode K-means klustering untuk mengevaluasi kualitas udara
Perbedaan	Tidak membandingkan metode <i>clustering</i> K-Means dengan PFCM	Menggunakan kombinasi metode hirarki dan K-means untuk meningkatkan algoritma K-means

Kelebihan	Melakukan perbandingan kedua metode yakni K-Means dan PFCM dalam menentukan indeks kualitas udara	Metode kombinasi algoritma hirarki dan algoritma K-means lebih sesuai dan lebih cepat dibandingkan dengan metode tradisional atau algoritma K-means yang bisasa.
	Penelitian 3 [11]	Penelitian 4 [12]
Judul	<i>Data Mining to Aid Policy Making in Air Pollution Management</i>	<i>Hybridization of Air Quality Forecasting Models Using Machine Learning and Clustering : An Original Approach to Detect Pollutant Peaks</i>
Metode	Self-Organizing Map Neural Networks	Artificial Neural Network dan Kombinasi Self-Organization Map & K-Means Clustering
Penulis	Sheng-Tun Li dan Li-Yen Shue	Wani Tamas, Gilles Notton, Christophe Paoli, Marie-Laure Nivet, Cyril Voyant
Tujuan	Menggunakan analisis cluster untuk identifikasi pola data dan hasil analisa terakhir untuk memetakan cluster yang teridentifikasi pada lokasi geografis dari distribusi kualitas udara <i>Taiwanese Air Quality</i>	Menggabungkan Artificial Neaural Network dan <i>Clustering</i> untuk mendeteksi puncak polutan

	<i>Monitoring Network (TAQMN)</i>	
Hasil Penelitian	<ul style="list-style-type: none"> • Akuisisi data dilakukan dari 71 stasiun website yang ada di Taiwan dengan parameter PM₁₀. • SOM neural network digunakan untuk untuk identifikasi cluster seperti ruang lingkup dimensional yang tinggi. Hasil klasterisasi mengindikasikan terdapat 7 cluster. • Pemetaan temuan ke kualitas udara saat ini daerah, terdapat 2-4 cluster di kabupaten, dan kabupaten bisa menjangkau 2-7 tingkat cluster. Berdasarkan temuan ini, bahwa efektivitas kebijakan pengendalian pencemaran ini, yang sepenuhnya didasarkan pada kenyamanan administrasi, mungkin lebih ditingkatkan dengan mempertimbangkan pengelompokan polutan, yang dapat digambarkan dalam zona. 	<ul style="list-style-type: none"> • Data yang digunakan adalah kualitas udara pada pulau Corsica selama 5 tahun yang dibagi menjadi dataset <i>training</i>, data validasi, dan data <i>testing</i>. • Dilakukan pembangunan 3 model MLP untuk peramalan PM₁₀, O₃, NO₂. Model pertama yang di-<i>training</i> dan dievaluasi memberikan presisi global yang baik. Model kedua merupakan model <i>hybrid</i> dari MLP & metode <i>clustering</i> dengan pendekatan <i>hierarchical clustering</i> menggunakan Euclidean distance dengan Ward Criterion (Hmlp). Model ketiga menggunakan <i>k-means clustering</i> yang digabung dengan Self Organisation Map (Kmlp). Hasil model hybrid keduanya memiliki presisi global

		<p>yang rendah namun menunjukkan peramalan yang lebih akurat. Kedua pendekatan antara <i>hierarchical</i> dengan SOM/K-means menunjukkan hasil yang efisien, bergantung dengan situasi. Penggunaannya meningkatkan deteksi tingkat polusi yang tinggi</p>
Persamaan	<p>Menggunakan teknik data mining yakni analisa cluster dalam memetakan daerah tingkat kualitas udara</p>	<p>Menggunakan studi kasus kualitas udara dan terdapat proses <i>clustering</i> yang menggunakan metode K-Means</p>
Perbedaan	<p>Pada penelitian ini menggunakan metod Self Organizing Map Neural Network yang diolah dengan <i>tools</i> MATLAB</p>	<p>Penelitian ini membandingkan 3 model antara MLP klasik, MLP dengan <i>hierarchical clustering</i> dan MLP dengan <i>clustering</i> menggunakan SOM & K-Means untuk memperoleh peramalan terbaik.</p>
Kelebihan	<ul style="list-style-type: none"> • Menggunakan analisa klaster dengan distribusi berdasarkan lokasi 	<p>Membandingkan 3 model antara MLP klasik, MLP dengan <i>hierarchical clustering</i> dan MLP dengan <i>clustering</i> menggunakan SOM & K-Means untuk memperoleh peramalan terbaik.</p>

	Penelitian 5 [7]	Penelitian 6 [13]
Judul Penelitian	<i>Air Pollutants Concentrations Forecasting Using Back Propagation Neural Network Based on Wavelet Decomposition with Meteorological Conditions</i>	<i>Analysis of Air Quality Data in Mexico City Clustering Techniques Based on Genetic Algorithm</i>
Metode	Weighted Backpropagation Neural Network dan Mono Backpropagation Neural Network	Genetic Algorithm
Penulis	Yun Bai, Yong Li, Xiaoxue Wang, Jingjing Xie, Chuan Li	Jaime Reyes, Abraham Sanchez
Tujuan	Meramalkan konsentrasi polusi udara (PM10, SO ₂ , NO ₂) sehari-hari	Melakukan analisa data kualitas udara untuk menemukan solusi yang optimal menggunakan metode Genetic Algorithm
Hasil Penelitian	Analisis korelasi antara polusi udara dan kondisi cuaca untuk menentukan <i>input node</i> dari model regresi (BPNN dan W-BPNN). Terdapat 360 hari <i>dataset</i> , 300 data harian pertama digunakan untuk <i>training</i>	<ul style="list-style-type: none"> • Pada penelitian ini dilakukan clustering menggunakan Genetic Algorithm yang terdiri dari 3 jenis yaitu STCM, CSPM, SCMA • Hasil menunjukkan bahwa terdapat 10 cluster dimana polutan terbanyak adalah CO dan SO₂ sebagai area yang rendah polusi,

	<p>set, sedangkan sisanya digunakan untuk <i>testing</i></p> <p>Model menggunakan BPNN struktur jaringan 6-6-1 (<i>input node=6, hidden node=6, output node=1</i>) yang menunjukkan hasil MAPE = 31.26% (PM10), 22.11% (SO₂), 35.03% (NO₂), RMSE = 23.624 $\mu\text{g}/\text{m}^3$ (PM10), 12.716 $\mu\text{g}/\text{m}^3$ (SO₂), 5.406 $\mu\text{g}/\text{m}^3$ (NO₂), dan CC = 0.926 (PM10), 0.847 (SO₂), 0.770 (NO₂).</p> <p>Hasil perbandingan antara BPNN dengan W-BPNN menunjukkan bahwa W-BPNN lebih akurat dibandingkan dengan mono-BPNN, sehingga W-BPNN lebih baik menghasilkan peramalan kualitas udara</p>	 <p>sedangkan NO_x dan O₃ merupakan tinggi polusi</p> <ul style="list-style-type: none"> • Clustering menampilkan tiga tipe pola, cluster berwarna biru merupakan ukuran yang paling besar yakni PM₁₀ dengan rata-rata 164.70 IMECA. Cluster berwarna hijau dengan nilai yang besar yakni O₃ yang memiliki rata-rata 129.13 IMECA. Sedangkan area gelap memiliki nilai yang lebih kecil dibandingkan biru dan hijau dengan nilai yang lebih besar PM₁₀ dan rata-rata 67.06 IMECA
<p>Persamaan</p>	<p>Menggunakan studi kasus kualitas udara dan menggunakan metode peramalan BPNN</p>	<p>Melakukan analisa data kualitas udara dengan teknik <i>clustering</i></p>

Perbedaan	Studi kasus yang digunakan pada penelitian ini adalah berlokasi pada China	Metode yang digunakan dalam teknik <i>clustering</i> yakni menggunakan <i>Genetic Algorithm</i>
Kelebihan	<ul style="list-style-type: none"> • Membandingkan hasil antara metode W-BPNN dengan mono-BPNN • Hasil menunjukkan tingkat akurasi yang cukup tinggi. • Menggunakan analisa korelasi pada faktor - faktor yang mempengaruhi kualitas udara (data meteorologi dan <i>particel matter</i>) sebagai input dan output untuk BPNN 	

Tabel 2.2

2.2 Dasar Teori

2.2.1 Air Quality Management Kota Surabaya

Status kualitas udara saat ini telah disajikan di Indonesia khususnya di kota-kota tertentu yang tercakup dalam *Air Quality Management System* (AQMS). AQMS di Indonesia meliputi 10 kota di Indonesia, yaitu Jakarta, Bandung, Semarang, Surabaya, Denpasar, Medan, Pekanbaru, Palangkaraya, Jambi, dan Pontianak. Setiap kota dilengkapi dengan stasiun tetap *monitoring*, stasiun pemantauan ponsel, pusat regional dan pusat kalibrasi regional. Informasi Pemantauan dibuat untuk publik melalui elektronik data yang ditampilkan setiap hari. [1]

Adapun stasiun pemantauan udara *ambient* secara permanen di Kota Surabaya pada tahun 2016 diletakkan pada daerah taman prestasi, wonorejo dan kebonsari.

Sedangkan untuk Public Display Data ditempatkan di beberapa lokasi seperti :

1. Di depan Monumen Kapal Selam, Jalan Gubeng Pojok (Central Surabaya)
2. Di depan BAPPEDA Provinsi Jawa Timur, Jalan Pahlawan (Surabaya Utara)
3. Ring Road Jalan Mayjend Sungkono (Surabaya Selatan)
4. Perempatan Jalan Dharmawangsa dan Jalan Kertajaya (Surabaya Timur)
5. Di depan BNI Graha Pangeran, A. Yani (Surabaya Selatan)

2.2.2 Kualitas Udara

2.2.2.1 Indeks Standar Pencemar Udara

Indek Standar Pencemar Udara (ISPU) merupakan suatu indeks yang digunakan dalam pelaporan kualitas udara harian. ISPU memberikan informasi seberapa bersih atau terpolusi udara di sekitar beserta hubungannya terkait dampak kesehatan yang dapat disebabkan. ISPU berfokus pada dampak kesehatan yang dapat dirasakan setelah beberapa jam atau beberapa hari menghirup udara yang terpolusi. ISPU dihitung berdasarkan empat polutan udara utama yang diatur oleh *Clean Air Act*, antara lain: Ozon, Polusi Partikel, Karbon Monoksida, dan Sulfur Dioksida. Untuk setiap polutan, *Environmental Protection Agency* (EPA) telah menetapkan standar kualitas udara nasional untuk melindungi kesehatan masyarakat.

ISPU memiliki suatu rentang nilai dimana semakin tinggi nilai ISPU maka semakin tinggi tingkat polusi udara dan semakin besar pula dampaknya bagi kesehatan. Sebagai contoh, ISPU dengan nilai sebesar 50 menunjukkan kualitas udara yang baik dengan dampak yang minim bagi kesehatan, sementara ISPU dengan nilai diatas 300 merepresentasikan kualitas udara yang berbahaya dimana setiap orang dapat merasakan dampaknya

bagi kesehatan. ISPU dengan nilai 100 secara umum merupakan standar dari kualitas udara yang telah ditetapkan oleh EPA untuk melindungi kesehatan masyarakat. ISPU dengan nilai dibawah 100 secara umum menunjukkan kualitas udara yang baik sedangkan ISPU dengan nilai diatas 100 secara umum menunjukkan kualitas udara yang kurang baik khususnya bagi orang-orang yang memiliki pernapasan yang sensitif.

Untuk mempermudah pemahaman mengenai pengaruh kualitas udara terhadap kesehatan, ISPU dibagi menjadi enam tingkatan yang ditunjukkan pada Gambar 2.1.

Kategori	Rentang	Penjelasan
Baik	0-50	Tingkat kualitas udara yang tidak memberikan efek bagi kesehatan manusia atau hewan dan tidak berpengaruh pada tumbuhan, bangunan atau nilai estetika.
Sedang	51-100	Tingkat kualitas udara yang tidak berpengaruh pada kesehatan manusia ataupun hewan tetapi berpengaruh pada tumbuhan yang sensitif, dan nilai estetika.
Tidak sehat	101-199	Tingkat kualitas udara yang bersifat merugikan pada manusia ataupun kelompok hewan yang sensitif atau bisa menimbulkan kerusakan pada tumbuhan ataupun nilai estetika.
Sangat tidak sehat	200-299	Tingkat kualitas udara yang dapat merugikan pada sejumlah segmen populasi yang terpapar.
Berbahaya	300-lebih	Tingkat kualitas udara berbahaya yang secara umum dapat merugikan kesehatan yang serius

Gambar 2.1 Indeks Standar Pencemar Udara (ISPU) [14]

Berikut merupakan penjelasan dari masing-masing tingkatan pada ISPU:

1. Baik

Nilai ISPU berada diantara 0 dan 50. Hal ini menunjukkan kualitas udara yang baik dengan dampak yang minim bagi kesehatan.

2. Sedang

Nilai ISPU berada diantara 51 dan 100. Kualitas udara cukup baik, namun terdapat polusi yang dapat mempengaruhi kesehatan sebagian kecil masyarakat. Masyarakat yang sensitif terhadap ozon atau polusi partikel akan mengalami gangguan pernapasan.

3. Tidak sehat

Nilai ISPU berada diantara 101 dan 199. Tingkat kualitas udara yang bersifat merugikan pada manusia ataupun kelompok hewan yang sensitive atau bias menimbulkan kerusakan pada tumbuhan ataupun nilai estetika

5. Sangat Tidak Sehat

Nilai ISPU berada diantara 200 dan 299. Dapat memicu peringatan kesehatan yang berarti seluruh masyarakat dapat merasakan dampak kesehatan yang serius.

6. Berbahaya

Nilai ISPU berada diatas 300. Dapat memicu peringatan kesehatan dalam kondisi darurat. Seluruh populasi dapat merasakan dampak kesehatan yang serius.

2.2.2.2 Parameter yang Diukur

Parameter yang diukur dalam stasiun pemantau kualitas udara di Kota Surabaya ada 16 (enam belas) parameter, yang terdiri dari 5 (lima) parameter kunci: PM₁₀, SO₂, O₃, NO₂, CO.

Tabel 2.3. Parameter Polutan Udara yang Diukur

No	Parameter	Waktu Pengukuran
1	Partikulat (PM ₁₀)	24 Jam (periode pengukuran rata-rata)
2	Sulfur Dioksida (SO ₂)	24 Jam (periode pengukuran rata-rata)
3	Carbon Monoksida (CO)	8 Jam (periode pengukuran rata-rata)
4	Ozon (O ₃)	1 Jam (periode pengukuran rata-rata)
5	Nitrogen Dioksida (NO ₂)	1 Jam (periode pengukuran rata-rata)

2.2.2.3 Polutan Udara

Berdasarkan *Environmental Protection Agency* (EPA), terdapat empat jenis polutan utama yang berbahaya bagi kesehatan, antara lain:

1. Ozon

Ozon merupakan suatu zat gas yang terkandung pada udara yang kita hirup. Ozon dapat bersifat baik atau buruk tergantung kondisi saat zat tersebut terbentuk. Ozon yang buruk terbentuk di dekat permukaan tanah ketika polutan (yang disebabkan oleh mobil, pembangkit listrik, industri, kilang minyak, dan pabrik kimia) bereaksi secara kimia dengan cahaya matahari. Polusi ozon lebih sering terjadi ketika bulan-bulan dengan cuaca yang hangat.

2. Polusi Partikel

Polusi Partikel (atau disebut juga sebagai “*particulate matter*”) tersusun atas campuran zat padat dan zat cair. Beberapa partikel terbentuk secara langsung, sedangkan beberapa partikel lainnya terbentuk ketika suatu polutan yang berasal dari sumber tertentu bereaksi di atmosfer. Polusi partikel dapat mencapai tingkatan yang tidak sehat hingga berbahaya pada kondisi tertentu, seperti kebakaran hutan. Tingkat polusi partikel di dalam ruangan dapat meningkat, khususnya apabila tingkat polusi partikel di luar ruangan sangat tinggi. Partikel memiliki ukuran yang beraneka ragam. Partikel dengan diameter kurang dari 10 mikrometer (lebih kecil daripada lebar sehelai rambut manusia) berukuran sangat kecil sehingga dapat terhirup dan masuk ke paru-paru sehingga menyebabkan gangguan kesehatan yang serius.

3. Karbon Monoksida

Karbon Monoksida merupakan gas yang tidak berbau dan tidak berwarna. Karbon Monoksida terbentuk ketika karbon pada bahan bakar tidak terbakar secara sempurna. Emisi kendaraan

bermotor menyumbangkan kurang lebih 75% dari seluruh emisi karbon monoksida pada suatu negara dan 95% pada suatu kota. Sumber lainnya dari karbon monoksida adalah pembakaran bahan bakar pada industri dan juga bencana alam seperti kebakaran. Polusi karbon monoksida dapat mencapai tingkatan tertinggi ketika musim dingin, karena cuaca yang dingin menyebabkan pembakaran menjadi kurang sempurna dan menyebabkan polutan terjebak dengan ketinggian yang dekat dengan permukaan tanah.

4. Sulfur Dioksida

Sulfur dioksida merupakan gas yang reaktif dan tidak berwarna. Sulfur dioksida terbentuk ketika terjadi pembakaran pada bahan bakar yang memiliki kandungan sulfur seperti batu bara dan minyak. Secara umum, tingkat tertinggi dari polusi sulfur dioksida terjadi di sekitar kawasan industri yang besar. Sumber utama dari polutan ini antara lain, pembangkit listrik, kilang minyak, dan industri.

5. Nitrogen Dioksida

Jumlah oksida nitrat (NO) dan NO₂ yang biasa disebut nitrogen oksida atau NO_x. Oksida nitrogen lainnya termasuk asam nitrit dan asam nitrat adalah bagian dari keluarga nitrogen oksida. Sementara EPA Nasional Standar Kualitas Udara Ambien (NAAQS) meliputi seluruh keluarga ini, NO₂ adalah komponen bunga terbesar dan indikator untuk kelompok yang lebih besar dari nitrogen oksida.

NO_x bereaksi dengan amonia, uap air, dan senyawa lain untuk membentuk partikel kecil. Partikel-partikel kecil menembus dalam ke bagian sensitif dari paru-paru dan dapat menyebabkan atau memperburuk penyakit pernapasan, seperti emfisema dan bronkitis, dan dapat memperburuk penyakit jantung yang ada, yang menyebabkan peningkatan penerimaan rumah sakit dan kematian dini.

2.2.3 Data Meteorologi Kota Surabaya

Pada penelitian ini, dataset yang digunakan adalah data cuaca kota Surabaya dengan 4 atribut seperti pada tabel di bawah ini. Dataset dipilih dari repositori data cuaca NCDC (*National Climatic Data Center*) yang merupakan organisasi yang menyediakan rekam data cuaca secara global untuk seluruh stasiun meteorologi. Dataset sendiri merupakan data harian ringkasan cuaca pada kota Surabaya yang direkam oleh stasiun meteorologi Perak, Surabaya.

Tabel 2.4. Atribut Dataset Meteorologi

No	Variabel	Deskripsi
1	Suhu Udara	Rata-rata suhu udara dalam derajat Celcius
2	Tekanan Udara	Tekanan permukaan laut dalam milibar
3	Kecepatan Angin	Rata-rata kecepatan angin dalam knots
4	Visibilitas	Ukuran tingkat jarak pandang dalam km

2.2.4 Metode K-means Clustering

K-means merupakan salah satu algoritma clustering. Tujuan algoritma K-Means yaitu untuk membagi data menjadi beberapa kelompok atau *cluster*. Algoritma ini menerima masukan berupa data tanpa label kelas (*unsupervised learning*). Proses *clustering* K-Means, dilakukan oleh komputer dengan mengelompokkan sendiri data-data yang menjadi masukannya tanpa mengetahui terlebih dulu target kelasnya. Pembelajaran ini termasuk dalam *unsupervised learning*. Masukan yang diterima adalah data atau objek dan k buah kelompok (*cluster*) yang diinginkan. Algoritma ini akan mengelompokkan data atau objek ke dalam k buah kelompok tersebut. Pada setiap cluster terdapat titik pusat (*centroid*) yang merepresentasikan *cluster* tersebut.

Algoritma untuk melakukan K-Means *clustering* adalah sebagai berikut [14]:

- a. Menentukan jumlah kelompok

Langkah pertama yang dilakukan adalah membagi objek ke dalam sejumlah inisial kelompok K , dimana jumlah K harus ditentukan dengan spesifik.

b. Menentukan nilai centroid

Dalam menentukan nilai centroid pada awal iterasi, nilai awal centroid ditentukan secara acak. Sedangkan jika menentukan nilai centroid yang merupakan tahap dari iterasi, maka nilai centroid ditentukan dengan persamaan.

$$v_{ij} = \frac{1}{N_i} \sum_{k=0}^{N_i} x_{kj}$$

Simbol v_{ij} adalah centroid atau rata-rata kelompok ke- i untuk variabel ke- j . Sedangkan N adalah jumlah data yang menjadi anggota kelompok ke- i . Indeks dari kelompok disimbolkan oleh i, k . Sedangkan j adalah indeks dari variabel. x_{kj} adalah nilai data ke- k yang ada di dalam kelompok tersebut untuk variabel ke- j .

c. Menghitung jarak antara titik centroid dengan titik tiap objek.

Perhitungan jarak antar titik ini dapat dilakukan dengan menggunakan jarak *Euclidean*. Rumus untuk menghitung jarak *Euclidean* dapat dilakukan dengan mengikuti persamaan berikut.

$$D_e = \sqrt{(x_i - s_i)^2 + (y_i - t_i)^2}$$

Jarak *Euclidean* dilambangkan dengan D . Sedangkan jumlah objek disimbolkan oleh i . Koordinat objek dilambangkan dengan (x, y) . Sedangkan (s, t) melambangkan koordinat centroid.

d. Pengelompokan objek

Menentukan anggota kelompok dapat dilakukan dengan menghitung jarak minimum objek. Nilai yang didapatkan dalam keanggotaan data pada jarak matriks adalah 0 atau 1, nilai 1 untuk data yang dialokasikan ke kelompok

sedangkan nilai 0 untuk data yang dialokasikan ke kelompok lain.

- e. Mengulang langkah ke-2, lakukan perulangan hingga nilai centroid yang dihasilkan tetap dan tidak ada lagi anggota kelompok yang berpindah ke kelompok lain.

2.2.5 Uji Korelasi

Berdasarkan jurnal penelitian [15], interpretasi uji korelasi dari nilai *correlation coefficient* dikelompokkan seperti yang ditunjukkan pada Tabel 2.5 berikut.

Tabel 2.5 Interpretasi Uji Korelasi

Range Correlation	Interpretasi
0,90 to 1 (-0,90 to -1,0)	Sangat kuat positif (negatif) berkorelasi
0,70 to 0,90 (-0,70 to -0,90)	Kuat positif (negatif) berkorelasi
0,50 to 0,70 (-0,50 to -0,70)	Cukup positif (negatif) berkorelasi
0,30 to 0,50 (-0,30 to -0,50)	Rendah positif (negatif) berkorelasi
0,00 to 0,30 (-0,00 to -0,30)	Tidak berkorelasi

Terdapat tiga jenis uji korelasi, yaitu pearson, spearman dan kendall. Metode uji korelasi Pearson digunakan apabila data memiliki variable interval atau ratio, memiliki distribusi normal, bersifat linear dan outlier minimum atau dihapus [16]. Sedangkan, kendall dan spearman digunakan apabila datanya bersifat *monotonic*. [17].

Menurut Kendall dan Gibson, hasil dari spearman kurang handal dibandingkan kendall. Selain itu spearman tidak bisa menghitung apabila *ranking* antara keduanya sama [18]. Berikut ini adalah rumus kendall adalah :

$$\tau = \frac{C - D}{C + D}$$

C : jumlah nilai yang lebih tinggi daripada x

D: jumlah value yang lebih rendah daripada x

2.2.6 Peramalan

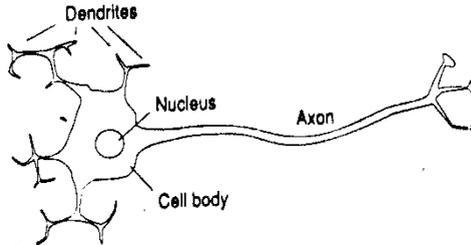
Jay Heizer dan Barry Render menyatakan bahwa peramalan (*forecasting*) adalah ilmu untuk memperkirakan kejadian di masa yang akan datang dengan harapan hasil peramalan mendekati data sebenarnya atau aktual. Sedangkan menurut Lerbin R., peramalan adalah kegiatan dalam menerapkan model yang telah dikembangkan pada waktu yang akan datang. Jadi peramalan adalah ilmu memprediksi sesuatu di masa depan dengan melakukan perhitungan secara objektif melalui penerapan model berdasarkan data historis atau data-data masa lalu.

Pembuat keputusan membutuhkan peramalan untuk memprediksi suatu hal yang tidak pasti di masa depan. Peramalan digunakan dalam perencanaan untuk memastikan apa yang terjadi ke depannya. Perencana dapat menggunakan metode peramalan untuk memprediksi keluaran atau hasil untuk rencana alternatif. Jika hasil peramalan tidak memuaskan, maka perencana dapat meninjau kembali rencananya, lalu mendapatkan peramalan baru, dan mengulang proses sampai hasil yang diramalkan sudah memuaskan atau memenuhi target yang diharapkan [19]. Sehingga tujuan dari peramalan adalah untuk mengurangi suatu hal yang tidak pasti di masa depan dengan melakukan manajemen penilaian.

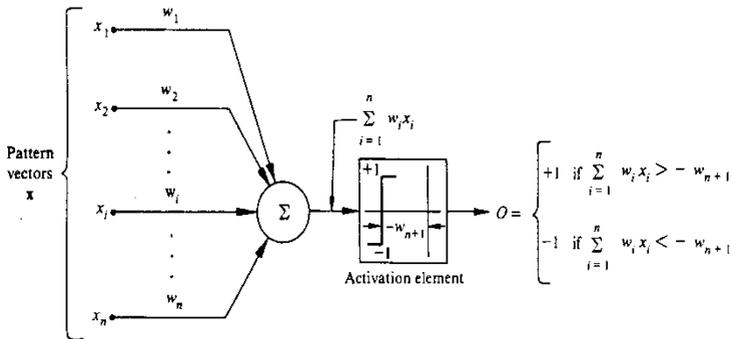
2.2.6.1 Artificial Neural Network

Jaringan saraf tiruan (*Artificial Neural Network*) adalah sebuah sistem yang terdiri atas sekelompok unit pemroses yang dimodelkan untuk pemrosesan informasi yang meniru cara kerja sistem saraf biologis seperti jaringan saraf manusia [8]. Jaringan saraf manusia dapat dilihat pada Gambar 2.2 dan

jaringan syaraf tiruan dapat dilihat pada Gambar 2.3. Terdapat beberapa teknik yang dikembangkan oleh para peneliti *neural network*, di antaranya adalah *delta learning rule*, *generalized delta learning rule*, *backpropagation*, *counterpropagation*, *radial basis function*, *kohonen Self Organizing Map (SOM)*, dan *polynomial neural network*



Gambar 2.2 Jaringan Syaraf Manusia [20]



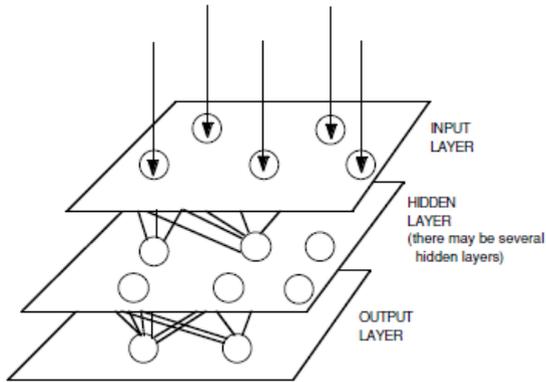
Gambar 2.3. Jaringan syaraf tiruan (Artificial Neural Network) [20]

Adapun cara kerja dari JST adalah dengan menggunakan proses masukan dari variabel yang telah diputuskan. Kemudian dicari kemungkinan keluaran dari beberapa masukan yang telah diproses. Setelah itu dilakukan perhitungan *error* atau kesalahan yang terjadi. Kemudian melakukan pembenaran pada nilai bobot (*weight*) dan bias sesuai dengan *error* yang terjadi.

JST merupakan mesin pembelajaran yang dibangun dari sejumlah elemen pemrosesan sederhana yang disebut *neuron*

atau *node*. Setiap *neuron* memiliki hubungan interaksi langsung dengan *neuron* lainnya melalui pola hubungan yang disebut sebagai model jaringan. Tiap penghubung diasosiasikan dengan sebuah nilai bobot (w). Seperti pada sebuah sinapsis, nilai bobot menentukan derajat pengaruh dari sebuah neuron ke neuron yang lainnya. Pengaruh dari sebuah neuron ke neuron yang lain merupakan hasil kali dari nilai keluaran dari neuron-neuron yang masuk ke neuron (x) dengan nilai bobot (w) yang menghubungkan neuron-neuron sebelumnya. Metode yang digunakan untuk menentukan besar koneksi antar *neuron* (dikenal dengan nama bobot) tersebut disebut dengan algoritma pembelajaran. Setiap neuron dikombinasikan dengan sebuah fungsi aktivasi yang berfungsi sebagai penghubung dari penjumlahan semua nilai masukan dengan nilai keluarannya. Keluaran dari neuron inilah yang nantinya akan menentukan apakah sebuah neuron itu aktif ataukah tidak. [8]

JST disusun dari sejumlah satuan masukan (*input*) dan keluaran (*output*) yang saling terhubung dimana setiap penghubung memiliki bobot yang dapat diubah-ubah untuk memperoleh hasil prediksi yang sesuai [20]. JST terdiri dari *neuron-neuron* yang dikelompokkan menjadi beberapa lapisan seperti pada Gambar 2.4, yakni sebagai berikut [21]:



Gambar 2.4. Arsitektur jaringan syaraf tiruan (Artificial Neural Network) [18]

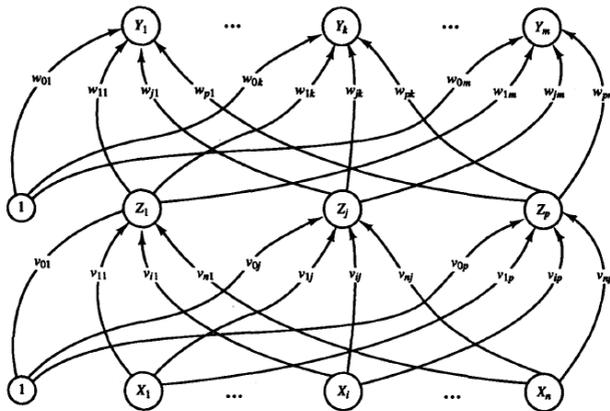
- Lapisan masukan (*input layer*) yang merupakan lapisan penghubung antara jaringan ke sumber data. Lapisan masukan akan menerima masukan berupa data yang nantinya akan mengalami proses pelatihan ke dalam jaringan. Setiap masukan akan menunjukkan beberapa variabel bebas yang berpengaruh pada lapisan keluaran (*output layer*)
- Lapisan tersembunyi (*hidden layer*) terletak di antara *input layer* dan *output layer*. *Hidden layer* berfungsi sebagai lapisan yang menerima masukan dari *input layer* dan mengirim sinyal ke jaringan syaraf dimana *hidden layer* dipengaruhi oleh nilai masukan dan bobot dari setiap penghubung.
- Lapisan keluaran (*output layer*) merupakan hasil dari yang telah diproses pada *hidden layer*. Pada *output layer*, hasil bergantung pada *hidden layer* dan bobot dari setiap penghubung.

2.2.6.2 Backpropagation Neural Network

Backpropagation atau “*backward propagation of errors*” adalah salah satu algoritma dalam jaringan syaraf tiruan atau

neural network yang dapat dikenal dengan singkatan BPNN. *Back propagation* lebih banyak digunakan dari algoritma lain dikarenakan kesederhanaan dan kekuatan dari algoritma yang dijalankan. Tidak seperti *precursors*, aturan *perceptron learning*, dan aturan *widrow-hoff learning*, *backpropagation* dapat diimplementasikan untuk pelatihan jaringan *nonlinier* dari konektivitas arbitari. Metode ini dipilih karena dapat digunakan untuk semua jenis data. [22]

BPNN merupakan *multilayer perceptron* dimana arsitektur BPNN terdiri dari tiga *layer* (*input*, *hidden*, *output*) serta mengalami tahap *feedforward* (maju dari *input*, *hidden*, *output*) & *backpropagation* (mundur dari *output*, *hidden*, *input*). Arsitektur BPNN dapat dilihat pada Gambar 2.5. Algoritma BPNN memiliki tiga tahapan yaitu tahap *Feedforward* pola pelatihan input, tahap *backpropagation* untuk error dan tahap perubahan bobot (*weight update*) dengan penjelasan sebagai berikut :



Gambar 2.5. Backpropagation Neural Network dengan satu hidden layer [20]

1. Tahapan *Feedforward*

- Pertama, setiap unit *input* (x_1, \dots, x_n) akan menerima sinyal dari luar unit dan melanjutkan sinyal tersebut pada setiap unit di *hidden layer* (z_1, \dots, z_p)
- Kedua, setiap unit pada *hidden layer* (z_1, \dots, z_p) kemudian melakukan perhitungan berdasarkan pada fungsi aktivasi, dan melanjutkan sinyal tersebut pada setiap unit *output* (y_1, \dots, y_m)
- Ketiga, setiap unit pada *output layer* (y_1, \dots, y_m) melakukan perhitungan berdasarkan fungsi aktivasi dan menghasilkan sinyal keluaran ANN berdasarkan pola *input*

2. Tahapan *Backpropagation*

- Keempat, pada saat proses pelatihan setiap *output* unit (y_1, \dots, y_m) melakukan perbandingan antara sinyal keluaran ANN dengan sinyal yang seharusnya (target sinyal) untuk mendapatkan *error* pada unit tersebut.
- Kelima, setiap *error* pada *output* unit didistribusikan kembali pada semua unit sebelumnya yakni pada *hidden layer* untuk dihitung perubahan bobot masing-masing unit pada *hidden layer* terhadap *output layer*.
- Keenam, menghitung *error* pada semua unit *hidden layer* yang dilakukan dengan cara yang sama seperti sebelumnya
- Ketujuh, hasil dari perhitungan *error* pada *hidden layer* tidak perlu didistribusikan pada semua *unit input layer*, tetapi hanya digunakan untuk menghitung perubahan bobot pada masing-masing unit *input layer* pada *hidden layer*.

3. Tahapan perubahan bobot

- Kedelapan, setelah semua *error* pada masing-masing unit yakni *output* dan *hidden layer* telah diketahui, maka secara simultan dilakukan perubahan bobot pada masing-masing unit.
- Kesembilan, Perubahan bobot pada setiap unit *hidden layer* ke *output layer* dilakukan perhitungan berdasar *error*

pada unit *output layer* dan fungsi aktivasi pada unit di *hidden layer*.

- Kesepuluh, kemudian pada perubahan bobot antara unit *input layer* ke *hidden layer* dihitung berdasarkan *error* pada unit *hidden layer* dan fungsi aktivasi pada unit *input layer*.

2.2.7 Klasifikasi Naive Bayes

Algoritma *Naive Bayes* merupakan salah satu algoritma yang terdapat pada teknik klasifikasi. *Naive Bayes* merupakan pengklasifikasian dengan metode probabilitas dan statistik yang dikemukakan oleh ilmuwan Inggris *Thomas Bayes*, yaitu memprediksi peluang di masa depan berdasarkan pengalaman dimasa sebelumnya sehingga dikenal sebagai *Teorema Bayes*. Teorema tersebut dikombinasikan dengan *Naive* dimana diasumsikan kondisi antar atribut saling bebas. Klasifikasi *Naive Bayes* diasumsikan bahwa ada atau tidak ciri tertentu dari sebuah kelas tidak ada hubungannya dengan ciri dari kelas lainnya. Persamaan dari teorema *Bayes* adalah sebagai berikut.

$$P(H|X) = \frac{P(X|H)P(H)}{P(X)}$$

Keterangan :

X : Data dengan class yang belum diketahui

H : Hipotesis data X merupakan suatu class spesifik

$P(H|X)$: Probabilitas hipotesis H berdasar kondisi X (posteriori probability)

$P(H)$: Probabilitas hipotesis H (prior probability)

$P(X|H)$: Probabilitas X berdasarkan kondisi pada hipotesis H

$P(X)$: Probabilitas X

Proses klasifikasi memerlukan sejumlah petunjuk untuk menentukan kelas apa yang cocok bagi sampel yang dianalisis tersebut. Karena itu, teorema *bayes* di atas disesuaikan sebagai berikut :

$$P(C | F_1 \dots F_n) = \frac{P(C)P(F_1 \dots F_n | C)}{P(F_1 \dots F_n)}$$

Dimana Variabel C merepresentasikan kelas, sementara variabel $F_1 \dots F_n$ merepresentasikan karakteristik petunjuk yang dibutuhkan untuk melakukan klasifikasi. Maka rumus tersebut menjelaskan bahwa peluang masuknya sampel karakteristik tertentu dalam kelas C (*Posterior*) adalah peluang munculnya kelas C (sebelum masuknya sampel tersebut, seringkali disebut *prior*), dikali dengan peluang kemunculan karakteristik – karakteristik sampel pada kelas C (disebut juga *likelihood*), dibagi dengan peluang kemunculan karakteristik – karakteristik sampel secara global (disebut juga *evidence*). Karena itu, rumus diatas dapat pula ditulis secara sederhana sebagai berikut:

$$Posterior = \frac{Prior \times likelihood}{evidence}$$

Nilai *Evidence* selalu tetap untuk setiap kelas pada satu sampel. Nilai dari *posterior* tersebut nantinya akan dibandingkan dengan nilai – nilai *posterior* kelas lainnya untuk menentukan ke kelas apa suatu sampel akan diklasifikasikan.

Persamaan Naive bayes adalah sebagai berikut. Asumsi independensi yang sangat tinggi (*naif*), bahwa masing – masing petunjuk ($F_1, F_2 \dots F_n$) saling bebas (independen) satu sama lain. Dengan asumsi tersebut, maka berlaku suatu kesamaan sebagai berikut

$$P(F_i | F_j) = \frac{P(F_i \cap F_j)}{P(F_j)} = \frac{P(F_i)P(F_j)}{P(F_j)} = P(F_i)$$

Untuk $i \neq j$, sehingga
 $P(F_i | C, F_j) = P(F_i | C)$

2.2.8 Uji Performa

Uji Performa yang akan digunakan untuk menguji hasil *clustering* menggunakan SSE, DBI, serta silhoutte Index dan untuk menguji hasil peramalan adalah menggunakan MAPE.

2.2.8.1 Sum of Squared Error (SSE)

SSE atau *Sum of Squared Error* merupakan sebuah metode yang paling umum untuk mengukur kevalidan sebuah hasil klusterisasi. Dalam sebuah kluster, error merupakan jarak dari sebuah titik dalam sebuah kluster ke titik pusat. Untuk mendapatkan nilai SSE dilakukan dengan mengkuadratkan error tersebut kemudian menjumlahkannya.

$$SSE = \sum_{i=1}^K \sum_{x \in C_i} dist^2(m_i, x)$$

Dimana x adalah titik data dalam kluster C_i dan m_i adalah titik perwakilan untuk cluster C_i yang menunjukkan bahwa m_i merupakan pusat (mean) dari cluster C_i . Jika terdapat dua kluster, kita bisa memilih salah satu dengan error terkecil. Salah satu cara yang mudah untuk mengurangi SSE adalah dengan meningkatkan jumlah cluster.

2.2.8.2 Dunn Indeks

Indeks Dunn (DI) merupakan metrik untuk mengevaluasi algoritma clustering yang diperkenalkan oleh J. C. Dunn pada tahun 1974. Indeks Dunn adalah rasio jarak terkecil antara observasi yang tidak dalam cluster yang sama dengan jarak intra-cluster yang paling besar. Indeks Dunn didefinisikan sebagai :

$$Dunn = \min_{1 \leq i \leq c} \left\{ \min \left\{ \frac{d(c_i, c_j)}{\max_{1 \leq k \leq c} (d(X_k))} \right\} \right\}$$

Di mana $d(c_i, c_j) = \text{intercluster distance}$ adalah jarak maksimum antara observasi dalam kluster. Sedangkan $(d(X_k)) = \text{intracluster distance}$ adalah jarak maksimum antara observasi dalam kluster.

2.2.8.3 Silhoutte Index

Indek silhoutte adalah jarak rata-rata untuk elemen dalam cluster yang sama dengan jarak rata-rata untuk elemen dalam cluster lainnya. Objek dengan nilai siluet tinggi dianggap baik karena sifatnya yang berkerumun, objek dengan nilai yang rendah mungkin bersifat outlier. Objek yang berkerumun memiliki nilai mendekati 1 dan objek yang buruk memiliki nilai mendekati -1. Indek siluet didefinisikan sebagai

$$S(i) = \frac{b_i - a_i}{\max(b_i, a_i)}$$

a_i adalah jarak rata-rata antara i dan semua pengamatan lainnya di cluster yang sama, dan b_i adalah jarak rata-rata antara i dan pengamatan di klaster tetangga terdekat.

$$a_i = \frac{1}{n(C(i))} \sum_{j \in C(i)} \text{dist}(i, j),$$

$$b_i = \min_{c_k \in C \setminus C(i)} \sum_{j \in C(i)} \frac{\text{dist}(i, j)}{n(C_k)}$$

Di mana $C(i)$ adalah mengelompokkan pengamatan i , $\text{dist}(i; j)$ adalah jarak antara pengamatan i untuk j , dan $n(C)$ adalah kardinalitas kelompok C .

2.2.8.4 Mean Absolute Percentage Error (MAPE)

Ukuran ketepatan Metode Peramalan dilakukan untuk mengukur ketepatan suatu metode peramalan berdasarkan kesalahan dari peramalan tersebut. Mean Absolute Percentage Error (MAPE) digunakan untuk memilih metode terbaik dan mengetahui ketepatan dalam melakukan peramalan. Adapun rumus MAPE adalah [23]:

$$MAPE = \frac{1}{n} \sum_{t=1}^n |PE_t|$$

Dengan n adalah banyaknya periode dan Pet adalah kesalahan persentasenya (Percentage Error) [23]:

$$PE_t = \left(\frac{X_t - F_t}{X_t} \right) \times 100\%$$

Dimana:

X_t = Observasi pada periode ke t

F_t = Ramalan pada periode ke t

Semakin kecil nilai MAPE maka nilai taksiran semakin mendekati dengan nilai yang sebenarnya, atau dengan kata lain metode yang telah dipilih merupakan metode yang terbaik [24]. Sebuah metode mempunyai kinerja sangat bagus apabila nilai MAPE berada dibawah 10%, dan mempunyai kinerja bagus jika nilai berada diantara 10% dan 20% [25].

Mean Absolute Percentage Error (MAPE) merupakan nilai *error* dari prosentase selisih data asli dengan hasil peramalan. Rumus perhitungan MAPE adalah sebagai berikut :

Nilai yang dihasilkan melalui evaluasi ini, menunjukkan kemampuan peramalan seperti yang ditunjukkan dalam kriteria MAPE pada table Tabel 2.6 berikut ini [26].

Tabel 2.6 Interpretasi Kemampuan Model Peramalan Berdasarkan Nilai MAPE

Nilai MAPE	Justifikasi
< 10%	Kemampuan peramalan sangat baik
10% - 20%	Kemampuan peramalan baik
20% - 50%	Kemampuan peramalan cukup
> 50%	Kemampuan peramalan buruk

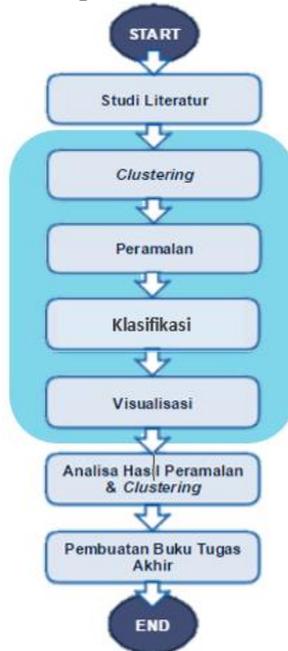
(Halaman ini sengaja dikosongkan)

BAB III METODOLOGI

Pengerjaan tugas akhir ini akan melalui beberapa metode yang meliputi studi literatur, pengumpulan data, pembuatan model, analisa data dan penarikan kesimpulan. Pada bab ini akan dijelaskan secara detail masing-masing metodologi yang akan dilakukan.

3.1 Tahapan Metodologi

Berikut pada Gambar 3.1 adalah gambar metodologi yang berisi tahapan yang akan dilakukan dalam penyelesaian tugas akhir ini seperti yang ditunjukkan pada tabel berikut.



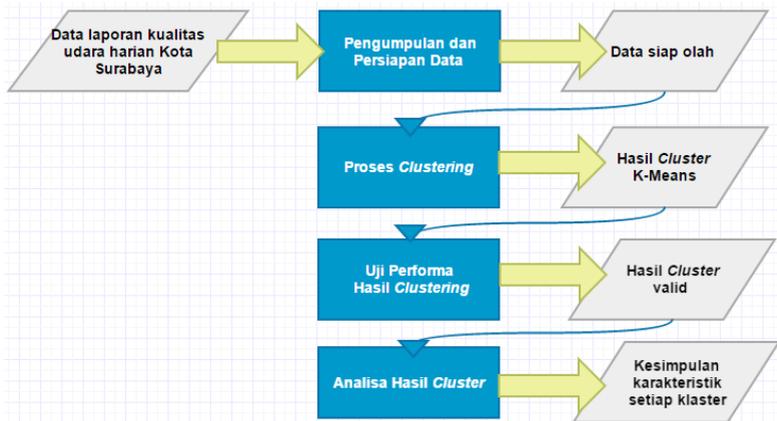
Gambar 3.1 Metodologi Pengerjaan Secara Umum

3.1.1 Studi Literatur

Tahapan ini merupakan tahapan awal penyusunan tugas akhir. Pada tahapan ini akan dilakukan analisis permasalahan yang akan dijadikan topik pengerjaan tugas akhir. Pada tahapan ini menghasilkan topik dan latar belakang permasalahan, tujuan tugas akhir, serta manfaat yang didapatkan dengan adanya tugas akhir ini.

Selanjutnya dilakukan pengumpulan berbagai informasi dan referensi mengenai topik penelitian yang dilakukan, teori mengenai polusi udara, dan visualisasi data. Hal ini dilakukan untuk mengkaji dan menunjang pengetahuan dalam mengerjakan tugas akhir ini. Adapun literatur yang digunakan yaitu: jurnal ilmiah nasional maupun internasional, *paper* penelitian tentang peramalan dan *clustering* kualitas udara, *e-book*, maupun buku-buku tentang teori polusi udara, dan metode visualisasi data yang dapat dijadikan bahan acuan pengerjaan tugas akhir ini.

3.1.2 Tahapan *Clustering*

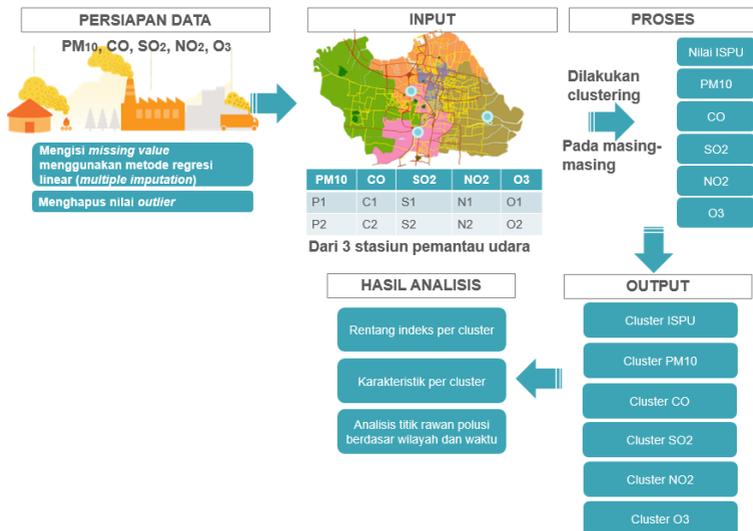


Gambar 3.2. Rincian Metodologi Pengerjaan Tahap *Clustering*

3.1.2.1 Persiapan Data untuk *Clustering*

Dengan adanya persiapan data, maka akan meminimalisir dalam mendapatkan hasil yang buruk terhadap proses *data mining*. Persiapan data untuk tahap klusterisasi adalah melakukan pembersihan data dengan mengisi data yang kosong dari 6 parameter zat kualitas udara pada tahun 2016.

Pada gambar 9 menunjukkan kerangka kerja secara teknis yang dilakukan pada tahap *clustering* yang meliputi tahap persiapan data, *input* data tahap *clustering*, proses *clustering*, *output*, dan hasil analisis dari *output clustering*.



Gambar 3.3. Kerangka Kerja Teknis Tahap *Clustering*

3.1.2.2 Proses *Clustering K-Means*

Pada proses *preprocessing* data atau persiapan data dihasilkan data siap olah yang akan digunakan pada tahap selanjutnya yakni pengolahan data. Berdasarkan masukan data siap olah, pengolahan data dilakukan dengan algoritma K-Means untuk menemukan kluster dari partikel kualitas udara. Jumlah kluster yang digunakan ditetapkan sesuai standar kebijakan *air quality*

index yakni 5 klaster. *Output* dari tahap ini adalah klaster *air quality index* dari 5 partikulat kualitas udara dan klaster-klaster pada setiap zat-zat dari 5 partikulat kualitas udara tersebut di dua stasiun pemantau Surabaya. Hasil tersebut siap dianalisa untuk tahap selanjutnya. Tahapan ini dilakukan dengan alat bantu yakni R untuk mempercepat proses pengolahan data.

Pada langkah pengerjaan algoritma *clustering* dengan metode K-means yang dilakukan pertama adalah melakukan pemilihan variabel dari data. Kemudian bentuk data diubah ke dalam data numerik, untuk memudahkan proses perhitungan matrix pada algoritma K-Means. Selanjutnya melakukan klasterisasi menggunakan K-Means dan menentukan jumlah centroid pada algoritma K-Means.

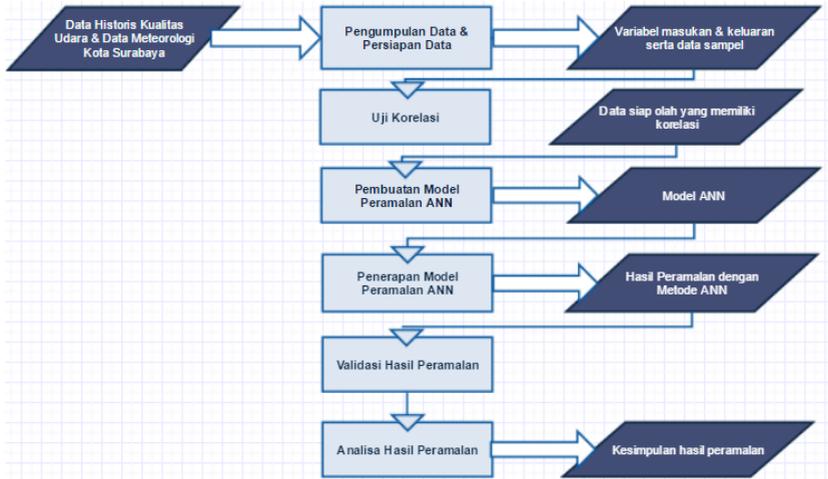
3.1.2.3 Uji Performa Hasil *Clustering*

Pada proses ini akan dilakukan pengujian hasil *clustering* dengan menggunakan *Sum Square Error (SSE)*, *Dunn Index* dan *Silhouette Index* . Apabila hasil *clustering* telah optimal maka dilakukan proses analisa hasil.

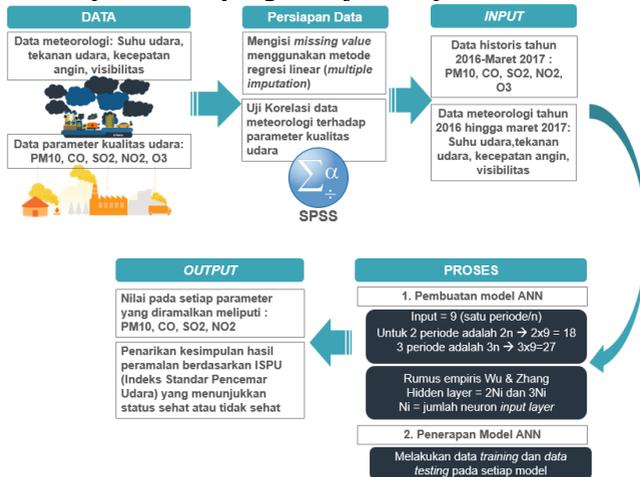
3.1.2.4 Analisa Data Hasil *Clustering*

Tahapan ini dilakukan setelah data selesai diklasterisasi. Pada setiap klaster dilakukan analisa mengenai ciri-ciri yang ada pada tiap klaster, sehingga nantinya bisa didapatkan titik wilayah dan waktu rawan polusi. Ciri-ciri setiap klaster berjumlah 5 klaster sesuai standar ISPU dengan kisaran indeks kualitas udara menyesuaikan hasil klasterisasi keadaan kualitas udara di Surabaya. Selain hasil klasterisasi, hasil visualisasi juga dilakukan analisa untuk mendeskripsikan apa yang ditampilkan oleh hasil visualisasi tersebut.

3.1.3 Tahapan Peramalan



Gambar 3.4. Rincian Metodologi Tahap Peramalan
Berikut ini dijelaskan kerangka pengerjaan secara teknis dalam melakukan peramalan yang ditunjukkan pada Gambar 3.5.



Gambar 3.5. Kerangka Kerja Teknis Tahap Peramalan

3.1.3.1 Pengumpulan Data & Persiapan Data

Tahapan pengumpulan data diperlukan dalam pengerjaan tugas akhir ini. Data harian 5 parameter kualitas udara di Kota Surabaya dalam bentuk excel. Data ini kemudian akan diolah sehingga menghasilkan prediksi yang mampu memecahkan permasalahan yang diangkat pada penelitian ini.

Tahapan penyiapan data merupakan tahap dasar untuk melakukan normalisasi data yang telah diperoleh. Normalisasi berfungsi agar jaringan tidak mengalami kegagalan ketika melakukan pembelajaran (*training* dan *testing*). Kegiatan yang dilakukan meliputi pembersihan data, penghapusan *noise*, data yang hilang dan konsistensi data menggunakan SPSS. Kemudian pada tahap ini dilakukan uji korelasi terhadap keterkaitan data meteorologi yang merupakan data independen dengan data lima parameter kualitas udara. Masing-masing data meteorologi yang terdiri dari suhu udara, tekanan udara, kecepatan angin dan visibilitas akan diujikan satu per satu terhadap data dependen yakni lima parameter kualitas udara. Metode yang akan digunakan dalam uji korelasi yakni Pearson dengan menggunakan *software* R. Jika memiliki korelasi terhadap data dependen yakni lima parameter kualitas udara, maka data independen tersebut akan digunakan dalam tahap peramalan sebagai *input-an*.

Setelah melakukan normalisasi data, kemudian data dibagi menjadi beberapa sub bagian yang lebih kecil, yaitu 70% dari keseluruhan data digunakan untuk proses *training* dan 15% digunakan untuk *testing* dan sisanya 15% digunakan untuk validasi hasil.

3.1.3.2 Pembuatan Model Peramalan ANN

Membuat model peramalan yang didasarkan dari studi yang telah dilakukan dengan menggunakan metode peramalan *Artificial Neural Network* dengan langkah-langkah sebagai berikut.

- a. Menentukan lapisan masukan (*input layer*), lapisan tersembunyi (*hidden layer*) dan lapisan keluaran (*output layer*). Variabel input dalam penelitian disini data meteorologi seperti temperatur, tekanan udara dan kelembapan serta data historis tingkat polusi sebelumnya. Sedangkan, variabel *output* dalam penelitian ini adalah peramalan tingkat polusi udara tahun 2017. Pada *hidden layer*, jumlah neuronnya ditentukan berdasarkan rumus empiris yang dipengaruhi oleh jumlah *input* neuronnya.
- b. Fungsi aktivasi
Fungsi aktivasi digunakan untuk memformulasikan keluaran (*output*) dari setiap *neuron*.
- c. Penggunaan algoritma *Backpropagation Neural Network Training backpropagation* terdiri dari 3 fase, yaitu propagasi maju, propagasi mundur, dan perubahan bobot.

3.1.3.3 Penerapan Model ANN

Tahapan penerapan model dilakukan jika model ANN telah dibuat dan yang memiliki nilai yang paling dengan tingkat error kecil sehingga model tersebut dapat digunakan pada kumpulan data *testing* sebanyak 15% dari total data historis untuk diuji. Dalam menerapkan model *ANN* digunakan sebuah perangkat lunak ,yakni R yang digunakan untuk membantu dalam pengolahan data. Berikut ini adalah tahapan-tahapan yang dilakukan dalam penerapan model *ANN* :

- a. Inisialisasi bobot dan bias.
Tahapan ini dilakukan agar jaringan dapat melakukan generalisasi dengan baik terhadap data di dalamnya. Inisialisasi dilakukan dari lapisan masukan ke lapisan tersembunyi maupun dari lapisan tersembunyi ke lapisan luaran.
- b. Perhitungan nilai kesalahan
Perhitungan nilai kesalahan dilakukan dengan fungsi Mean Absolute Percentage Error (MAPE) agar dapat diketahui keakurasian jaringan.

c. Perbaruan bobot

Tahapan ini dilakukan apabila kesalahan yang dihasilkan oleh jaringan tidak lebih kecil sama dengan nilai kesalahan yang ditetapkan. Rumus untuk memperbarui bobot adalah sebagai berikut :

$$\Delta w = \eta * \delta_i * n_i$$

Keterangan,

η : learning rate

δ_i : error yang berasosiasi dengan neuron yang dihitung

n_i : nilai error dari neuron yang dihitung

d. *Testing*

Pada proses *testing* JST dilakukan inisialisasi bobot yang berasal dari bobot-bobot yang terpilih dari proses training. Penerapan peramalan pada tahap ini dilakukan dengan menggunakan *tools* R sebagai analitik. Untuk menggunakan metode ANN, maka diperlukan menginstall *package* *neuralnet* pada R.

3.1.3.4 Uji Performa Hasil Peramalan

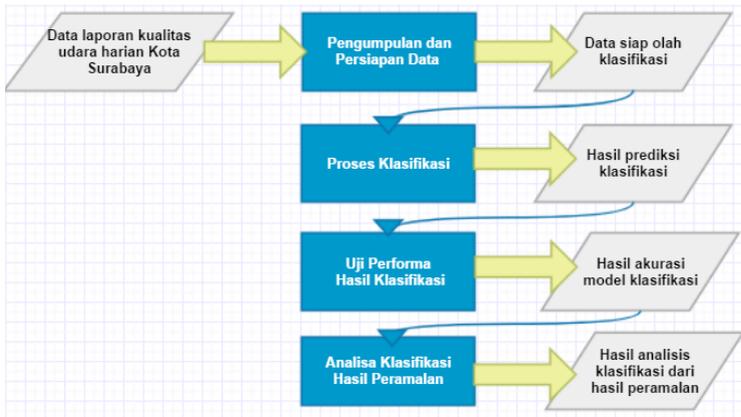
Tahapan validasi merupakan tahapan menghitung akurasi dari hasil peramalan dengan melakukan pengukuran menggunakan fungsi *Mean Absolute Percentage Error* (MAPE). Semakin kecil nilai MAPE, maka semakin bagus tingkat akurasi model.

Suatu peramalan dikatakan memiliki kinerja yang sangat baik apabila memiliki nilai MAPE dibawah 10%, dan memiliki kinerja yang bagus apabila nilai MAPE berkisar antara 10% - 30%

3.1.3.5 Analisa Data Hasil Peramalan

Tahapan analisa data hasil peramalan adalah melakukan analisa terhadap pola atau kecenderungan tren dari kualitas udara di masa depan. Kecenderungan hasil peramalan akan dinalisis menyesuaikan dengan kondisi lingkungan cuaca dan musim.

3.1.4 Tahapan Klasifikasi



Gambar 3.6 Rincian Metodologi Tahap Klasifikasi

3.1.4.1 Pengumpulan dan Persiapan Data

Tahap pengumpulan dan persiapan data dilakukan pembagian data *training* dan *testing* untuk tiga percobaan proporsi data yakni *training* 60% *testing* 40%, *training* 70% *testing* 30%, dan *training* 80% *testing* 20%.

3.1.4.2 Proses Klasifikasi

Tahap proses klasifikasi dilakukan pembuatan model klasifikasi dengan melakukan beberapa percobaan berdasarkan tiga proporsi data yang berbeda. Pembuatan model klasifikasi menggunakan metode Naive Bayes dan K-Fold Cross Validation untuk menentukan model data terbaik.

3.1.4.3 Uji Performa Hasil Klasifikasi

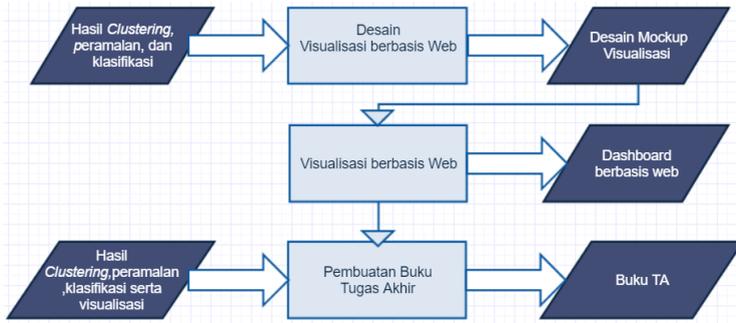
Tahap proses uji performa hasil klasifikasi adalah melakukan perhitungan akurasi model pada setiap percobaan model klasifikasi dari proporsi data yang berbeda.

3.1.4.4 Analisis Klasifikasi Hasil Peramalan

Tahap analisis klasifikasi hasil peramalan adalah tahap penerapan model terbaik dari masing-masing unsur polutan

udara yang diterapkan pada data hasil peramalan pada tahap sebelumnya.

3.1.5 Tahapan Visualisasi



Gambar 3.7 Rincian Metodologi Tahap Visualisasi

3.1.5.1 Desain Visualisasi

Pada tahapan ini adalah membuat desain *mockup* visualisasi dashboard yang memberikan informasi mengenai urutan penyampaian informasi visual pada dashboard, serta komponen-komponen visual klasterisasi & peramalan yang tepat untuk mengungkapkan informasi. Pada tahapan desain visualisasi hasil klasterisasi dan peramalan juga mempertimbangkan *audience* yang akan melihat informasi dashboard dalam keseharian untuk menampilkan bentuk informasi yang tepat ke dalam dashboard.

3.1.5.2 Visualisasi Berbasis Web

Pada tahap visualisasi hasil adalah memvisualisasikan hasil ke dalam dashboard berbasis websites. Adapun bentuk komponen visualisasi yang akan digunakan untuk menunjukkan hasil adalah *leaflet map*, *line chart* dan lain-lain. Visualisasi grafik tersebut dilakukan menggunakan *package R* yang kemudian diintegrasikan dengan website

3.1.6 Analisa Hasil *Clustering* dan Peramalan

Pada tahap analisa hasil *clustering* dan peramalan dilakukan setelah proses pengolahan data dan visualisasi telah dilakukan. Tahap ini melakukan analisa untuk penarikan kesimpulan terhadap hasil dari *clustering* dan peramalan dimana hasil peramalan disimpulkan berdasarkan hasil klaster indeks kualitas udara yang tepat sesuai kondisi wilayah Surabaya.

3.1.7 Pembuatan Buku Tugas Akhir

Pada tahapan terakhir ini akan dilakukan pembuatan laporan dalam bentuk buku tugas akhir yang disusun sesuai format yang telah ditentukan. Buku ini berisi dokumentasi langkah-langkah pengerjaan tugas akhir secara rinci. Buku ini diharapkan dapat bermanfaat sebagai referensi untuk pengerjaan penelitian lain, serta sebagai acuan untuk pengembangan lebih lanjut terhadap topik penelitian yang serupa.

(halaman ini sengaja dikosongkan)

BAB IV

PERANCANGAN

Pada bab ini, akan dijelaskan tentang rancangan dari tugas akhir yang terdiri dari subjek dan objek dari tugas akhir ini. Selain itu akan dijelaskan juga proses pemilihan subjek dan objek dari tugas akhir.

4.1 Pengumpulan Data

Pada tahap ini dilakukan pengumpulan data untuk tugas akhir. Untuk melakukan pengumpulan data kualitas udara Kota Surabaya dilakukan di Badan Lingkungan Hidup Surabaya. Data yang diperoleh merupakan data sekunder yang terdiri dari 5 parameter kualitas udara pada tahun 2016. Selain melakukan pengajuan data pada Badan Lingkungan Hidup Kota Surabaya juga dilakukan wawancara dan observasi.

Observasi dilakukan dengan melakukan pengamatan pada titik stasiun pemantauan udara secara permanen di Kota Surabaya untuk mengetahui kondisi udara berdasarkan peralatan operasional.

4.1.1 Parameter yang Diukur

Data yang didapatkan berupa data kualitas udara pada tahun 2016 terdiri dari 5 parameter yakni Karbon Monoksida(CO), Nitrogen Dioksida(NO₂), Ozon(O₃), Partikulat udara/debu

(PM₁₀), dan Sulfur Dioksida (SO₂) seperti yang ditunjukkan pada Tabel 4.1 Parameter yang digunakan.

Tabel 4.1 Parameter yang digunakan

No	Parameter
1	Partikulat (PM ₁₀)
2	Sulfur Dioksida (SO ₂)
3	Carbon Monoksida (CO)
4	Ozon (O ₃)
5	Nitrogen Dioksida (NO ₂)

Data-data yang didapatkan berupa 1800 buah file Microsoft Excel dari total kelima parameter yang diperoleh melalui Badan Lingkungan Hidup Kota Surabaya. File tersebut berisi rincian kualitas udara harian dari 5 parameter udara dimana per hari status udara diperbarui setiap 30 menit sehingga terdapat 48 baris data kualitas udara.

4.1.2 Pemantauan Kualitas Udara Otomatis

Pemantauan kualitas udara dilakukan berdasarkan tingkat konsentrasi pencemar, penyebaran pencemar dan inventarisasi emisi. Lokasi penempatan stasiun akan mempengaruhi analisa terhadap pengolahan data dalam menentukan titik rawan polusi dan prediksi kualitas udara Kota Surabaya ke depan. Pada Tabel 4.2 Lokasi stasiun pemantauan Kualitas Udara di Kota Surabaya yang masih aktif pada tahun 2016.

Tabel 4.2 Lokasi stasiun pemantauan Kualitas Udara di Kota Surabaya

Stasiun	Lokasi Pemantauan	Wilayah
SUF1	Halaman Taman Prestasi, Jl.Ketabang Kali	Surabaya Pusat
SUF6	Wonorejo	Surabaya Timur
SUF7	Kebonsari	Surabaya Selatan

Data ini merupakan data yang menjelaskan dokumentasi masing-masing unsur pada periode 2016 yakni 5 parameter yang akan digunakan untuk pengukuran.

Name	Date modified
CO (Carbon monoxide - Karbon monoksida)	03/03/2017 13.27
NO2 (Nitrogen dioxide - Nitrogen dioksida)	18/01/2017 20.25
O3 (Ozone - Ozon)	18/01/2017 20.26
PM10 (Floating dust - Debu)	18/01/2017 20.26
SO2 (Sulfur dioxide - Sulfur dioksida)	18/01/2017 20.26

Gambar 4.1 Dokumentasi yang diperoleh dari Badan Lingkungan Hidup Surabaya

Pada Gambar 4.2 Laporan harian kualitas udara Kota Surabaya untuk tiap parameter menunjukkan data kualitas udara setiap 30 menit dalam sehari yang diperoleh dari Badan Lingkungan Hidup Kota Surabaya.

Sistem Pemantauan Kualitas Udara Kota Surabaya
Laporan harian kualitas udara untuk parameter
Daily Air Quality Report for Parameters

Tanggal / Date: 01/01/2016
 Parameter / Parameter: CO: Karbon monoksida / Carbon monoxide
 Satuan / Unit: mg/m3

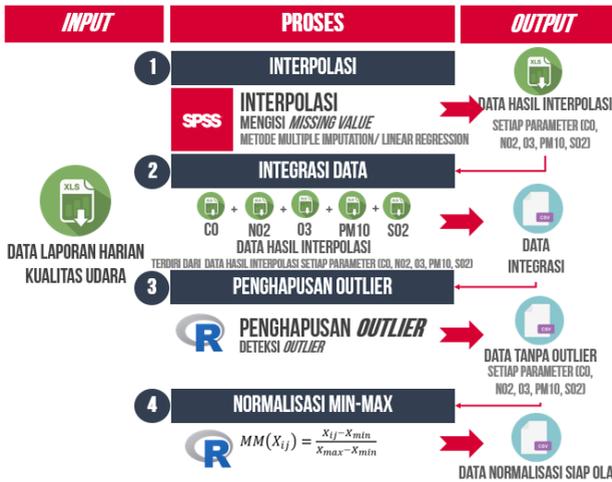
Laporan disiapkan di / Report prepared at: Data Center Surabaya
Laporan berdasarkan data setengah jam rata-rata / Report based on half hour mean values

Waktu / Time (GMT+7 (WIB))	Surabaya		Surabaya		Surabaya		Surabaya	
	SUF1	SUF3	SUF4	SUF5	SUF6	SUF7		
	Taman Prestasi	Sukorejo	Gayamsari	Gedung Putih	Wirocempu	Kebonsari		
00:30	1,07	1,07	1,07	1,07	1,07	1,07	1,48	1,48
01:30	0,88	0,88	0,88	0,88	0,88	0,88	1,39	1,39
02:00	0,80	0,80	0,80	0,80	0,80	0,80	1,67	1,67
02:30	0,78	0,78	0,78	0,78	0,78	0,78	1,77	1,77
03:00	0,69	0,69	0,69	0,69	0,69	0,69	1,97	1,97
03:30	0,68	0,68	0,68	0,68	0,68	0,68	1,94	1,94
04:00	0,68	0,68	0,68	0,68	0,68	0,68	2,33	2,33
04:30	0,62	0,62	0,62	0,62	0,62	0,62	1,06	1,06
05:00	0,67	0,67	0,67	0,67	0,67	0,67	0,91	0,91
05:30	0,57	0,57	0,57	0,57	0,57	0,57	1,14	1,14
06:00	0,48	0,48	0,48	0,48	0,48	0,48	1,66	1,66
06:30	0,51	0,51	0,51	0,51	0,51	0,51	1,27	1,27
07:00	0,51	0,51	0,51	0,51	0,51	0,51	0,66	0,66
07:30	0,49	0,49	0,49	0,49	0,49	0,49	1,18	1,18
08:00	0,51	0,51	0,51	0,51	0,51	0,51	1,29	1,29
08:30	0,51	0,51	0,51	0,51	0,51	0,51	1,21	1,21
09:00	0,46	0,46	0,46	0,46	0,46	0,46	0,71	0,71

Gambar 4.2 Laporan harian kualitas udara Kota Surabaya untuk tiap parameter

4.2 Persiapan Data untuk Clustering

Tahap persiapan data merupakan proses dilakukan pembersihan data, integrasi data dan normalisasi data yang ditunjukkan pada Gambar 4.3 Kerangka kerja proses persiapan data untuk Clustering.



Gambar 4.3 Kerangka kerja proses persiapan data untuk Clustering

4.2.1 Interpolasi Data Clustering

Tahap interpolasi yakni mengisi data yang kosong atau *miss* yang dapat dilakukan dengan menggunakan metode linear regresi di SPSS. Pada Gambar 4.4 menunjukkan data mentah yang merupakan laporan harian kualitas udara yang terdapat nilai kosong atau *missing value*. Oleh karena itu diperlukan interpolasi untuk mengisi nilai kosong tersebut dengan menggunakan SPSS yang ditunjukkan pada Gambar 4.5

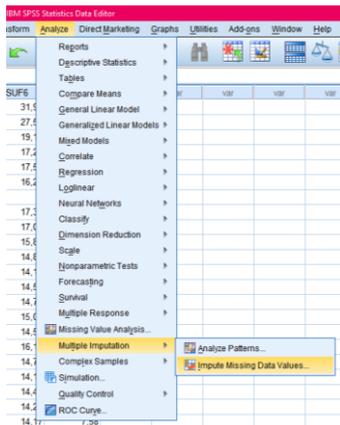
Waktu / Time GMT+7 (WB)	Surabaya		Surabaya	
	SUF1 Taman Prestasi	SUF6 Woronorejo	SUF7 Kebonsari	
08.00	18,34	54,17	19,01	A1
08.30	18,34	48,06	11,10	A1
09.00	18,34	30,72	9,18	A1
09.30	18,34	31,95	9,26	A1
10.00	18,34	27,52	10,04	A1
10.30	18,34	19,15	10,11	A1
11.00	18,34	17,21	9,58	A1
11.30	18,34	17,57	9,04	A1
12.00	18,34	16,23	8,40	A1
12.30	---	---	8,60	A1
13.00	26,55	17,34	8,73	A1

Gambar 4.4 Data mentah laporan harian kualitas udara

	SUF1	SUF6	SUF7
19	18,34	31,95	9,26
20	18,34	27,52	10,04
21	18,34	19,15	10,11
22	18,34	17,21	9,58
23	18,34	17,57	9,04
24	18,34	16,23	8,40
25			8,60
26	26,55	17,34	8,73
27	36,09	17,04	8,95
28	20,59	15,81	9,32
29	18,34	14,81	8,64

Gambar 4.5 Proses interpolasi menggunakan SPSS

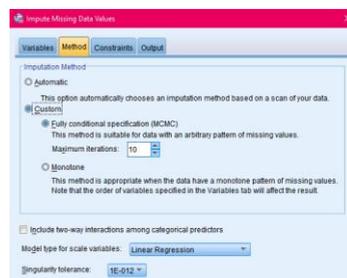
Selanjutnya pada SPSS dilakukan pengisian *missing value* dengan menggunakan menu *analyze* → *multiple imputation* → *impute missing data value* yang ditunjukkan pada Gambar 4.6. Kemudian dilakukan pemilihan variabel yang diperlukan untuk mengisi nilai yang hilang dimana variabel tersebut adalah SUF1 (Surabaya pusat), SUF6 (Surabaya timur), SUF7 (Surabaya selatan) yang ditunjukkan pada Gambar 4.7. Lalu pada Gambar 4.8 dilakukan pemilihan metode untuk mengisi data yang kosong yakni *linear regression*.



Gambar 4.6 Fungsi Multiple Imputation



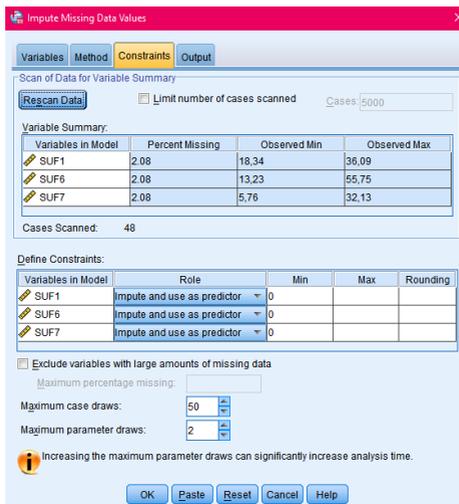
Gambar 4.7 Penentuan Variabel untuk Multiple Imputation



Gambar 4.8 Penentuan Method pada fitur Multiple Imputation

Selanjutnya dilakukan penentuan *constraint* yang ditunjukkan pada Gambar 4.9 dimana nilai minimal pada masing-masing variabel ditetapkan sebagai 0. Ketika dilakukan *scan data* akan muncul *percent missing* pada masing-masing variabel.

Selanjutnya dilakukan penentuan *constraint* yang ditunjukkan pada Gambar 4.9 dimana nilai minimal pada masing-masing variabel ditetapkan sebagai 0. Ketika dilakukan *scan data* akan muncul *percent missing* pada masing-masing variabel.



Gambar 4.9 Pengaturan constraint fungsi multiple imputation pada SPSS

Hasil pengisian *missing value* pada SPSS dengan menggunakan metode multiple imputation ditunjukkan pada Gambar 4.10. Hasil imputation kelima yang akan digunakan sebagai hasil interpolasi. Hasil interpolasi dari SPSS akan disalin ke bentuk format excel pada setiap parameter seperti yang ditunjukkan pada Gambar 4.11.

	Imputation_1	SUF1	SUF6	SUF7	var	var
241	5	18,34	13,40	6,12		
242	5	18,34	14,81	6,07		
243	5	18,34	30,20	5,81		
244	5	18,34	55,75	5,76		
245	5	18,34	54,53	6,74		
246	5	18,34	36,07	8,48		
247	5	18,34	38,44	11,01		
248	5	18,34	30,01	13,36		
249	5	18,34	31,98	16,45		
250	5	18,34	33,24	18,37		
251	5	18,34	35,49	16,47		
252	5	18,34	31,13	15,68		
253	5	18,34	27,55	16,38		
254	5	18,34	27,62	20,34		
255	5	18,34	34,41	32,13		

Gambar 4.10 Hasil interpolasi menggunakan multiple imputation di SPSS

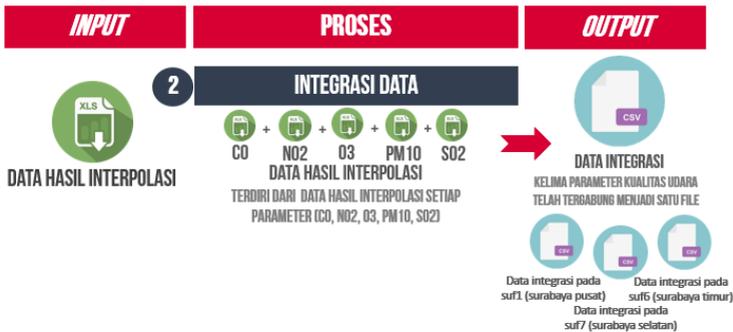
	suf1	suf6	suf7	min_suf1	max_suf1	mean_suf1	min_suf6	max_suf6	mean_suf6	min_suf7	max_suf7	mean_suf7
1	18,34	13,40	6,12	16,41	36,09	18,89	13,23	55,75	23,04	5,76	32,13	10,40
2	18,34	14,81	6,07									
3	18,34	30,20	5,81									
4	18,34	55,75	5,76									
5	18,34	54,53	6,74									
6	18,34	36,07	8,48									
7	18,34	38,44	11,01									
8	18,34	30,01	13,36									
9	18,34	31,98	16,45									
10	18,34	33,24	18,37									
11	18,34	35,49	16,47									
12	18,34	31,13	15,68									
13	18,34	27,55	16,38									
14	18,34	27,62	20,34									
15	18,34	34,41	32,13									
16	18,34	54,17	19,01									
17												

Gambar 4.11 Hasil interpolasi ke format excel

Interpolasi ini dilakukan pada kelima parameter yang ada dan periode harian tahun 2016, sehingga interpolasi dilakukan pada 1800 file data dari setiap data laporan harian kualitas udara.

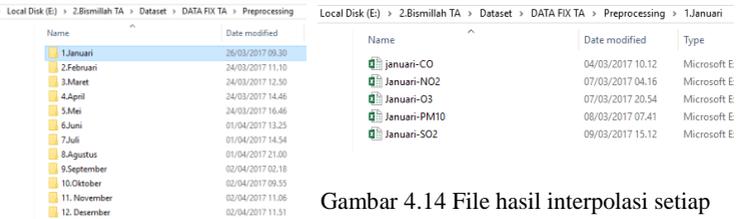
4.2.2 Integrasi Data

Tahap integrasi data dilakukan penggabungan data hasil interpolasi pada proses sebelumnya dimana data interpolasi masih terdiri dari data harian setiap parameter kualitas udara selama tahun 2016. Maka tahap ini menggabungkan data rata-rata kualitas udara harian selama 365 hari pada setiap parameter CO, NO₂, O₃, PM₁₀, SO₂ menjadi satu *file* dalam format csv seperti yang ditunjukkan pada kerangka kerja integrasi data Gambar 4.12.



Gambar 4.12 Integrasi data untuk proses *clustering*

Data hasil interpolasi pada awalnya dipisahkan berdasarkan bulan dengan 5 parameter seperti yang ditunjukkan pada Gambar 4.13. Satu bulan terdiri dari 5 *file* dari setiap parameter yang terdiri dari *sheet* yang berisi indeks kualitas harian yang telah dilakukan interpolasi seperti yang ditunjukkan Gambar 4.14.



Gambar 4.13 Folder data hasil interpolasi

Gambar 4.14 File hasil interpolasi setiap parameter dalam setiap bulan

Data hasil interpolasi disimpan dalam satu *file* bulanan yang terdiri dari *sheet-sheet* yang berisi data kualitas udara harian yang telah dilakukan interpolasi seperti yang ditunjukkan pada Gambar 4.15.

	A	B	C	D	E	F	G	H	I	J	K	L
	suf1	suf6	suf7	min_suf1	max_suf1	mean_suf1	min_suf6	max_suf6	mean_suf6	min_suf7	max_suf7	mean_suf7
1	0.65	1.66	0.32	0.23	0.65	0.40	1.66	3.76	2.23	0.00	3.83	0.56
2	0.57	1.82	0.26									
3	0.48	1.99	0.31									
4	0.45	1.78	0.34									
5	0.37	1.73	0.26									
6	0.34	1.73	0.27									
7	0.34	1.86	0.25									
8	0.34	1.85	0.00									
9	0.34	1.83	0.12									
10	0.34	1.81	0.33									
11	0.28	1.94	0.38									
12	0.34	1.95	0.82									
13	0.34	2.08	2.97									
14	0.42	2.05	1.36									
15	0.46	2.07	3.19									
16	0.46	2.32	0.07									
17	0.46	2.16	0.70									
18	0.39	2.01	0.49									
19	0.46	1.97	0.01									
20	0.44	1.91	0.00									
21	0.44	2.12	0.00									
22	0.44	2.09	0.00									
23	0.42	2.05	0.01									
24	0.34	1.96	2.30									
25	0.34	2.00	0.00									
26	0.34	1.98	0.00									
27	0.34	1.99	0.00									
28	0.34	1.99	0.00									

Gambar 4.15 File hasil interpolasi Bulan Januari pada setiap parameter

Selanjutnya dilakukan integrasi data dari kelima parameter periode harian menjadi satu data terintegrasi yang siap untuk diolah. Data integrasi yang dibutuhkan untuk proses *clustering* terdiri dari data integrasi dari seluruh stasiun pemantau wilayah

Surabaya, integrasi data stasiun pemantau wilayah bagian surabaya pusat (suf1), integrasi data stasiun pemantau wilayah bagian surabaya timur (suf6), dan integrasi data stasiun pemantau wilayah bagian surabaya selatan (suf7). Keempat file data terintegrasi itu diperlukan pengolahan data pada saat proses *clustering*.

4.2.2.1 Integrasi Data pada Seluruh Stasiun Pemantau Udara di Surabaya

Pada masing-masing *file* data harian yang telah dilakukan interpolasi akan digabungkan menjadi satu *file* dengan lima parameter yang ada di tiga stasiun pemantau udara Kota Surabaya seperti ditunjukkan pada Gambar 4.16.

	A	B	C	D	E	F	G
1	Date	CO	NO2	O3	PM10	SO2	stasiun
2	01/01/2016	0.47	13.67	4.99	11.5	4.52	1
3	02/01/2016	0.38	2.81	25.94	8.05	4.5	1
4	03/01/2016	0.4	6.91	4.99	4.93	2.8	1
5	04/01/2016	0.6	2.66	24.24	17.77	3.64	1
6	05/01/2016	0.63	3.92	31.45	3.69	2.56	1
7	06/01/2016	0.52	5.58	29.45	11.25	1.74	1
8	07/01/2016	0.34	1.17	31.8	8.55	4.85	1
9	08/01/2016	0.36	14.44	32.61	6.29	4.09	1
10	09/01/2016	0.36	10.38	32.86	7.86	3.35	1
11	10/01/2016	0.37	8.25	28.14	23.43	4.21	1
12	11/01/2016	0.54	9.76	22.47	23.44	3.16	1
13	12/01/2016	0.43	10.25	19.9	24.21	3.73	1
14	13/01/2016	0.37	8.92	22.74	28.88	2.34	1
15	14/01/2016	0.44	4.45	21.26	17.21	2.65	1
16	15/01/2016	0.25	3.34	23	11.32	2.4	1
17	16/01/2016	0.38	9.25	19.41	23.1	6.31	1
18	17/01/2016	0.38	4.92	32.08	22.55	2.68	1
19	18/01/2016	0.41	5.31	32.28	16.61	2.87	1
20	19/01/2016	0.35	3.41	25.9	17.4	3.72	1
21	20/01/2016	0.41	2.46	23.51	37.27	3.73	1
22	21/01/2016	0.41	2.95	23.74	10.79	2.02	1
23	22/01/2016	0.36	2.41	32.21	24.05	2.32	1

Gambar 4.16 Data integrasi 5 parameter kualitas udara di Surabaya (semua stasiun pemantau)

4.2.2.2 Integrasi Data pada Setiap Stasiun Pemantau Wilayah Surabaya Pusat (SUF1-Taman Prestasi)

Persiapan data integrasi dari kelima parameter pada stasiun pemantau wilayah Surabaya Pusat yang diletakkan pada daerah Taman Prestasi digunakan untuk proses *clustering* indeks kualitas udara yang hanya mempertimbangkan wilayah

Surabaya Pusat. Integrasi data pada wilayah Surabaya Pusat (suf1) ditunjukkan pada Gambar 4.17.

Date	suf1_co	suf1_no2	suf1_o3	suf1_pm10	suf1_so2
01/01/2016	0.47	13.67	4.99	11.5	4.52
02/01/2016	0.38	2.81	25.94	8.05	4.5
03/01/2016	0.4	6.91	4.99	4.93	2.8
04/01/2016	0.6	2.66	24.24	17.77	3.64
05/01/2016	0.63	3.92	31.45	3.69	2.56
06/01/2016	0.52	5.58	29.45	11.25	1.74
07/01/2016	0.34	1.17	31.8	8.55	4.85
08/01/2016	0.36	14.44	32.61	6.29	4.09
09/01/2016	0.36	10.38	32.86	7.86	3.35
10/01/2016	0.37	8.25	28.14	23.43	4.21
11/01/2016	0.54	9.76	22.47	23.44	3.16

Gambar 4.17 Integrasi Data pada Stasiun Pemantau Wilayah Surabaya Pusat (SUF1-Taman Prestasi)

4.2.2.3 Integrasi Data pada Stasiun Pemantau Wilayah Surabaya Timur (SUF 6-Wonorejo)

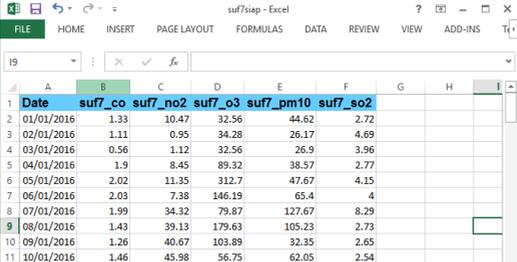
Persiapan data integrasi dari kelima parameter pada stasiun pemantau wilayah Surabaya Timur yang diletakkan pada daerah Wonorejo digunakan untuk proses *clustering* indeks kualitas udara yang hanya mempertimbangkan wilayah Surabaya Timur. Integrasi data pada wilayah Surabaya Timur (suf6) ditunjukkan pada Gambar 4.18.

Date	suf6_co	suf6_no2	suf6_o3	suf6_pm10	suf6_so2
01/01/2016	1.8	6.13	53.56	41.46	14.32
02/01/2016	1.81	10.04	37.1	19.26	21.41
03/01/2016	2.23	23.37	53.56	51.33	14.14
04/01/2016	1.94	24.31	40.17	36.44	15.25
05/01/2016	2.18	18.72	58.46	36.86	14.85
06/01/2016	2.32	30.92	71.53	42.74	14.75
07/01/2016	2.19	30.73	56.74	60.57	5.28
08/01/2016	2.06	24.36	50.36	73.47	19.45
09/01/2016	2.05	17.43	41.24	51.02	15.05
10/01/2016	1.95	30.27	59.69	68.86	15.01
11/01/2016	1.92	23.59	60.87	61.32	18.43
12/01/2016	1.94	34.18	57.3	71.01	15.23
13/01/2016	2.36	22.38	31.52	46.8	15.22
14/01/2016	2.2	14.07	40.97	37.64	14.6
15/01/2016	1.99	8.21	43.23	53.64	16.04

Gambar 4.18 Integrasi Data pada Stasiun Pemantau Wilayah Surabaya Timur (SUF 6-Wonorejo)

4.2.2.4 Integrasi Data pada Stasiun Pemantau Wilayah Surabaya Selatan (SUF 7-Kebonsari)

Persiapan data integrasi dari kelima parameter pada stasiun pemantau wilayah Surabaya Selatan yang diletakkan pada daerah Kebonsari digunakan untuk proses *clustering* indeks kualitas udara yang hanya mempertimbangkan wilayah Surabaya Selatan. Integrasi data pada wilayah Surabaya Selatan (suf7) ditunjukkan pada Gambar 4.19.



Date	suf7_co	suf7_no2	suf7_o3	suf7_pm10	suf7_so2
01/01/2016	1.33	10.47	32.56	44.62	2.72
02/01/2016	1.11	0.95	34.28	26.17	4.69
03/01/2016	0.56	1.12	32.56	26.9	3.96
04/01/2016	1.9	8.45	89.32	38.57	2.77
05/01/2016	2.02	11.35	312.7	47.67	4.15
06/01/2016	2.03	7.38	146.19	65.4	4
07/01/2016	1.99	34.32	79.87	127.67	8.29
08/01/2016	1.43	39.13	179.63	105.23	2.73
09/01/2016	1.26	40.67	103.89	32.35	2.65
10/01/2016	1.46	45.98	56.75	62.05	2.54

Gambar 4.19 Integrasi Data pada Stasiun Pemantau Wilayah Surabaya Selatan (SUF 7-Kebonsari)

4.2.3 Pembersihan Data

Pada Gambar 4.20 menunjukkan masukan, proses dan keluaran dari proses penghapusan *outlier*.



Gambar 4.20 Penghapusan *outlier* yakni pembersihan untuk proses *clustering*

Pada tahap pembersihan data, data-data yang tidak relevan itu juga lebih baik dibuang karena keberadaannya bisa mengurangi mutu atau akurasi dari hasil data mining nantinya. Pembersihan data juga akan mempengaruhi performansi dari sistem *data mining* karena data yang ditangani akan berkurang jumlah dan kompleksitasnya.

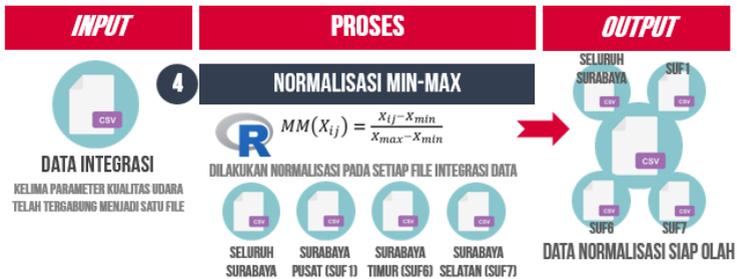
Perhatian utama algoritma deteksi outlier berbasis *clustering* adalah untuk menemukan *cluster* dan *outlier*, yang sering dianggap sebagai *noise* yang harus dihapus agar *clustering* lebih handal. Beberapa titik *noise* mungkin jauh dari titik data, sedangkan yang lainnya mungkin dekat. Titik *noise* yang jauh akan mempengaruhi hasilnya lebih signifikan karena lebih berbeda dari titik data. Tahap ini dilakukan pengidentifikasian dan menyingkirkan outlier, yang jauh dari semua titik lainnya di *cluster* [27]. Proses pengidentifikasian terhadap *outlier* dilakukan dengan menggunakan metode Tukey pada R. Metode Tukey's (1977) dengan membuat boxplot adalah alat grafis sederhana yang terkenal untuk menampilkan informasi tentang data univariat yang kontinu, seperti median, kuartil rendah, kuartil atas, ekstrem bawah, dan ekstrem atas kumpulan data [28].

4.2.4 Normalisasi Min-Max

Tahap ini bertujuan untuk melakukan standarisasi data, sehingga ketika dikelompokkan dengan algoritma K-Means tidak condong ke satu atribut yang nilainya lebih besar.

Nilai-nilai yang didapatkan memiliki perbedaan nilai yang cukup jauh sehingga memungkinkan tingkat ketidakakuratan hasil klaster yang didapatkan semakin besar.

Metode normalisasi yang digunakan adalah metode *min-max* yang mentransformasikan data sehingga memiliki rentang nilai antara 0 sampai 1.

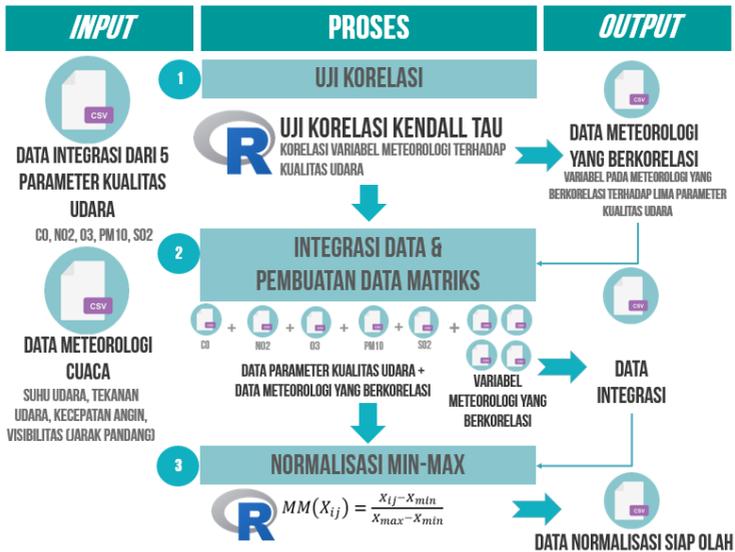


Gambar 4.21 Kerangka kerja normalisasi data untuk clustering

Berdasarkan kerangka kerja normalisasi data yang ditunjukkan pada Gambar 4.21, pada setiap *file* data yang merupakan data integrasi yang dilakukan pada proses persiapan sebelumnya, masing-masing *file* data dilakukan normalisasi dengan menggunakan metode min-max. Normalisasi data dilakukan pada *file* data dari seluruh stasiun pemantau di Surabaya, data pada stasiun wilayah Surabaya Pusat, data pada stasiun wilayah Surabaya Timur, data pada stasiun wilayah Surabaya Selatan.

4.3 Persiapan Data untuk Peramalan

Pada tahap ini dilakukan persiapan data untuk proses peramalan dari 5 parameter kualitas udara.



Gambar 4.22 Kerangka kerja proses persiapan data peramalan

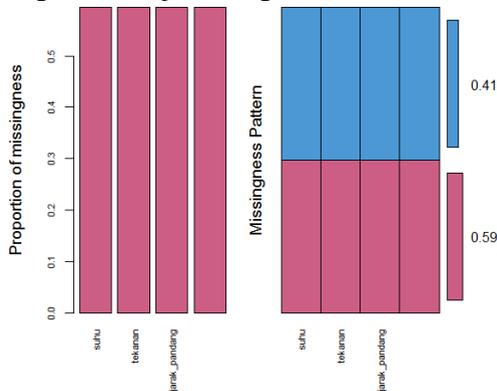
Pada Gambar 4.22 menjelaskan bahwa data masukan yang akan dipersiapkan berasal dari data integrasi kelima parameter kualitas udara yang telah dipersiapkan pada tahap persiapan data untuk *clustering*. Data kelima parameter yang telah menjadi satu file akan dilakukan uji korelasi dengan data meteorologi cuaca yang terdiri dari empat variabel yakni suhu udara, tekanan udara, kecepatan angin, jarak pandang. Selanjutnya jika terdapat variabel yang berkorelasi baik dengan data kelima parameter kualitas udara. Maka hanya variabel dari data meteorologi yang berkorelasi saja yang akan dilakukan penyatuan atau integrasi data. Kemudian data yang telah terintegrasi akan dinormalisasi menggunakan metode normalisasi min-max.

4.3.1 Interpolasi Data Peramalan

Pada tahap ini dilakukan interpolasi atau mengisi data yang *missing* atau hilang menggunakan R. Data yang akan diinterpolasi adalah data meteorologi yang terdiri dari data suhu

udara, tekanan, kecepatan angin dan jarak pandang. Data meteorologi merupakan data independen dari data polutan udara dimana data meteorologi ini akan dilakukan uji korelasi terhadap data polutan udara sebagai data dependen pada tahap selanjutnya.

Pada tahap interpolasi disini menggunakan metode *Predictive Mean Matching* (PMM) yang fungsinya telah disediakan di R dengan menggunakan *package* MICE dan VIM. Pada Gambar 4.23 menunjukkan jumlah proporsi data yang hilang pada data meteorologi yang meliputi variabel suhu udara, tekanan udara, jarak pandang dan kecepatan angin.



Gambar 4.23 Proporsi data *missing* pada data meteorologi

4.3.2 Uji Korelasi

Pada tahapan uji korelasi dilakukan pengujian terhadap keterkaitan data meteorologi dengan data polutan udara. Data meteorologi merupakan data independen yang terdiri dari variabel suhu udara, tekanan udara, jarak pandang dan kecepatan angin. Setiap variabel dari data meteorologi akan diuji korelasinya terhadap data utama polutan udara yang terdiri dari CO, NO₂, O₃, PM₁₀, SO₂.

4.3.3 Penentuan Data

Peramalan yang baik akan dapat dicapai dengan tersedianya informasi atau data dalam periode waktu yang memadai. Pada tugas akhir ini, terdapat data indeks kualitas udara Surabaya dalam tahun 2016 yakni 366 hari. Peramalan indeks kualitas udara yang akan dilakukan berbentuk periode harian, sehingga akan digunakan 366 data yang merupakan jumlah hari sejak 1 Januari 2016 hingga 31 Desember 2016 yang dapat dilihat pada lampiran A.

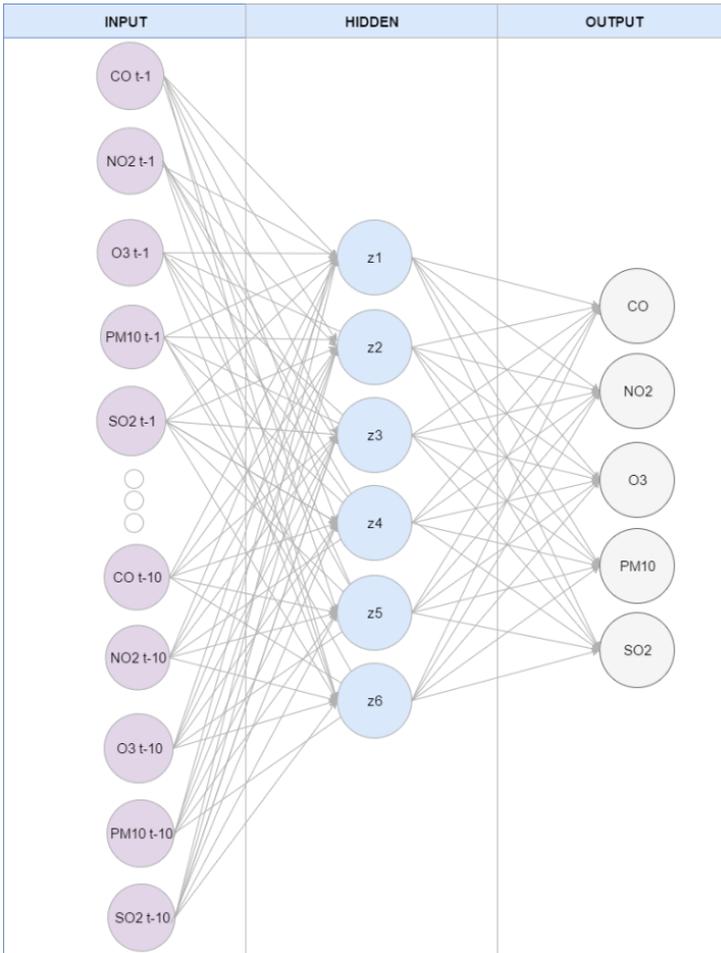
Model ANN pada dasarnya memiliki dua tahapan proses yang dapat dilakukan yaitu proses *training* dan *testing*. Pada tugas akhir ini, setiap model ANN memiliki data indeks kualitas yang dibagi menjadi 70% untuk proses *training*, 15% proses *testing* dari total 366 data kualitas udara Surabaya pada tahun 2016.

4.3.4 Model Artificial Neural Network

Data indeks kualitas udara menunjukkan bahwa tidak ada korelasi dengan variabel lain seperti data meteorologi (suhu, tekanan udara, jarak pandang, kecepatan angin). Rancangan model ANN yang digunakan dalam tugas akhir ini berbentuk *time series*, yaitu dengan melihat data hingga beberapa hari ke belakang untuk meramalkan kondisi polusi udara ke depan. Model ANN pada tugas akhir ini, terdiri dari *input layer* yang berisi neuron-neuron indeks kualitas udara pada masa lampau, *hidden layer* yang terdiri dari satu lapisan berisikan neuron-neuron dan *output layer* terdiri dari satu neuron, yaitu target indeks kualitas udara pada masing-masing variabel.

Proses pelatihan dengan menggunakan ANN berfungsi untuk melatih data dengan uji coba hingga terdapat beberapa model yang kemudian dipilih model terbaik. Hasil dari uji coba model yang digunakan adalah dengan nilai MAPE paling minimum. Untuk melakukan uji coba, dalam tugas akhir ini mencoba mengubah pada *input layer* dan *hidden layer*.

Pada Gambar 4.24 menunjukkan rancangan model *Artificial Neural Network* yang akan dilakukan pengujian cobaan dengan penggantian *input node*, *hidden node*, dan parameter terkait.



Gambar 4.24 Model *Artificial Neural Network*

Keterangan berdasarkan Gambar 4.24 adalah sebagai berikut :

$CO_{(t-1)}$ = Data variabel CO 1 hari sebelumnya

$NO2_{(t-1)}$ = Data variabel NO2 1 hari sebelumnya
 $O3_{(t-1)}$ = Data variabel O3 1 hari sebelumnya
 $PM10_{(t-1)}$ = Data variabel PM10 1 hari sebelumnya
 $SO2_{(t-1)}$ = Data variabel SO2 10 hari sebelumnya
 $CO_{(t-10)}$ = Data variabel CO 10 hari sebelumnya
 $NO2_{(t-10)}$ = Data variabel NO2 10 hari sebelumnya
 $O3_{(t-10)}$ = Data variabel O3 10 hari sebelumnya
 $PM10_{(t-10)}$ = Data variabel PM10 10 hari sebelumnya
 $SO2_{(t-10)}$ = Data variabel SO2 10 hari sebelumnya
 Z_1 = Jumlah neuron 1
 Z_2 = Jumlah neuron 2
 Z_3 = Jumlah neuron 3
 Z_4 = Jumlah neuron 4
 Z_5 = Jumlah neuron 5
 Z_6 = Jumlah neuron 6

4.3.5 Penentuan *Input Node*

Input data yang digunakan pada tugas akhir ini adalah lima variabel polutan udara yang meliputi Karbon monoksida, nitrogen dioksida, ozon, partikulat matter, dan sulfur dioksida mulai dari Januari 2016 hingga akhir Desember 2016. Data merupakan kandungan polutan harian dengan satuan ppm.

Data *input* yang akan digunakan dalam model ANN terdiri dari satu *input layer*. Satu *input layer* terdiri dari beberapa neuron. Setiap satu periode, *input node* berjumlah n , yakni n senilai 5. Sehingga ketika dua periode dan periode ketiga bernilai $2*n$ dan $3*n$, yakni sejumlah 10 node dan 15 node. Pada Tabel 4.3 menunjukkan jumlah *input node* setiap periode dimana n adalah sejumlah 5 *node*.

Tabel 4.3 Tabel jumlah *input node* setiap periode waktu

Periode	Rumus	Jumlah input node
Periode 1 hari sebelumnya	n	5
Periode 2 hari sebelumnya	$2n$	10
Periode 3 hari sebelumnya	$3n$	15

Periode	Rumus	Jumlah input node
.....		
Periode 10 hari sebelumnya	10n	50

4.3.6 Penentuan *Hidden Node*

Pada penelitian tugas akhir ini dilakukan *trial and error* terhadap banyaknya node yang digunakan pada *hidden layer*. Jumlah neuron pada *hidden* yang akan digunakan pada percobaan model terdiri antara 1 neuron sampai dengan 6 neuron pada setiap percobaan model.

4.3.7 Penentuan Parameter

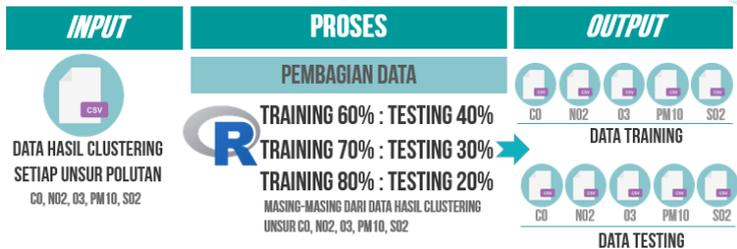
Parameter adalah nilai-nilai yang digunakan untuk mengenali pola data. Uji coba parameter penting dilakukan *trial and error* untuk mengetahui nilai parameter mana yang paling optimal yang dapat digunakan pada model yang telah ditentukan. Pengubahan terhadap parameter yang ada ditujukan untuk mencari MAPE yang paling rendah.

Berikut ini dijelaskan pengubahan parameter yang terdapat pada *package neuralnet* pada R dan digunakan pada penelitian tugas akhir ini:

- a. *Activation function* : fungsi terdiferensialkan yang digunakan untuk merapikan hasil produk silang dari kovariat atau neuron dan bobotnya. *Activation function* pada R terdiri dari dua jenis yakni “logistic” dan “tanh”.
- b. *Learning rate* : nilai numerik yang menentukan tingkat pembelajaran yang digunakan oleh backpropagation tradisional. Nilai *learning rate* yang digunakan adalah berkisar antara 0.1 sampai dengan 0.9 pada setiap percobaan model.
- c. *Stepmax / epoch* : langkah maksimal untuk melakukan pelatihan jaringan syaraf tiruan. Pelatihan akan mencapai maksimum sesuai dengan jumlah *stepmax* menyebabkan terhentinya proses pelatihan jaringan saraf. *Stepmax* yang

digunakan pada percobaan sejumlah 100000, 200000, dan 300000.

4.4 Persiapan Data untuk Klasifikasi



Gambar 4.25 Kerangka kerja proses persiapan data klasifikasi

Pada tugas akhir ini, terdapat data indeks kualitas udara Surabaya tahun 2016 yakni 366 hari. Data harian diberikan justifikasi label berdasarkan hasil analisa kelompok dari hasil *clustering*. Klasifikasi indeks kualitas udara yang akan dilakukan berbentuk periode harian, sehingga akan digunakan 366 data yang merupakan jumlah hari sejak 1 Januari 2016 hingga 31 Desember 2016 yang dapat dilihat pada lampiran A.

Data untuk proses klasifikasi dibagi menjadi data *training* 70% dan data *testing* 30% pada setiap variabel polutan udara yang akan diklasifikasikan. Data *training* sejumlah 256 data untuk menguji coba model dan data *testing* sejumlah 110 data untuk pengujian dari model dimana model akan dipilih berdasarkan akurasi terbaik dari pengujian model.

Pengontrolan data *train* dilakukan dengan menggunakan K-Fold *Cross Validation* dimana bertujuan melakukan pembagian data di dalam proses pencarian model menggunakan data *train* sehingga data sangat *fit* dengan model. Pada Gambar 4.26 menunjukkan data masukan untuk proses *cross validasi* dan proses pencarian model klasifikasi dengan metode Naive Bayes.

	CO	cluster	kategori
1	0.47	4	Sedang
2	0.38	1	Baik
3	0.40	4	Sedang
4	0.60	4	Sedang
5	0.63	4	Sedang
6	0.52	4	Sedang
7	0.34	1	Baik
8	0.36	1	Baik
9	0.36	1	Baik
10	0.37	1	Baik

Gambar 4.26 Tabel data persiapan klasifikasi

BAB V

IMPLEMENTASI

Pada bab ini, akan dijelaskan mengenai proses pengolahan data yang dilakukan. Data yang akan diolah didasarkan pada data yang diperoleh pada bab sebelumnya.

5.1 Lingkungan Implementasi

Lingkungan implementasi merupakan kriteria perangkat implementasi yang digunakan dalam mengimplementasikan model yang telah dibuat pada tugas akhir ini. Lingkungan implementasi terdiri dari perangkat keras dan perangkat lunak. Adapun perangkat keras yang digunakan ditunjukkan pada Tabel 5.1.

Tabel 5.1 Lingkungan Perangkat Keras Implementasi

Perangkat Keras	Spesifikasi
Jenis	Laptop
Processor	Intel(R) Core (TM) i3-3217U CPU @ 1.80GHz
RAM	6 GB
Hard Disk Drive	500 GB

Sementara untuk lingkungan perangkat lunak dalam implementasi program menggunakan spesifikasi dibawah ini. Spesifikasi perangkat lunak dapat dilihat pada Tabel 5.2.

Tabel 5.2 Lingkungan Perangkat Lunak Implementasi

Perangkat Lunak	Spesifikasi
Sistem Operasi	Windows
Bahasa Pemrograman	R
Menghitung Data	Microsoft Excel 2010
Interpolasi	SPSS
Uji Korelasi	R-Studio
Visualisasi dan Pengolahan Data	R-Studio

5.2 Persiapan Data *Clustering*

Persiapan data *clustering* yang diimplementasikan dalam proses melibatkan dua tahapan yakni penghapusan *outlier* dan normalisasi min-max.

5.2.1 Penghapusan *Outlier* Metode Tukey

Deteksi dan penghapusan *outlier* bertujuan untuk menghilangkan titik *noise* yakni seperti *outlier* pada data yang dapat mempengaruhi performa hasil *clustering* secara signifikan. Berikut ini merupakan langkah-langkah melakukan deteksi dan penghapusan *outlier* dengan metode Tukey menggunakan R.

1. Membaca dataset dengan format csv

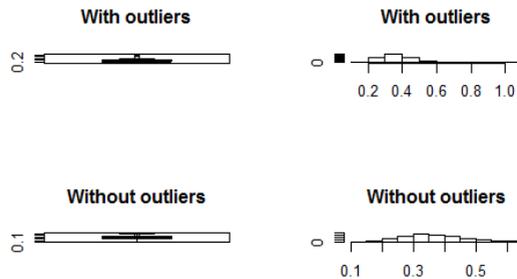
```
> dataoutlier = read.csv ("E:/2.Bismillah TA/Dataset/DATA FIX TA/DataReady/DataSiap.csv", sep=";")
```

2. Mendefinisikan fungsi deteksi & penghapusan *outlier* metode Tukey dengan nama *OutlierKD*

```
> outlierKD <- function(dt, var) {
+   var_name <- eval(substitute(var),eval(dt))
+   na1 <- sum(is.na(var_name))
+   m1 <- mean(var_name, na.rm = T)
+   par(mfrow=c(2, 2), oma=c(0,0,3,0))
+   boxplot(var_name, main="with outliers")
+   hist(var_name, main="with outliers", xlab=NA, ylab=NA)
+   outlier <- boxplot.stats(var_name)$out
+   mo <- mean(outlier)
+   var_name <- ifelse(var_name %in% outlier, NA, var_name)
+   boxplot(var_name, main="without outliers")
+   hist(var_name, main="without outliers", xlab=NA, ylab=NA)
+   title("Outlier Check", outer=TRUE)
+   na2 <- sum(is.na(var_name))
+   cat("Outliers identified:", na2 - na1, "\n")
+   cat("Propotion (%) of outliers:", round((na2 - na1) / sum
+ (is.na(var_name))*100, 1), "\n")
+   cat("Mean of the outliers:", round(mo, 2), "\n")
+   m2 <- mean(var_name, na.rm = T)
+   cat("Mean without removing outliers:", round(m1, 2), "\n")
+   cat("Mean if we remove outliers:", round(m2, 2), "\n")
+   response <- readline(prompt="Do you want to remove outlie
+ rs and to replace with NA? [yes/no]: ")
+   if(response == "y" | response == "yes"){
+     dt[as.character(substitute(var))] <- invisible(var_na
+ me)
+     assign(as.character(as.list(match.call())$dt), dt, en
+ vir = .GlobalEnv)
+     cat("Outliers successfully removed", "\n")
+     return(invisible(dt))
+   } else{
+     cat("Nothing changed", "\n")
+     return(invisible(var_name))
+   }
+ }
```

3. Memanggil fungsi `OutlierKD` untuk mendeteksi & menghapus *outlier*

```
> outlierKD(dataoutlier, suf1_co)
Outliers identified: 9 nProportion (%) of outliers: 2.5 nMean
of the outliers: 0.72 nMean without removing outliers: 0.37 n
Mean if we remove outliers: 0.37 n
Do you want to remove outliers and to replace with NA? [yes/n
o]: yes
Outliers successfully removed n
```



Gambar 5.1 Deteksi outlier metode Tukey pada R

Pada Gambar 5.2 menunjukkan hasil penghapusan *outlier* dengan metode Tukey dimana kolom data *outlier* yang terhapus diganti dengan NA (*not available*).

	Date	suf1_co	suf1_no2	suf1_o3	suf1_pm10	suf1_so2
35	04/02/2016	0.41	2.56	30.78	31.26	3.64
36	05/02/2016	0.39	2.30	34.82	NA	2.56
37	06/02/2016	0.32	2.01	33.78	28.55	1.74
38	07/02/2016	0.37	2.29	37.07	29.68	4.85
39	08/02/2016	0.29	2.84	31.35	35.22	4.09
40	09/02/2016	0.33	1.07	33.41	31.00	3.35
41	10/02/2016	0.41	1.65	35.52	31.49	4.21
42	11/02/2016	0.26	2.32	25.83	20.39	3.16
43	12/02/2016	0.27	4.78	32.67	50.56	3.73
44	13/02/2016	0.36	3.24	29.06	30.21	2.34
45	14/02/2016	0.51	3.64	15.44	40.16	2.65
46	15/02/2016	NA	4.99	20.40	44.63	2.40
47	16/02/2016	NA	4.91	22.42	40.50	6.31
48	17/02/2016	0.30	4.34	33.91	33.83	2.68
49	18/02/2016	0.30	4.48	22.95	35.61	2.87

Showing 34 to 50 of 366 entries

Gambar 5.2 Data outlier hasil penghapusan outlier dengan metode Tukey

4. Menghapus *record* data yang *not available* (NA) atau data *outlier* yang terhapus pada langkah 3

```
> dataoutlier=na.omit(dataoutlier)
```

Pada Gambar 5.3 menunjukkan bahwa baris data yang merupakan *outlier* pada tahap sebelumnya yang dinyatakan dengan NA telah terhapus pada langkah keempat dengan menggunakan `na.omit`.

	Date	suf1_co	suf1_no2	suf1_o3	suf1_pm10	suf1_so2
32	01/02/2016	0.33	1.19	32.84	27.98	4.49
33	02/02/2016	0.37	6.92	26.38	26.85	4.50
34	03/02/2016	0.34	4.94	25.21	23.91	2.80
35	04/02/2016	0.41	2.56	30.78	31.26	3.64
37	06/02/2016	0.32	2.01	33.78	28.55	1.74
38	07/02/2016	0.37	2.29	37.07	29.68	4.85
39	08/02/2016	0.29	2.84	31.35	35.22	4.09
40	09/02/2016	0.33	1.07	33.41	31.00	3.35
41	10/02/2016	0.41	1.65	35.52	31.49	4.21
42	11/02/2016	0.26	2.32	25.83	20.39	3.16
43	12/02/2016	0.27	4.78	32.67	50.56	3.73
44	13/02/2016	0.36	3.24	29.06	30.21	2.34
45	14/02/2016	0.51	3.64	15.44	40.16	2.65
48	17/02/2016	0.30	4.34	33.91	33.83	2.68
49	18/02/2016	0.30	4.48	22.95	35.61	2.87

Showing 30 to 46 of 349 entries

Gambar 5.3 Penghilangan baris data not available hasil penghapusan nilai outlier

Pendektesian dan penghapusan *outlier* dilakukan pada keempat *file* data integrasi yang telah disiapkan datanya pada proses sebelumnya. Setiap kolom atau variabel pada setiap *file* data integrasi akan dilakukan penghapusan *outlier* secara satu per satu dengan memanggil fungsi `OutlierKD` yang merupakan penerapan metode Tukey.

5.2.2 Normalisasi Min-Max

Normalisasi min-max bertujuan untuk mencari rentang nilai antara 0 sampai 1 pada seluruh variabel yang digunakan sebagai masukan. Berikut ini merupakan langkah-langkah normalisasi metode min-max dengan menggunakan *script* R.

5.2.2.1 Normalisasi data seluruh stasiun pemantau di Surabaya

Berikut ini merupakan langkah-langkah melakukan normalisasi dengan metode min-max pada seluruh pemantau kualitas udara Kota Surabaya yang masih aktif.

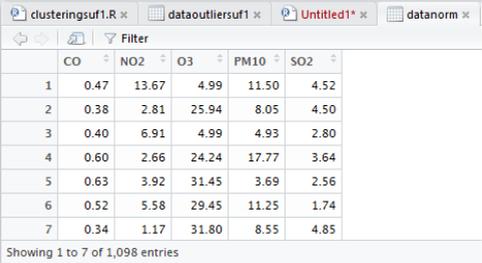
1. Menghilangkan variabel “date” pada data untuk normalisasi

```
> myvars <- names(datasiap) %in% c("Date", "stasiun")
> datanorm <- datasiap[!myvars]
```

Untuk melihat data siap dilakukan normalisasi maka menggunakan *script* berikut.

```
> view(datanorm)
```

Pada Gambar 5.4 menunjukkan data siap untuk dinormalisasi yang merupakan data gabungan kualitas udara di tiga stasiun pemantau kualitas udara di Surabaya.



	CO	NO2	O3	PM10	SO2
1	0.47	13.67	4.99	11.50	4.52
2	0.38	2.81	25.94	8.05	4.50
3	0.40	6.91	4.99	4.93	2.80
4	0.60	2.66	24.24	17.77	3.64
5	0.63	3.92	31.45	3.69	2.56
6	0.52	5.58	29.45	11.25	1.74
7	0.34	1.17	31.80	8.55	4.85

Showing 1 to 7 of 1,098 entries

Gambar 5.4 Data siap untuk normalisasi

2. Melakukan normalisasi dengan metode min-max

```
> normalized = (datanorm - min(datanorm)) / (max(datanorm) - min(datanorm))
```

Untuk melihat hasil data normalisasi, maka menggunakan *script* berikut.

```
> view(normalized)
```

Pada Gambar 5.5 merupakan data kualitas udara pada tiga stasiun pemantau di Surabaya setelah dilakukan normalisasi min-max.

	CO	NO2	O3	PM10	SO2
1	0.003498495	0.110894150	0.04027337	0.09323896	0.03644943
2	0.002766252	0.022536816	0.21072329	0.06516964	0.03628671
3	0.002928972	0.055894557	0.04027337	0.03978521	0.02245546
4	0.004556179	0.021316410	0.19689203	0.14425189	0.02928972
5	0.004800260	0.031567814	0.25555284	0.02969653	0.02050281
6	0.003905297	0.045073631	0.23928077	0.09120495	0.01383126
7	0.002440810	0.009193719	0.25840046	0.06923765	0.03913433
8	0.002603531	0.117158897	0.26499064	0.05085022	0.03295094

Showing 1 to 8 of 952 entries

Gambar 5.5 Data hasil normalisasi min-max seluruh stasiun pemantau udara Surabaya

3. Mengubah format data numerik ke vector

Untuk menampilkan visualisasi histogram perbandingan antara data sebelum dan sesudah normalisasi membutuhkan format data ke dalam bentuk vektor dengan *script* sebagai berikut.

```
> vectnorm=as.vector(as.matrix(datanorm))
> vectnormalized=as.vector(as.matrix(normalized))
```

4. Menampilkan visualisasi plot histogram perbandingan data

```
> par(mfrow=c(1,2))
> hist(vectnorm, breaks=10, xlab="Data",
col="orange", main="")
> hist(vectnormalized, breaks=10, xlab="Normalized
Data", col="orange", main="")
```

5.2.2.2 Normalisasi data pada setiap stasiun pemantau udara di wilayah Surabaya

Langkah untuk melakukan normalisasi data pada setiap stasiun pemantau di wilayah Surabaya yang meliputi Surabaya Pusat (suf1), Surabaya Timur (suf6), dan Surabaya Selatan (suf7). Berikut ini adalah *script* normalisasi min-max dengan langkah-langkah yang sama seperti sebelumnya yang menggunakan contoh Surabaya Pusat.

$$\text{normalizedsuf1} = \frac{\text{datanormsuf1} - \min(\text{datanormsuf1})}{\max(\text{datanormsuf1}) - \min(\text{datanormsuf1})}$$

View(normalizedsuf1)

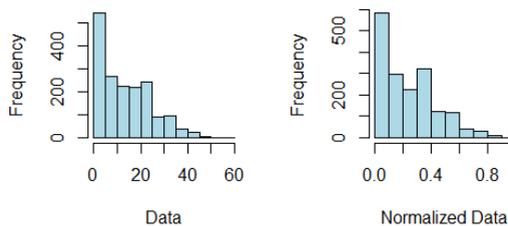
Pada Gambar 5.6 menunjukkan data setelah dilakukan normalisasi pada *dataset* suf1 yakni stasiun pemantau udara wilayah Surabaya Pusat.

	suf1_co	suf1_no2	suf1_o3	suf1_pm10	suf1_so2
1	0.006237747	0.24148993	0.0867938	0.20281590	0.07841739
2	0.004633755	0.04794154	0.4601675	0.14132953	0.07806095
3	0.004990198	0.12101230	0.0867938	0.08572447	0.04776332
4	0.008554625	0.04526822	0.4298699	0.31456068	0.06273392
6	0.007128854	0.09730886	0.5227232	0.19836036	0.02887186
7	0.003920870	0.01871324	0.5646052	0.15024060	0.08429870
8	0.004277312	0.25521297	0.5790412	0.10996257	0.07075388
9	0.004277312	0.18285511	0.5834967	0.13794333	0.05756550

Showing 1 to 8 of 349 entries

Gambar 5.6 Data hasil normalisasi min-max pada stasiun pemantau udara wilayah Surabaya Pusat

Berikut ini menunjukkan histogram perbandingan data tanpa normalisasi dengan data normalisasi pada *dataset* stasiun pemantau Surabaya Pusat (suf1-Taman Prestasi) yang ditunjukkan Gambar 5.7.



Gambar 5.7 Histogram perbandingan data tanpa normalisasi dengan data normalisasi pada stasiun pemantau udara bagian Surabaya Pusat (Suf1-Taman Prestasi)

5.3 Clustering dengan K-Means

Jumlah kluster yang digunakan pada percobaan adalah sejumlah lima kluster yang dipilih sesuai Indeks Standar Pencemar Udara (ISPU). Untuk mengetahui rentang indeks pencemar udara yang sesuai dengan kondisi Surabaya dan pada kondisi masing wilayah bagian Surabaya, maka pada tahap ini dapat dilakukan

proses *clustering* dengan menggunakan algoritma K-Means. Proses *clustering* yang dilakukan pada tahap ini menggunakan 24 kali proses *clustering* yang terangkum pada Tabel 5.3.

Tabel 5.3 Ringkasan Percobaan Clustering

Proses	Bagian	Parameter	Jumlah K
1	Seluruh Surabaya (Suf1, Suf6, Suf7)	CO, NO ₂ , O ₃ , PM ₁₀ , SO ₂	5
2		CO	5
3		NO ₂	5
4		O ₃	5
5		PM ₁₀	5
6		SO ₂	5
7	Surabaya Pusat (Suf1- Taman Prestasi)	CO, NO ₂ , O ₃ , PM ₁₀ , SO ₂	5
8		CO	5
9		NO ₂	5
10		O ₃	5
11		PM ₁₀	5
12		SO ₂	5
13	Surabaya Timur (Suf6- Wonorejo)	CO, NO ₂ , O ₃ , PM ₁₀ , SO ₂	5
14		CO	5
15		NO ₂	5
16		O ₃	5
17		PM ₁₀	5
18		SO ₂	5
19	Surabaya Selatan (Suf7- Kebonsari)	CO, NO ₂ , O ₃ , PM ₁₀ , SO ₂	5
20		CO	5
21		NO ₂	5
22		O ₃	5
23		PM ₁₀	5
24		SO ₂	5

5.3.1 *Clustering* Seluruh Stasiun Pemantau di Surabaya

Hasil dari *clustering* proses pertama ini berupa cluster rentang indeks sesuai kondisi udara di Surabaya yang menggunakan data seluruh stasiun pemantau udara yang aktif yakni tiga

bagian diantaranya stasiun Taman Prestasi, Wonorejo, Kebonsari.

Beberapa proses *clustering* yang dilakukan dari data integrasi kelima parameter di seluruh stasiun pemantau Surabaya yang mencakup Surabaya Pusat (suf1), Surabaya Timur (suf6), dan Surabaya Selatan (suf7) memiliki langkah-langkah pengerjaan dengan *R script* sebagai berikut.

A. *Clustering* 5 parameter udara dari 3 stasiun pemantau udara di Surabaya

1. Install *package* K-Means

```
> install.packages("kmeans")
```

2. Melakukan *clustering* dengan memanggil *library* K-Means

Proses *clustering* k-means menggunakan data normalisasi (*normalized*) dan jumlah k=5. Kemudian didefinisikan sebagai object dengan nama *clustering*

```
> clustering<-kmeans(normalized,5)
```

3. Melihat nilai *centroid* pada setiap *cluster* satu sampai dengan lima

```
> clustering$centers
```

Hasil titik *centroid* pada setiap *cluster* dengan memanggil *object* dengan nama *clustering* ditunjukkan seperti Gambar 5.8.

```
> clustering$centers
      CO      NO2      O3      PM10      SO2
1 0.001149920 0.02375724 0.04713593 0.04356420 0.02323171
2 0.001712044 0.03184817 0.18094179 0.11353280 0.04776610
3 0.002192997 0.03964304 0.09900096 0.08468882 0.04195374
4 0.003282081 0.04817601 0.50923642 0.10228352 0.02991330
5 0.003314676 0.06238910 0.08088964 0.17557067 0.03271490
```

Gambar 5.8 Hasil titik centroid pada setiap cluster dari data normalisasi

4. Menyimpan hasil *clustering* dengan membuat data *frame* (tabel)

```
> hasilclustering<-data.frame(datasiap,clustering$cluster)
```

Hasil *clustering* seperti yang ditunjukkan pada Gambar 5.9 berikut.

	Date	CO	NO2	O3	PM10	SO2	stasiun	clustering.cluster
483	26/04/2016	2.37	17.48	71.39	23.89	17.22	6	3
484	27/04/2016	0.61	20.48	93.10	45.35	21.21	6	2
485	28/04/2016	0.24	14.68	102.17	34.45	17.21	6	2
486	29/04/2016	0.25	8.10	83.69	26.13	17.90	6	2
487	30/04/2016	2.10	11.33	69.74	23.03	19.70	6	3
488	01/05/2016	0.19	12.84	46.22	16.27	17.67	6	1
489	02/05/2016	0.14	20.87	50.23	27.01	17.13	6	3
490	03/05/2016	0.13	15.42	57.70	15.39	17.52	6	3
491	04/05/2016	0.17	16.64	54.88	18.63	17.54	6	2

Showing 482 to 491 of 1,063 entries

Gambar 5.9 Tabel hasil clustering 5 parameter pada seluruh stasiun pemantau udara di Surabaya

B. *Clustering* pada setiap parameter udara (CO, NO₂, O₃, PM₁₀, SO₂) dari 3 stasiun pemantau udara di Surabaya

Proses *clustering* pada tahap ini hanya menggunakan parameter CO dari seluruh data integrasi di 3 stasiun pemantau aktif seluruh Surabaya yang aktif.

Berikut ini merupakan langkah-langkah *clustering* parameter CO di Surabaya.

1. Melakukan *clustering* parameter CO dengan memanggil *library* K-Means

Proses *clustering* k-means menggunakan data normalisasi (*normalized*) yang hanya diambil variabel ["CO"] dan jumlah k=5. Kemudian didefinisikan sebagai object dengan nama *clustersby_co*

```
> clustersby_co<-kmeans(normalized["CO"], 5)
```

2. Melihat nilai *centroid* pada setiap *cluster* satu sampai dengan lima pada hasil *cluster* parameter CO di seluruh wilayah Surabaya

```
> clustersby_co$centers
```

Hasil titik *centroid* pada setiap *cluster* dengan memanggil *object* dengan nama *clustersby_co* ditunjukkan seperti Gambar 5.10.

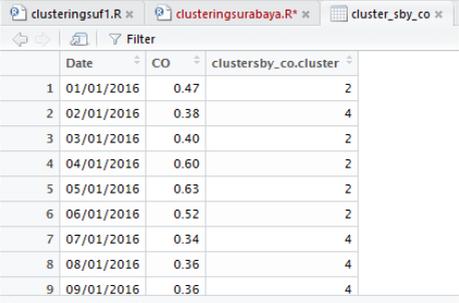
```
> clustersby_co$centers
      CO
1 0.0060703392
2 0.0010125290
3 0.0042293619
4 0.0004645717
5 0.0028677801
```

Gambar 5.10 Hasil titik centroid pada setiap cluster parameter CO di seluruh Surabaya dari data normalisasi

- Menyimpan hasil *clustering* dengan membuat data *frame* (tabel)

```
> cluster_sby_co <- data.frame(datasiap["Date"], datasiap["CO"], clustersby_co$cluster, datasiap["stasiun"])
```

Hasil *clustering* parameter CO di seluruh wilayah Surabaya seperti yang ditunjukkan pada Gambar 5.11 berikut.



	Date	CO	clustersby_co.cluster
1	01/01/2016	0.47	2
2	02/01/2016	0.38	4
3	03/01/2016	0.40	2
4	04/01/2016	0.60	2
5	05/01/2016	0.63	2
6	06/01/2016	0.52	2
7	07/01/2016	0.34	4
8	08/01/2016	0.36	4
9	09/01/2016	0.36	4

Showing 1 to 9 of 1,063 entries

Gambar 5.11 Tabel hasil clustering parameter CO pada seluruh stasiun pemantau udara di Surabaya

5.3.2 Clustering Setiap Stasiun Pemantau Udara Bagian Surabaya Pusat, Surabaya Timur dan Surabaya Selatan

Hasil dari *clustering* proses bagian kedua ini berupa hasil *clustering* pada masing-masing stasiun pemantau udara yakni suf1 yang mewakili Surabaya Pusat diletakkan di Taman Prestasi, suf6 yang mewakili Surabaya Timur diletakkan di daerah Wonorejo, dan suf7 yang mewakili Surabaya Selatan diletakkan di daerah Kebonsari.

Beberapa proses *clustering* yang dilakukan adalah integrasi data 5 parameter kualitas udara hanya pada bagian setiap wilayah yakni Surabaya Pusat, Surabaya Timur & Surabaya Selatan dan *clustering* pada masing-masing parameter kualitas udara di setiap bagian wilayah Surabaya. Beringkut ini adalah contoh implementasi proses *clustering* pada R yang menggunakan data wilayah Surabaya Pusat. Implementasi pada Surabaya Timur dan Selatan menggunakan proses dan *script* yang sama seperti contoh berikut.

A. *Clustering* 5 parameter udara pada setiap stasiun pemantau udara di setiap bagian wilayah Surabaya

1. Melakukan *clustering* dengan memanggil *library* K-Means

Proses *clustering* k-means menggunakan data normalisasi (*normalizedsuf1*) dan jumlah $k=5$. Kemudian didefinisikan sebagai object dengan nama *clusteringsuf1*

```
> clusteringsuf1<-kmeans(normalizedsuf1,5)
```

2. Melihat nilai *centroid* pada setiap *cluster* satu sampai dengan lima

```
> clusteringsuf1$centers
```

Hasil titik *centroid* pada setiap *cluster* dengan memanggil *object* dengan nama *clusteringsuf1* ditunjukkan seperti Gambar 5.12.

```
> clusteringsuf1$centers
      suf1_co  suf1_no2  suf1_o3  suf1_pm10  suf1_so2
1 0.004596082 0.1859660 0.4029875 0.2211017 0.09088275
2 0.004163899 0.1699810 0.3922295 0.6610068 0.34901249
3 0.005232882 0.1830523 0.6034954 0.3882988 0.37500806
4 0.003417826 0.1549462 0.2112239 0.3095159 0.32581737
5 0.004409541 0.1401079 0.4602940 0.5233211 0.07445341
```

Gambar 5.12 Hasil titik centroid pada setiap cluster dari data normalisasi lima parameter di Surabaya Pusat (suf1)

3. Menyimpan hasil *clustering* dengan membuat data *frame* (tabel)

```
> hasilclusteringsuf1<-data.frame(dataoutliersuf1,clusteringsuf1$cluster)
```

Hasil *clustering sufl* seperti yang ditunjukkan pada Gambar 5.13 berikut.

	Date	suf1_co	suf1_no2	suf1_o3	suf1_pm10	suf1_so2	clustering_suf1_cluster
1	01/01/2016	0.47	13.67	4.99	11.50	4.52	4
2	02/01/2016	0.38	2.81	25.94	8.05	4.50	1
3	03/01/2016	0.40	6.91	4.99	4.93	2.80	1
4	04/01/2016	0.60	2.66	24.24	17.77	3.64	1
6	06/01/2016	0.52	5.58	29.45	11.25	1.74	1
7	07/01/2016	0.34	1.17	31.80	8.55	4.85	1
8	08/01/2016	0.36	14.44	32.61	6.29	4.09	1
9	09/01/2016	0.36	10.38	32.86	7.86	3.35	1
10	10/01/2016	0.37	8.25	28.14	23.43	4.21	5

Showing 1 to 9 of 349 entries

Gambar 5.13 Tabel hasil clustering 5 parameter pada stasiun pemantau udara di Surabaya Pusat (suf1)

B. *Clustering* parameter udara CO (Karbon Monoksida) pada setiap stasiun pemantau udara di setiap bagian wilayah Surabaya

Proses *clustering* pada tahap ini hanya menggunakan parameter CO dari data kualitas udara di stasiun pemantau Surabaya Pusat yang diwakilkan oleh stasiun pemantau udara dan diletakkan di Taman Prestasi.

Berikut ini merupakan langkah-langkah *clustering* parameter CO di Surabaya bagian Pusat.

1. Melakukan *clustering* parameter CO dengan memanggil *library* K-Means

Proses *clustering* k-means menggunakan data normalisasi (*normalized*) yang hanya diambil variabel ["CO"] dan jumlah k=5. Kemudian didefinisikan sebagai object dengan nama *clustersuf1_co*

```
> clustersuf1_co<-kmeans(normalizedsuf1["suf1_co"],
```

2. Melihat nilai *centroid* pada setiap *cluster* satu sampai dengan lima pada hasil *cluster* parameter CO di wilayah Surabaya bagian Pusat

```
> clustersuf1_co$centers
```

Hasil titik *centroid* pada setiap *cluster* dengan memanggil *object* dengan nama *clustersuf1_co* ditunjukkan seperti Gambar 5.14.

```
> clustersuf1_co$centers
suf1_co
1 0.007795747
2 0.001716349
3 0.004538279
4 0.003192487
5 0.005925860
```

Gambar 5.14 Hasil titik centroid pada setiap cluster parameter CO pada Surabaya Pusat (suf1) dari data normalisasi

- Menyimpan hasil *clustering* dengan membuat data *frame* (tabel)

```
> cluster_suf1_co <- data.frame(dataoutliersuf1["Date"
], dataoutliersuf1["suf1_co"], clustersuf1_co$cluster)
```

Hasil *clustering* parameter CO di wilayah Surabaya bagian pusat seperti yang ditunjukkan pada Gambar 5.15 berikut.

	Date	suf1_co	clustersuf1_co.cluster
1	01/01/2016	0.47	5
2	02/01/2016	0.38	3
3	03/01/2016	0.40	3
4	04/01/2016	0.60	1
6	06/01/2016	0.52	1
7	07/01/2016	0.34	3
8	08/01/2016	0.36	3
9	09/01/2016	0.36	3
10	10/01/2016	0.37	3

Showing 1 to 9 of 349 entries

Gambar 5.15 Tabel hasil clustering parameter CO pada stasiun pemantau Surabaya bagian pusat (Suf1-Taman Prestasi)

C. *Clustering* parameter udara NO₂ (Nitrogen Dioksida) pada setiap stasiun pemantau udara di setiap bagian wilayah Surabaya

Proses *clustering* pada tahap ini hanya menggunakan parameter NO₂ hanya pada stasiun pemantau udara Surabaya bagian Pusat.

Berikut ini merupakan langkah-langkan *clustering* parameter NO₂ di Surabaya bagian Pusat.

1. Melakukan *clustering* parameter NO₂ dengan memanggil *library* K-Means

Proses *clustering* k-means menggunakan data normalisasi (*normalizedsuf1*) yang hanya diambil variabel ["suf1_no2"] dan jumlah k=5. Kemudian didefinisikan sebagai object dengan nama *clustersuf1_no2*

```
> clustersuf1_no2<-kmeans(normalizedsuf1["suf1_no2"],5)
```

2. Melihat nilai *centroid* pada setiap *cluster* satu sampai dengan lima pada hasil *cluster* parameter NO₂ di seluruh wilayah Surabaya

```
> clustersuf1_no2$centers
```

Hasil titik *centroid* pada setiap *cluster* dengan memanggil *object* dengan nama *clustersuf1_no2* ditunjukkan seperti Gambar 5.16.

```
> clustersuf1_no2$centers
  suf1_no2
1 0.12306492
2 0.32919711
3 0.06122894
4 0.24888727
5 0.17661516
```

Gambar 5.16 Hasil titik centroid pada setiap cluster parameter NO₂ pada Surabaya bagian Pusat (suf1-Taman Prestasi)

3. Menyimpan hasil *clustering* dengan membuat data *frame* (tabel)

```
> cluster_suf1_no2 <-data.frame(dataoutliersuf1["Date"],
,dataoutliersuf1["suf1_no2"],clustersuf1_no2$cluster)
```

Hasil *clustering* parameter NO₂ di sSurabaya bagian Pusat seperti yang ditunjukkan pada Gambar 5.17 berikut.

	Date	suf1_no2	clustersuf1_no2.cluster
1	01/01/2016	13.67	4
2	02/01/2016	2.81	3
3	03/01/2016	6.91	1
4	04/01/2016	2.66	3
6	06/01/2016	5.58	1
7	07/01/2016	1.17	3
8	08/01/2016	14.44	4
9	09/01/2016	10.38	5
10	10/01/2016	8.25	1

Showing 1 to 9 of 349 entries

Gambar 5.17 Tabel hasil clustering parameter NO₂ pada stasiun pemantau udara Surabaya Pusat (suf1-Taman Prestasi)

D. Clustering parameter udara O₃ (Ozon) pada setiap stasiun pemantau udara di setiap bagian wilayah Surabaya

Proses *clustering* pada tahap ini hanya menggunakan parameter O₃ pada stasiun pemantau udara Surabaya bagian Pusat.

Berikut ini merupakan langkah-langkah *clustering* parameter O₃ di Surabaya Pusat.

1. Melakukan *clustering* parameter O₃ dengan memanggil *library* K-Means

Proses *clustering* k-means menggunakan data normalisasi (*normalizedsuf1*) yang hanya diambil variabel ["suf1_o3"] dan jumlah k=5. Kemudian didefinisikan sebagai object dengan nama *clustersuf1_o3*

```
> clustersuf1_o3<-kmeans(normalizedsuf1["suf1_o3"],5)
```

2. Melihat nilai *centroid* pada setiap *cluster* satu sampai dengan lima pada hasil *cluster* parameter O₃ di wilayah Surabaya bagian pusat

```
> clustersuf1_o3$centers
```

Hasil titik *centroid* pada setiap *cluster* dengan memanggil *object* dengan nama *clustersuf1_o3* ditunjukkan seperti Gambar 5.18.

```
> clustersuf1_o3$centers
suf1_o3
1 0.6963999
2 0.1654125
3 0.4006772
4 0.5412362
5 0.2889346
```

Gambar 5.18 Hasil titik centroid pada setiap cluster parameter O₃ di wilayah Surabaya bagian pusat (suf1-Taman Prestasi)

- Menyimpan hasil *clustering* dengan membuat data *frame* (tabel)

```
> cluster_suf1_o3 <-data.frame(dataoutliersuf1["Date"],
dataoutliersuf1["suf1_o3"],clustersuf1_o3$cluster)
```

Hasil *clustering* parameter O₃ di seluruh wilayah Surabaya seperti yang ditunjukkan pada Gambar 5.19 berikut.

	Date	suf1_o3	clustersuf1_o3.cluster
1	01/01/2016	4.99	2
2	02/01/2016	25.94	3
3	03/01/2016	4.99	2
4	04/01/2016	24.24	3
6	06/01/2016	29.45	4
7	07/01/2016	31.80	4
8	08/01/2016	32.61	4
9	09/01/2016	32.86	4
10	10/01/2016	28.14	4

Showing 1 to 9 of 349 entries

Gambar 5.19 Tabel hasil clustering parameter O₃ pada stasiun pemantau udara wilayah Surabaya bagian pusat

E. *Clustering* parameter udara PM₁₀ (Partikulat Matter) pada setiap stasiun pemantau udara di setiap bagian wilayah Surabaya

Proses *clustering* pada tahap ini hanya menggunakan parameter PM₁₀ pada stasiun pemantau udara Surabaya bagian Pusat.

Berikut ini merupakan langkah-langkan *clustering* parameter PM₁₀ di Surabaya Pusat.

1. Melakukan *clustering* parameter PM₁₀ dengan memanggil *library* K-Means

Proses *clustering* k-means menggunakan data normalisasi (*normalizedsuf1*) yang hanya diambil variabel ["suf1_pm10"] dan jumlah k=5. Kemudian didefinisikan sebagai object dengan nama *clustersuf1_pm10*

```
> clustersuf1_pm10<-kmeans(normalizedsuf1["suf1_pm10"]
```

2. Melihat nilai *centroid* pada setiap *cluster* satu sampai dengan lima pada hasil *cluster* parameter PM₁₀ pada Surabaya Pusat

```
> clustersuf1_pm10$centers
```

Hasil titik *centroid* pada setiap *cluster* dengan memanggil *object* dengan nama *clustersuf1_pm10* ditunjukkan seperti Gambar 5.20.

```
> clustersuf1_pm10$centers
  suf1_pm10
1 0.1700473
2 0.2940427
3 0.7585835
4 0.4172162
5 0.5595810
```

Gambar 5.20 Hasil titik centroid pada setiap cluster parameter PM10 pada Surabaya bagian Pusat (suf1-Taman Prestasi)

3. Menyimpan hasil *clustering* dengan membuat data *frame* (tabel)

```
> cluster_suf1_pm10 <-data.frame(dataoutliersuf1["Date"],
,dataoutliersuf1["suf1_pm10"],clustersuf1_pm10$cluster)
```

Hasil *clustering* parameter PM₁₀ pada Surabaya bagian Pusat seperti yang ditunjukkan pada Gambar 5.21 berikut.

	Date	suf1_pm10	clustersuf1_pm10.cluster
1	01/01/2016	11.50	1
2	02/01/2016	8.05	1
3	03/01/2016	4.93	1
4	04/01/2016	17.77	2
6	06/01/2016	11.25	1
7	07/01/2016	8.55	1
8	08/01/2016	6.29	1
9	09/01/2016	7.86	1
10	10/01/2016	23.43	4

Showing 1 to 9 of 349 entries

Gambar 5.21 Tabel hasil clustering parameter PM10 pada stasiun pemantau wilayah Surabaya Pusat (suf1-Taman Prestasi)

F. *Clustering* parameter udara SO₂ (Sulfur Dioksida) pada stasiun pemantau udara di setiap bagian wilayah Surabaya

Proses *clustering* pada tahap ini hanya menggunakan parameter SO₂ pada stasiun pemantau udara Surabaya bagian Pusat.

Berikut ini merupakan langkah-langkan *clustering* parameter SO₂ di Surabaya Pusat.

1. Melakukan *clustering* parameter SO₂ dengan memanggil *library* K-Means

Proses *clustering* k-means menggunakan data normalisasi (*normalizedsuf1*) yang hanya diambil variabel ["suf1_so2"] dan jumlah k=5. Kemudian didefinisikan sebagai object dengan nama *clustersuf1_so2*

```
> clustersuf1_so2<-kmeans(normalizedsuf1["so2"],5)
```

2. Melihat nilai *centroid* pada setiap *cluster* satu sampai dengan lima pada hasil *cluster* parameter SO₂ di seluruh wilayah Surabaya Pusat.

```
> clustersuf1_so2$centers
```

Hasil titik *centroid* pada setiap *cluster* dengan memanggil *object* dengan nama *clustersuf1_so2* ditunjukkan seperti Gambar 5.22.

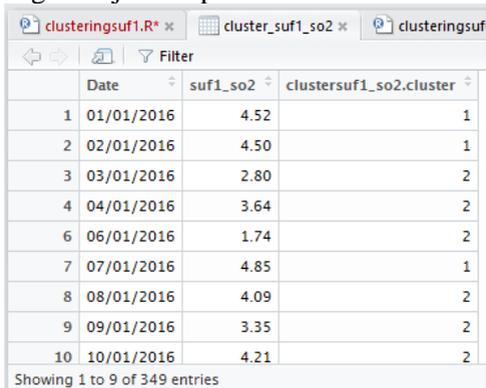
```
> clustersuf1_so2$centers
suf1_so2
1 0.09343805
2 0.05633623
3 0.37475866
4 0.16924027
5 0.33432174
```

Gambar 5.22 Hasil titik centroid pada setiap cluster parameter SO₂ pada stasiun pemantau Surabaya Pusat

- Menyimpan hasil *clustering* dengan membuat data *frame* (tabel)

```
> cluster_suf1_so2 <-data.frame(dataoutliersuf1["Date"
],dataoutliersuf1["suf1_so2"],clustersuf1_so2$cluster)
```

Hasil *clustering* parameter SO₂ pada Surabaya Pusat seperti yang ditunjukkan pada Gambar 5.23 berikut.



	Date	suf1_so2	clustersuf1_so2.cluster
1	01/01/2016	4.52	1
2	02/01/2016	4.50	1
3	03/01/2016	2.80	2
4	04/01/2016	3.64	2
6	06/01/2016	1.74	2
7	07/01/2016	4.85	1
8	08/01/2016	4.09	2
9	09/01/2016	3.35	2
10	10/01/2016	4.21	2

Showing 1 to 9 of 349 entries

Gambar 5.23 Tabel hasil clustering parameter SO₂ pada stasiun pemantau udara wilayah Surabaya Pusat

5.4 Uji Performa *Clustering*

Setelah dilakukan implementasi proses *clustering* yang menghasilkan beberapa model pada setiap proses, maka selanjutnya adalah melakukan uji performa pada setiap model yang dibangun untuk memilih model yang sebaiknya digunakan sampai proses analisis. Uji performa yang digunakan pada tahap

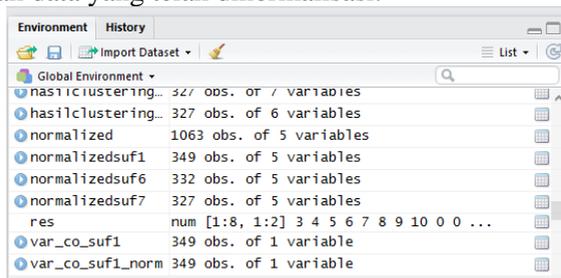
ini adalah menggunakan SSE, Dunn Index dan Silhouette yang diproses menggunakan *package* yang ada di R. Kemudian hasil nilai performa pada setiap metode analisa performa akan dibandingkan untuk menentukan model yang sesuai.

5.4.1 Sum Square Error (SSE)

SSE atau *Sum of Squared Error* merupakan sebuah metode yang paling umum untuk mengukur kevalidan sebuah hasil klusterisasi. Dalam sebuah klaster, error merupakan jarak dari sebuah titik dalam sebuah klaster ke titik pusat. Semakin kecil error, maka semakin baik performa hasil *clustering* tersebut. Sehingga SSE yang paling kecil dari model yang dibangun akan dipilih. Terdapat empat model yang dibangun pada proses *clustering*, dimana masing-masing model terdapat dua percobaan yakni ketika menggunakan data langsung kelima parameter atau menggunakan data yang di-*clustering* satu per satu pada masing-masing parameter kualitas udara.

Berikut ini adalah proses menghitung SSE menggunakan R.

1. Pilih data yang akan digunakan, data yang digunakan adalah data yang telah dinormalisasi.



Gambar 5.24 Objek data pada R

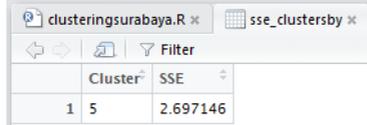
2. Masukkan *script* R seperti pada di bawah ini untuk melakukan proses SSE dengan jumlah *cluster* sebanyak 5.

```
> set.seed(6994)
> x <-normalized #memilih data
> sse_clustersby = kmeans(x, centers=5)$tot.withinss
#proses menghitung sse
> sse_clustersby=data.frame(c(5),c(sse_clustersby))
> names(sse_clustersby)[1]='cluster'
> names(sse_clustersby)[2]='SSE'
```

Untuk melihat hasil nilai SSE dengan jumlah *cluster*=5 maka menggunakan *script* berikut.

```
> View(sse_clustersby)
```

Kemudian akan muncul tabel hasil SSE seperti pada Gambar 5.25 berikut.



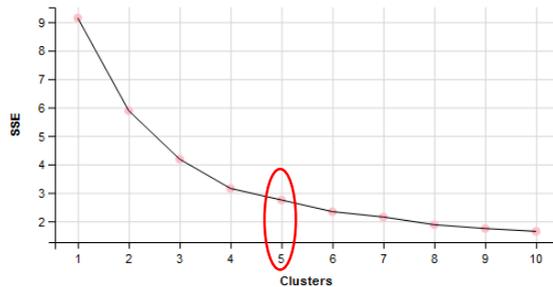
	Cluster	SSE
1	5	2.697146

Gambar 5.25 Tabel hasil nilai SSE

3. Untuk melihat hasil nilai perbandingan SSE dari *cluster* 1 sampai dengan 10, maka menggunakan *script* sebagai berikut.

```
> set.seed(6994)
> x <-normalized #memilih data
> sse_clustersby = kmeans(x, centers=1)$tot.withinss
#proses menghitung sse
> for (i in 2:10)
+   sse_clustersby[i] = kmeans(x, centers=i)$tot.wit
+   hinss
> library(ggvis) #memanggil library
> sse = data.frame(c(1:10), c(sse_clustersby))
> names(sse)[1] = 'Clusters'
> names(sse)[2] = 'SSE'
> sse %>% #membuat plot SSE
+   ggvis(~Clusters, ~SSE) %>%
+   layer_points(fill := 'pink') %>%
```

Hasil perbandingan nilai SSE mulai dari *cluster* 1 sampai dengan 10 ditunjukkan seperti pada plot grafik dari *package* *ggvis* pada Gambar 5.26 berikut.



Gambar 5.26 Hasil perbandingan nilai SSE pada R

- Selanjutnya pengujian performa menggunakan SSE diujikan ke 16 percobaan yang ada pada empat model *clustering* yang telah dibuat

5.4.1 Dunn Index

Uji performa Dunn Index digunakan untuk menguji algoritma *clustering*. Indeks Dunn adalah rasio jarak terkecil antara observasi yang tidak dalam cluster yang sama dengan jarak intra-cluster yang paling besar. Apabila semakin besar nilai indeks Dunn, maka semakin optimal hasil *cluster*.

Terdapat empat model yang dibangun pada proses *clustering*, dimana masing-masing model terdapat dua percobaan yakni ketika menggunakan data langsung kelima parameter atau menggunakan data yang di-*clustering* satu per satu pada masing-masing parameter kualitas udara.

Berikut ini adalah proses menghitung Dunn Index menggunakan R. Pemilihan klaster dengan metode *dunn index* dilakukan dengan melihat nilai *dunn index* yang paling maksimal. Untuk melihat nilai *dunn index* digunakan package **clValid**

- Memanggil library `clValid` kemudian memanggil data yang ternormalisasi (*normalized*)

```
> library("clValid")
> set.seed(6994)
> dunn_clustersbyco <- normalized["CO"] #memilih data
```

2. Proses melakukan pengujian *dunn index* dengan memakai *clvalid* yang disimpan dalam *object* '*intern_clustersby*'

```
> intern_clustersbyco <- clValid(dunn_clustersbyco, 3
:10, clMethods="kmeans", validation="internal")
```

3. Melihat hasil rangkuman dari proses pengujian *dunn index* dengan memanggil *object* '*intern_clustersby*'

```
summary(intern_clustersby)
```

Hasil *summary* dari *library* *clValid* ditunjukkan pada Gambar 5.27 berikut. Nilai *dunn* pada jumlah *cluster* 5 menunjukkan angka 0,0211. Sedangkan nilai yang optimal pada *dunn* adalah dengan jumlah *cluster* 5.

```
> summary(intern_clustersbyco)

Clustering Methods:
kmeans

Cluster sizes:
 3 4 5 6 7 8 9 10

Validation Measures:

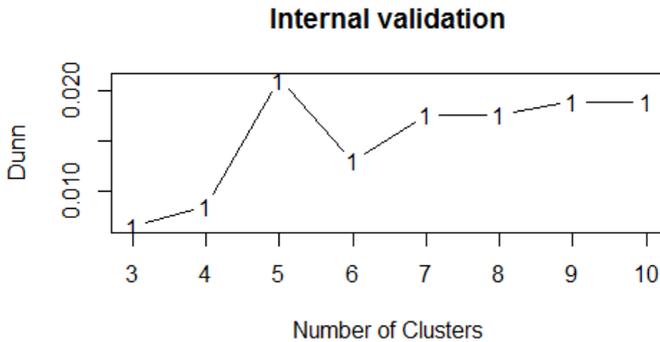
           3         4         5         6         7         8         9         10
kmeans Connectivity 12.3929 10.7468 13.4532 20.1369 30.5044 21.6690 28.4151 34.1611
Dunn              0.0065  0.0085 0.0211 0.0130  0.0175  0.0175  0.0189  0.0189
Silhouette        0.7287  0.7204  0.7013  0.6962  0.5943  0.5560  0.5519  0.5521

Optimal Scores:

      Score Method Clusters
Connectivity 10.7468 kmeans 4
Dunn         0.0211 kmeans 5
Silhouette   0.7287 kmeans 3
```

Gambar 5.27 Hasil *internal validation clustering* menggunakan *clValid* pada R

Pada Gambar 5.28 berikut ini merupakan plot grafik indeks *dunn* yang membandingkan hasil indeks ketika *cluster* berjumlah antara 3 hingga 10. Sedangkan nilai indeks *dunn* yang paling optimal yakni yang paling besar terdapat pada jumlah *cluster* sama dengan 5.



Gambar 5.28 Validasi internal Indeks Dunn

5.4.2 Silhouette

Indek silhouette adalah jarak rata-rata untuk elemen dalam cluster yang sama dengan jarak rata-rata untuk elemen dalam cluster lainnya. Objek dengan nilai siluet tinggi dianggap baik karena sifatnya yang berkerumun, objek dengan nilai yang rendah mungkin bersifat outlier. Objek yang berkerumun memiliki nilai mendekati 1 dan objek yang buruk memiliki nilai mendekati -1.

Berikut ini adalah proses menghitung Silhouette menggunakan R. Pemilihan kluster dengan metode *dunn index* dilakukan dengan melihat nilai *silhouette index* yang paling maksimal. Untuk melihat nilai *silhouette index* digunakan package **cIValid**

1. Memanggil library `cIValid` kemudian memanggil data yang ternormalisasi (*normalized*)

```
> library("cIValid")
> set.seed(6994)
> silhouette_clustersbyco <- normalized["CO"] #memilih data
```

2. Proses melakukan pengujian *silhouette* dengan memakai `cIvalid` yang disimpan dalam *object* 'intern_clustersby'

```
> intern_clustersbyco <- cIValid(silhouette_clustersbyco, 3:10, cIMethods="kmeans", validation="internal")
```

3. Melihat hasil rangkuman dari proses pengujian *silhouette index* dengan memanggil *object* ‘*intern_clustersby*’

```
summary(intern_clustersby)
```

Hasil *summary* dari *library* *clValid* ditunjukkan pada Gambar 5.29 berikut. Nilai *dunn* pada jumlah *cluster* 5 menunjukkan angka 0,7013.

```
> summary(intern_clustersbyco)

Clustering Methods:
kmeans

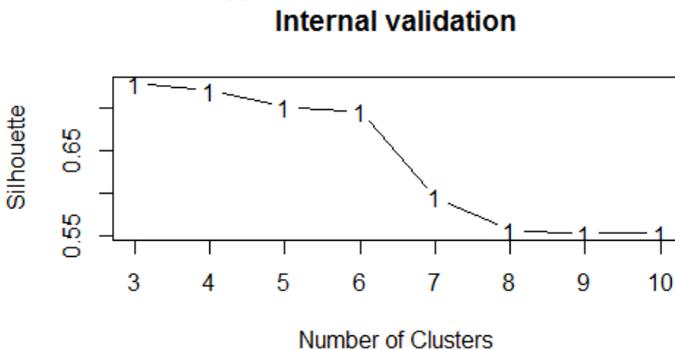
Cluster sizes:
3 4 5 6 7 8 9 10

Validation Measures:
                 3      4      5      6      7      8      9      10
kmeans Connectivity 12.3929 10.7468 13.4532 20.1369 30.5044 21.6690 28.4151 34.1611
      Dunn          0.0065  0.0085  0.0211  0.0130  0.0175  0.0175  0.0189  0.0189
      Silhouette    0.7287  0.7204  0.7013  0.6962  0.5943  0.5560  0.5519  0.5521

Optimal Scores:
           Score Method Clusters
Connectivity 10.7468 kmeans 4
      Dunn          0.0211 kmeans 5
      Silhouette    0.7287 kmeans 3
```

Gambar 5.29 Rangkuman hasil uji performa *silhouette index*

Berikut ini Gambar 5.30 menunjukkan plot gambar grafik hasil nilai indeks *silhouette* yang memiliki nilai indeks masih baik antara *cluster* 3 hingga 5.



Gambar 5.30 Validasi internal silhouette

5.5 Persiapan Data Peramalan

Implementasi *script* pada data peramalan terdiri dari tahap interpolasi data meteorologi yakni mengisi data *missing value* dan melakukan uji korelasi

5.5.1 Interpolasi Data Meteorologi

Interpolasi data meteorologi menggunakan metode *Predictive Mean Matching* untuk mengisi data yang hilang pada variabel suhu, tekanan, jarak pandang dan kecepatan angin. *Package* yang dibutuhkan untuk mengisi *missing value* menggunakan PMM adalah *MICE* dan *VIM*. Berikut ini adalah proses mengisi data yang hilang dengan metode PMM menggunakan *R script*.

1. Melihat jumlah data yang hilang pada masing-masing variabel pada data meteorologi

```
> cuaca = read.csv ("cuaca.csv", sep=";", header = T,
na.strings = "") #mendefinisikan objek data
> summary(cuaca) #melihat rangkuman nilai NA
```

Hasil *summary* data menunjukkan bahwa jumlah data yang hilang pada masing-masing variabel sejumlah 217 data

suhu	tekanan	jarak_pandang	kecepatan_angin
Min. :78.90	Min. :1005	Min. :4.200	Min. :0.000
1st Qu.:82.70	1st Qu.:1009	1st Qu.:5.800	1st Qu.:1.675
Median :84.10	Median :1010	Median :6.200	Median :2.600
Mean :84.28	Mean :1010	Mean :5.907	Mean :2.759
3rd Qu.:86.22	3rd Qu.:1010	3rd Qu.:6.200	3rd Qu.:3.800
Max. :89.10	Max. :1012	Max. :6.200	Max. :7.000
NA's :217	NA's :217	NA's :217	NA's :217

2. Melakukan pengisian data yang hilang dengan metode PMM (*Predictive Mean Matching*)

```
> tempData <- mice(cuaca,m=5,maxit=50,meth='pmm',seed=500)

iter imp variable
1 1 suhu tekanan jarak_pandang kecepatan_angin
1 2 suhu tekanan jarak_pandang kecepatan_angin
1 3 suhu tekanan jarak_pandang kecepatan_angin
1 4 suhu tekanan jarak_pandang kecepatan_angin
1 5 suhu tekanan jarak_pandang kecepatan_angin
2 1 suhu tekanan jarak_pandang kecepatan_angin
2 2 suhu tekanan jarak_pandang kecepatan_angin
2 3 suhu tekanan jarak_pandang kecepatan_angin
2 4 suhu tekanan jarak_pandang kecepatan_angin
2 5 suhu tekanan jarak_pandang kecepatan_angin
```

3. Melihat rangkuman hasil pengisian data hilang dari proses metode PMM

```
> summary(tempData)
```

Hasil *summary* adalah sebagai berikut.

Multiply imputed data set

Call:

```
mice(data = cuaca, m = 5, method = "pmm", maxit = 50, seed = 500)
Number of multiple imputations: 5
```

Missing cells per column:

```

      suhu          tekanan  jarak_pandang  kecepatan_angin
      218            218            218            218
Imputation methods:
      suhu          tekanan  jarak_pandang  kecepatan_angin
      "pmm"         "pmm"    "pmm"         "pmm"
VisitSequence:
      suhu          tekanan  jarak_pandang  kecepatan_angin
      1            2            3            4
PredictorMatrix:
      suhu  tekanan  jarak_pandang  kecepatan_angin
suhu      0          1          1          1
tekanan   1          0          1          1
jarak_pandang 1          1          0          1
kecepatan_angin 1          1          1          0
Random generator seed value: 500
```

5.5.2 Uji Korelasi Data Meteorologi terhadap Data Polutan Udara

Penjelasan mengenai *script* melakukan uji korelasi data meteorologi terhadap data polutan di R adalah sebagai berikut.

1. Melakukan corellation testing pada objek data `dfx1y1` variabel CO terhadap objek data `dfx1y1` variabel suhu dengan metode “kendall”

```
> cor.test(dfx1y1$CO, dfx1y1$suhu, method="kendall")
```

Hasil uji korelasi kendall rank correlation adalah sebagai berikut.

Kendall's rank correlation tau

data: dfx1y1\$CO and dfx1y1\$suhu

z = 1.9375, p-value = 0.05268

alternative hypothesis: true tau is not equal to 0

sample estimates:

```
tau
0.0687076
```

5.6 Peramalan dengan Artificial Neural Network

Tahap peramalan dengan *Artificial Neural Network* terdiri dari dua proses yakni pembuatan model peramalan ANN dan penerapan model untuk meramalkan ke depan. Metode ANN pada R membutuhkan *package neuralnet*.

5.6.1 Pembuatan Model Peramalan ANN

1. Melakukan pembagian data *training* 70% dan data *testing* 30% dari total data.

```
> data <- data1_suf1 #Ngganti variable disini
> index <- round(0.7*nrow(data)) #Proporsi train-
test
> train <- data[1:index,]
> test <- data[-(1:index),]
```

2. Melakukan normalisasi min-max untuk mendapatkan rentang nilai 0 sampai 1

```
#Normalisasi
> maxs <- apply(data, 2, max)
> mins <- apply(data, 2, min)
> scaled <- as.data.frame(scale(data, center = mi
ns, scale = maxs - mins))
> train_ <- scaled[1:index,]
> test_ <- scaled[-(1:index),]
> test_ <- na.omit(test_)
```

3. Mendeklarasikan parameter pada objek data seperti node *hidden*, *learning rate*, *activation function* dan *stepmax*

```
> z<-0
> nodes1<-c(1,2,3,4,5,6) #Hidden Layer 1
> transf<-c("logistic", "tanh") #Fungsi Transfer
ada 2 macam
> lrate <-c(0.1,0.2,0.3,0.4,0.5,0.6,0.7,0.8,0.9)
> stepmax <-c(1e+05,2e+05,3e+05)

> J=length(transf)
> K=length(lrate)
> H=length(nodes1)
> I=length(stepmax)
```

4. Membuat array vector dengan *mode numeric* yang berisi keempat parameter yang digunakan untuk *looping* pada tahap selanjutnya.

```
> result1_1period_suf1<-array(vector(mode = 'numeric'), c(H*I*
J*K,6))
> dimnames(result1_1period_suf1)[[2]]<-c("Hidden1","Stepmax/ep
och","Fungsi Aktivasi", "Lrate","MAPE.train","MAPE.test" )
```

5. Membuat *looping* untuk menjalankan parameter-parameter yang telah dideklarasikan kedalam *array* dan menjalankan algoritma pembuatan model ANN di dalam *package neuralnet*.

```
> for(k in 1:K) { #looping parameter learning rate
+   for(j in 1:J) { #looping parameter transfer function
+     for(i in 1:I){ #looping parameter stepmax
+       for(h in 1:H){ #looping parameter hidden node
+         set.seed(123)
+         z<-z+1
+         nn <- neuralnet(f,data=train_,hidden=(nodes1[h]),stepmax =
+           (stepmax[j]), act.fct=transf[j],learningrate =
+           lrate[k],linear.output=T)
+         pr.nn.test <- compute(nn,test_[,1:jumlahinput]) #Hasilpredi
ksi test masih normalisasi
+         pr.nn.train <- compute(nn,train_[,1:jumlahinput]) #Hasil pr
ediksi train masih normalisasi
+         pr.nn.train_ <-data.frame(array(vector(mode = 'numeric'),
+           c(nrow(pr.nn.train$net.result),ncol(pr.nn.tr
ain$net.result))))
+         pr.nn.test_ <-data.frame(array(vector(mode = 'numeric'),
+           c(nrow(pr.nn.test$net.result),ncol(pr.nn.test
$net.result))))
```

6. Melakukan denormalisasi dari hasil prediksi pada setiap percobaan parameter yang di-*looping*

```
+ #Hasilnya di denormalisasi
+ for(l in 1:nrow(pr.nn.test$net.result)) {
+   pr.nn.test_[l,] <-
+   pr.nn.test$net.result[l,]*(maxs[6:10]-mins[6:10])+mins[6:10]
+   }
+   test.r.test <- test[,6:10]
+
+
+   for(l in 1:nrow(pr.nn.train$net.result)) {
+     pr.nn.train_[l,] <-
+     pr.nn.train$net.result[l,]*(maxs[6:10]-mins[6:10])+mins[6:10]
+   }
+   test.r.train <- train[,6:10]
```

- Melakukan perhitungan MAPE pada hasil prediksi *training* dan *testing* dengan melakukan rata-rata MAPE pada setiap variabel polutan udara.

```

+ MAPE.nn.train_ <- (colMeans(abs(test.r.train - pr.nn.train_)/t
est.r.train))
+ MAPE.nn.train <- percent(mean(as.numeric(MAPE.nn.train_)))
+
+ MAPE.nn.test_ <- (colMeans(abs(test.r.test - pr.nn.test_)/test
.r.test))
+ MAPE.nn.test <- percent(mean(as.numeric(MAPE.nn.test_)))
+
+     result1_lperiod_suf1[z,1] <- nodes1[h]
+     result1_lperiod_suf1[z,2] <- stepmax[i]
+     result1_lperiod_suf1[z,3] <- transf[j]
+     result1_lperiod_suf1[z,4] <- lrate[k]
+     result1_lperiod_suf1[z,5] <- MAPE.nn.train
+     result1_lperiod_suf1[z,6] <- MAPE.nn.test
+   }
+ }
+ }
+ }

```

5.6.2 Penerapan Model Peramalan ANN

Pada tahap ini merupakan tahap penerapan model yang telah ditentukan berdasarkan uji performa model terbaik pada tahap sebelumnya. Model ANN yang terbaik akan diterapkan parameter, *input node*, dan *hidden node* untuk melakukan peramalan pada satu tahun kedepan.

- Membaca data matriks setiap periode yang siap olah dan melakukan normalisasi min-max pada data.

```

> data <- read.csv("E:/2.Bismillah TA/KnowledgeDiscovery
/Data ANN/data1_suf1_5target.csv", sep=";")
> maxs <- apply(data, 2, max)
> mins <- apply(data, 2, min)
> scaled <- as.data.frame(scale(data, center = mins, sca
le = maxs - mins))
> maxData <- maxs[1:5]
> minData <- mins[1:5]
> Zdata<- scaled[,1:5]

```

- Membuat *formula* dan menetapkan parameter untuk penerapan model yang merupakan model dengan uji performa terbaik .

```

> library(neuralnet)
# mendeklarasikan formula untuk model
> f <- as.formula(paste("target_suf1_CO+target_suf1_N
O2+target_suf1_O3+target_suf1_PM10+target_suf1_SO2~",
+ paste("aktual1_suf1_CO+aktual1_suf1_NO2+aktual1_suf1_O3+aktual1_suf1_PM10+aktual1_suf1_SO2"))
+ , collapse = " + "))
# menerapkan model dengan parameter yang ditentukan
> modelnn <- neuralnet(f,data=train_,hidden=(3),stepm
ax = (100000),
+ act.fct="logistic",learningrat
e = 0.1,linear.output=T)

```

3. Melakukan *looping* untuk melakukan peramalan kedepan dengan menjalankan “modelnn” yang telah dideklarasikan pada proses sebelumnya.

```

> set.seed(123)
> for(k in 1:365) {
+   temp <- compute(modelnn,Zdata[nrow(Zdata),])
+   Zdata[nrow(Zdata)+1,] <- temp$net.result
+ }
> HasilData <-data.frame(array(vector(mode = 'numeric
'),
+                               c(nrow(Zdata),ncol(Zda
ta))))
#melakukan denormalisasi Hasil Data Peramalan
> for(l in 1:nrow(Zdata)) {
+   HasilData[l,] <- Zdata[l,] *(maxData-minData)+mi
nData
+ }
> colnames(HasilData) <- c("CO", "NO2", "O3", "PM10",
"SO2")

```

5.7 Klasifikasi dengan Metode Naive Bayes

Berikut ini merupakan implementasi *script* ketika menggunakan metode Naive Bayes pada R.

5.7.1 Pembuatan Model Klasifikasi

1. Memanggil library yang dibutuhkan dan mendeklarasikan data hasil proses *clustering* sebagai objek data dengan nama “klasifikasi_PM10”

```
> library(NLP)
> library(tm)
> library(e1071)
> library(httr)
> library(MLmetrics)
> library(scales)
> #Data siap untuk klasifikasi
> myvars <- names(cluster_sby_pm10) %in% c("date","stasiun")
> klasifikasi_PM10 <- cluster_sby_pm10[!myvars]
```

2. Mendeklarasikan kelas label dari hasil *clustering* menjadi nama kelas kategori polutan udara dengan menggunakan *nested logical conditional*.

```
> klasifikasi_PM10$classcluster <-
+ ifelse(klasifikasi_PM10$cluster == 1, "Sedang",
+ (ifelse(klasifikasi_PM10$cluster == 2, "Baik",
+ (ifelse(klasifikasi_PM10$cluster == 3, "Sangat Baik",
+ (ifelse(klasifikasi_PM10$cluster == 4, "Tidak Baik",
+ (ifelse(klasifikasi_PM10$cluster == 5, "Sangat Tidak Baik"
+ ""))))))
+ )))
> colnames(klasifikasi_PM10) <- c("PM10","cluster", "kategori
")
> klasifikasi_PM10=klasifikasi_PM10[-2]
```

3. Melakukan pelabelan nama kelas dari hasil *cluster* yang terbentuk.

```
> klasifikasi_PM10$classcluster <-
+ ifelse(klasifikasi_PM10$cluster == 1, "Sedang",
+ (ifelse(klasifikasi_PM10$cluster == 2, "Baik",
+ (ifelse(klasifikasi_PM10$cluster == 3, "Sangat Baik",
+ (ifelse(klasifikasi_PM10$cluster == 4, "Tidak Baik",
+ (ifelse(klasifikasi_PM10$cluster == 5, "Sangat Tidak Baik"
+ ""))))))
+ )))
> colnames(klasifikasi_PM10) <- c("PM10","cluster", "kategori
")
> klasifikasi_PM10=klasifikasi_PM10[-2]
```

4. Melakukan pembagian data *training* dan *testing* untuk tiga percobaan model yakni 60% banding 40%, 70% banding 30%, dan 80% banding 20%.

```
#bagi data train 60% test 40%
smp_size <- floor(0.6 * nrow(klasifikasi_PM10))
## set the seed to make your partition reproducible
train_ind1 <- sample(seq_len(nrow(klasifikasi_PM10)), size =
smp_size)

train1_PM10 <- klasifikasi_PM10[train_ind1, ]
test1_PM10 <- klasifikasi_PM10[-train_ind1, ]
```

5. Membuat model klasifikasi pada setiap percobaan dari tiga pembagian data *training* dan *testing* yang berbeda.

```
library(e1071)
library(caret)
library(klaR)
#MODEL 1 - 60 train 40 test
#buat model-data train
x1 = train1_PM10[-2]
y1 = train1_PM10$kategori
a1 = test1_PM10[-2]
b1 = test1_PM10$kategori

model1_PM10 = train(x1,y1,'nb',trControl=trainControl(method=
'cv',number=10))
```

6. Melakukan prediksi dengan mengujicobakan setiap model dengan 3 proporsi data yang berbeda.

```
#prediksi-data training & testing model 1- 60% : 40%
prediksitrain1_PM10=predict(model1_PM10$finalModel,x1)
table(predict(model1_PM10$finalModel,x1)$class,y1) #confussio
n matrix training
prediksitrain1_PM10
prediksitest1_PM10=predict(model1_PM10$finalModel,a1)
table(predict(model1_PM10$finalModel,a1)$class,b1) #confussio
n matrix testing
prediksitrain1_PM10
```

Pada Gambar 5.31 menunjukkan salah satu contoh hasil *confussion matrix* pada klasifikasi model 1 unsur PM10.

```
> table(predict(model1_PM10$finalModel,a1)$class,b1) #confussion matrix testing
      b1
      Baik Sangat Baik Sangat Tidak Baik Sedang Tidak Baik
Baik      82          0          1          0          2
Sangat Baik 0         105        0          0          0
Sangat Tidak Baik 0          0         85          3          0
Sedang      0          0          0         108         0
Tidak Baik  0          0          0          0          40
```

Gambar 5.31 *Confussion Matrix* Model 1 Unsur PM10

7. Melakukan uji akurasi pada setiap percobaan model yang terbentuk dari setiap proporsi data yang berbeda.

```
#Uji akurasi Model 1
akurasi_train1_PM10<-percent(Accuracy(prediksi_train1_PM10$class,train1_PM10[,2]))
akurasi_train1_PM10
akurasi_test1_PM10<-percent(Accuracy(prediksi_test1_PM10$class,test1_PM10[,2]))
akurasi_test1_PM10
```

Pada Gambar 5.32 menunjukkan hasil nilai akurasi dari fungsi *Accuracy* pada *package* *Caret* untuk menghitung akurasi model dari hasil prediksi dibandingkan dengan nilai sebenarnya.

```
> akurasi_train1_PM10<-percent(Accuracy(prediksi_train1_PM10$class,train1_PM10[,2]))
> akurasi_train1_PM10
[1] "99.4%"
> akurasi_test1_PM10<-percent(Accuracy(prediksi_test1_PM10$class,test1_PM10[,2]))
> akurasi_test1_PM10
[1] "98.6%"
```

Gambar 5.32 Uji Akurasi Model pada Data *Training* dan *Testing* Model 1 Unsur PM10

8. Menyimpan model terbaik ke dalam format RDS dengan nama "modelNB_PM10.rds".

```
saveRDS(model2_PM10,"./modelNB_PM10.rds")
```

5.7.2 Penerapan Model Klasifikasi

Pada tahap penerapan model klasifikasi adalah tahap menggunakan model terbaik dari setiap percobaan di masing-masing unsur polutan udara yakni CO, NO₂, O₃, PM₁₀, SO₂. Model terbaik masing-masing akan diterapkan untuk mengklasifikasikan hasil peramalan pada tahun 2017 kedepan. Berikut ini adalah langkah-langkah penerapan model klasifikasi.

1. Membaca model terbaik yang telah disimpan dalam format RDS sebelumnya

```
ModelNB_NO2<- readRDS("./ModelNB_NO2.rds")
```

2. Mendeklarasikan variabel untuk setiap unsur polutan udara di setiap wilayah bagian Surabaya

```
> prediksif1<-read.csv("E:/2.Bismillah TA/KnowledgeDiscovery/DataMining/Forecast 1 tahun 2017 Surabaya Pusat.csv", sep=";")
> x1 = prediksif1[1] #unsur CO Surabaya Pusat
> x2 = prediksif1[2] #unsur NO2 Surabaya Pusat
> x3 = prediksif1[3] #unsur O3 Surabaya Pusat
> x4 = prediksif1[4] #unsur PM10 Surabaya Pusat
> x5 = prediksif1[5] #unsur SO2 Surabaya Pusat
```

3. Melakukan prediksi dengan memanggil model terbaik pada setiap unsur polutan udara di setiap bagian wilayah Surabaya

```
> peramalansuf1_CO=predict(ModelNB_CO$finalModel, x1)
> prediksiforecastsuf1_CO=data.frame(x1,peramalansuf1_CO["class"])
> peramalansuf1_NO2=predict(ModelNB_NO2$finalModel, x2)
> prediksiforecastsuf1_NO2=data.frame(x2,peramalansuf1_NO2["class"])
> peramalansuf1_O3=predict(ModelNB_O3$finalModel, x3)
> prediksiforecastsuf1_O3=data.frame(x3,peramalansuf1_O3["class"])
> peramalansuf1_PM10=predict(ModelNB_PM10$finalModel, x4)
> prediksiforecastsuf1_PM10=data.frame(x4,peramalansuf1_PM10["class"])
> peramalansuf1_SO2=predict(ModelNB_SO2$finalModel, x5)
> prediksiforecastsuf1_SO2=data.frame(x5,peramalansuf1_SO2["class"])
```

Pada Gambar 5.33 menunjukkan hasil prediksi kategori status polusi pada setiap unsur polutan udara pada stasiun pemantau wilayah Surabaya Pusat.

	CO	prediksi_CO	NO2	prediksi_NO2	O3	prediksi_O3	PM10	prediksi_PM10	SO2	prediksi_SO2
1	0.289336799	Baik	5.867382681	Sedang	12.17401226	Sedang	19.72665044	Sangat Baik	18.496406610	Sangat Baik
2	0.286528388	Baik	6.874905099	Sedang	12.10216905	Sedang	22.19626656	Sangat Baik	18.496642270	Sangat Baik
3	0.284936091	Baik	7.466931858	Sedang	12.05407221	Sedang	23.59033431	Sedang	18.498518460	Sangat Baik
4	0.284083092	Baik	7.810087528	Sedang	12.02657507	Sedang	24.36174837	Sedang	18.496297440	Sangat Baik
5	0.283659980	Baik	8.007784568	Sedang	12.01382985	Sedang	24.78215486	Sedang	18.489817740	Sangat Baik
6	0.283480641	Baik	8.121916564	Sedang	12.01074440	Sedang	25.00777248	Sedang	18.480173640	Sangat Baik
7	0.283437531	Baik	8.188612754	Sedang	12.01367785	Sedang	25.12630548	Sedang	18.468439420	Sangat Baik
8	0.283469911	Baik	8.228611265	Sedang	12.02025186	Sedang	25.18630850	Sedang	18.455397260	Sangat Baik
9	0.283543954	Baik	8.253680893	Sedang	12.02898962	Sedang	25.21443629	Sedang	18.441555070	Sangat Baik
10	0.283641002	Baik	8.270447917	Sedang	12.03900377	Sedang	25.22524237	Sedang	18.427222320	Sangat Baik

Gambar 5.33 Hasil Prediksi Kelas pada Setiap Unsur Polutan Udara untuk Wilayah Surabaya Pusat

5.8 Visualisasi Dashboard

Pada tahapan ini, hasil *clustering*, klasifikasi, dan peramalan akan dipresentasikan dalam bentuk grafik untuk mempermudah pemahaman dan analisa pada hasil yang telah dilakukan sebelumnya. Grafik yang digunakan dalam penelitian ini adalah *leaflet map*, *calendar heatmap*, *donut chart*, *bar chart* dan *line chart*. Visualisasi dihasilkan dengan bantuan *tools* Shiny dan Shiny *Dashboard*.

5.8.1 Leaflet Map

Bentuk komponen visualisasi *leaflet map* digunakan untuk menampilkan status polusi udara harian berdasarkan lokasi geografis di setiap titik stasiun pemantau udara yang mewakili wilayah bagian Surabaya. Grafik ini mempermudah pengguna untuk menganalisis cakupan setiap bagian wilayah yang diwakili oleh satu stasiun pemantau. *Package* yang digunakan untuk komponen visualisasi ini pada R yakni LeafletMap dan geojsonio. Data peta Surabaya yang digunakan adalah dalam bentuk format geojson *polygon*. Berikut ini merupakan *script* yang digunakan untuk membuat Leaflet Map.

```
surabayamap<-geojsonio::geojson_read("SBY.geojson", what = "sp")
leaflet(surabayamap) %>%
  addTiles() %>%
  setView(112.7, -7.29, zoom = 11) %>%
  addPolygons(stroke = FALSE, smoothFactor = 0.9, fillOpacity = 0.6,
    fillColor = ~pal(cluster),
    label = ~paste0(wilayah, ": ", formatC(cluster,
    big.mark = ", ")),
    highlightOptions = highlightOptions(color = "white",
    weight = 2, bringToFront = TRUE)) %>%

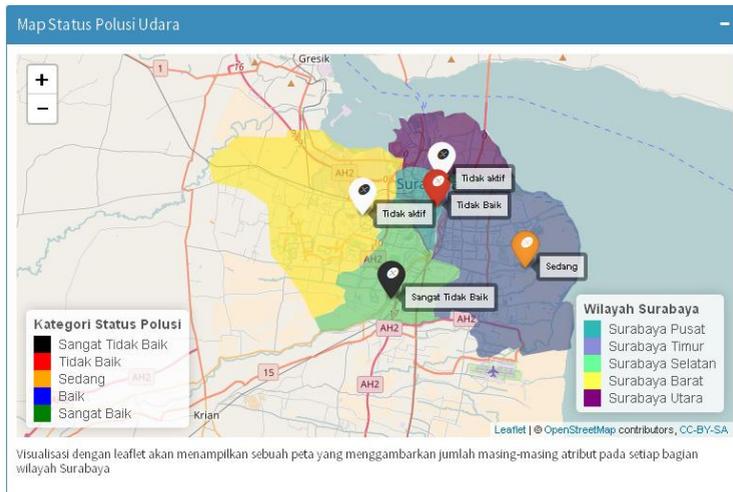
  addAwesomeMarkers(lng = 112.7438852, lat = -7.262007689,
    icon=getIcon( dfpusat ), label = paste(dfpusat$status_polusi),
    labelOptions = labelOptions(noHide = T, textSize = "9px")) %>%

  #surabaya pusat
  addAwesomeMarkers(lng = 112.8076601, lat = -7.305366919,
    icon=getIcon( dftimur ), label = paste(dftimur$status_polusi),
    labelOptions = labelOptions(noHide = T, textSize = "9px")) %>%

  #surabaya timur
  addAwesomeMarkers(lng = 112.7108216, lat = -7.326735031,
    icon=getIcon( dfselatan ), label = paste(dfselatan$status_polusi),
    labelOptions = labelOptions(noHide = T, textSize = "9px")) %>%

  #surabaya selatan
  addAwesomeMarkers(lng = 112.6905, lat = -7.2678,
    icon=makeAwesomeIcon(icon = 'ios-close', iconColor =
    'black', library = 'ion', markerColor = 'white' ), label = "Tidak
    aktif", labelOptions = labelOptions(noHide = T, textSize = "9px")
  )})
```

Data yang digunakan untuk visualisasi merupakan data klasifikasi baik dari data aktual tahun 2016 maupun klasifikasi hasil peramalan harian tahun 2017. Tanda *icon marker* menunjukkan lokasi stasiun pemantau udara dipasang. Sedangkan warna pada setiap *icon marker* menunjukkan kategori status polusi harian. *Leaflet map* prediksi status polusi udara harian ditunjukkan pada Gambar 5.34.



Gambar 5.34 Komponen Visualisasi *Leaflet Map*

5.8.2 *Calendar Heatmap*

Bentuk komponen visualisasi *calendar heatmap* digunakan untuk menampilkan hasil visualisasi yang meringkas status polusi udara pada setiap bagian wilayah Surabaya dalam bentuk *calendar*. *Calendar heatmap* akan mempermudah pengguna membaca kesimpulan status polusi dengan *slicing* variabel waktu yakni hari, bulan dan tahun secara lebih ringkas. *Package* yang digunakan untuk visualisasi *calendar heatmap* ini adalah *reshape* dan *ggplot2*. *Script* yang digunakan untuk visualisasi *calendar heatmap* adalah sebagai berikut.

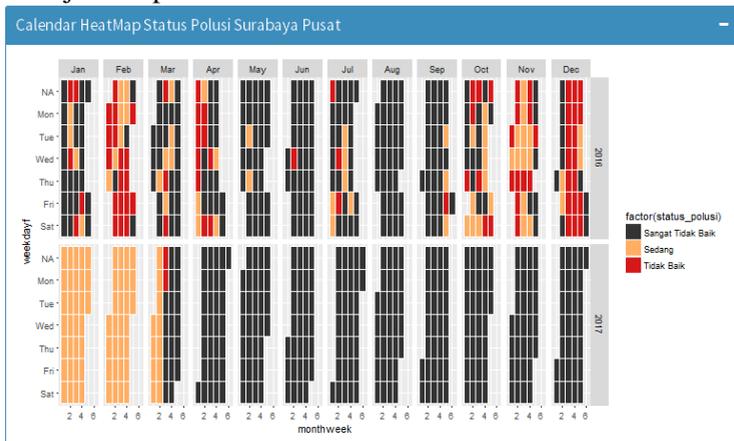
```

library(reshape2)
library(ggplot2)
output$CalendarHeatPusat <- renderPlot({
  colors <- c("#333333", "#FFAE63", "#D61818")

  ggplot(datapusat, aes(monthweek, weekdayf,
    fill = factor(status_polusi))) +
    geom_tile(colour = "white") +
    facet_grid(year~monthf) +
    scale_fill_manual(values=colors)
})

```

Data yang digunakan untuk visualisasi adalah data klasifikasi baik data aktual tahun 2016 maupun hasil klasifikasi data hasil peramalan. Komponen visualisasi *calendar heatmap* ditunjukkan pada Gambar 5.35.



Gambar 5.35 Komponen Visualisasi *Calendar Heatmap*

5.8.3 Doughnut Chart

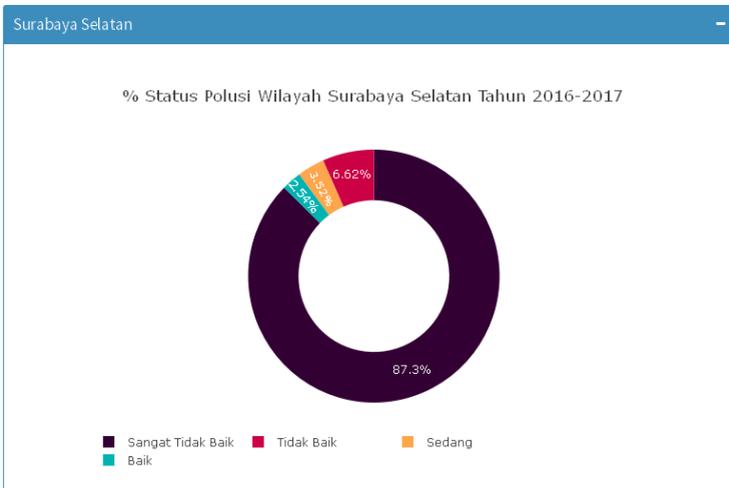
Bentuk komponen visualisasi *doughnut chart* digunakan untuk merepresentasikan presentasi status polusi pada setiap bagian wilayah Surabaya. Tujuannya adalah untuk mengetahui berapa persentase setiap status polusi pada tahun 2016 hingga tahun 2017 dengan lebih ringkas untuk dipahami pengguna. *Package* yang digunakan untuk merepresentasikan *doughnut chart* adalah dengan *package plotly*. Berikut ini merupakan *script* yang digunakan untuk visualisasi *doughnut chart*.

```
pusat=(dbGetQuery(conn = con, statement = ("SELECT status_polusi,
count(status_polusi) as jumlah FROM prediksi_status_polusi WHERE
wilayah='Surabaya Pusat' Group By status_polusi;"))

output$piesbypusat <- renderPlotly(
  p <- pusat %>%
    plot_ly(labels = ~status_polusi, values = ~jumlah,
            textposition = 'inside',
            textinfo = 'percent',
            insidetextfont = list(color = '#FFFFFF'),
            hoverinfo = 'text',
            marker = list(colors = c('rgb(51, 0, 51)',
            'rgb(255, 166, 77)', 'rgb(204, 0, 68)')) %>%

    add_pie(hole = 0.6) %>%
    layout(title = "% Status Polusi Wilayah Surabaya Pusat Tahun
2016-2017",
           legend = list(orientation = 'h'), showlegend = T,
           xaxis = list(showgrid = FALSE, zeroline = FALSE,
           showticklabels = FALSE),
           yaxis = list(showgrid = FALSE, zeroline = FALSE,
           showticklabels = FALSE)
  ))
))
```

Data yang digunakan untuk visualisasi adalah data klasifikasi baik data aktual tahun 2016 maupun hasil klasifikasi data hasil peramalan. Komponen visualisasi *calendar heatmap* ditunjukkan pada Gambar 5.36.



Gambar 5.36 Komponen visualisasi *donut chart* Wilayah Surabaya Selatan

5.8.4 Box Plot

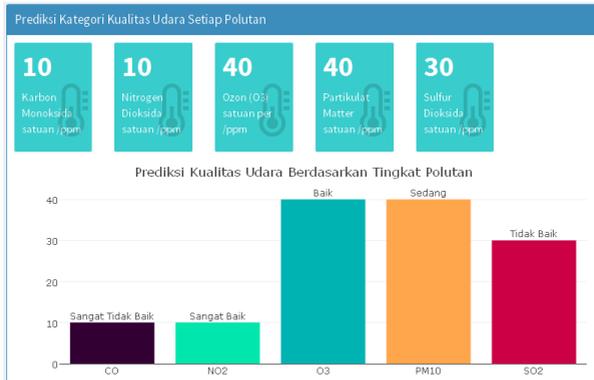
Grafik pada Gambar 5.37 ini digunakan untuk menunjukkan batas atas dan batas bawah dari nilai masing-masing *cluster* di setiap wilayah Surabaya.



Gambar 5.37 Box Plot Rentang Indeks Cluster Wilayah Surabaya

5.8.5 Bar Chart

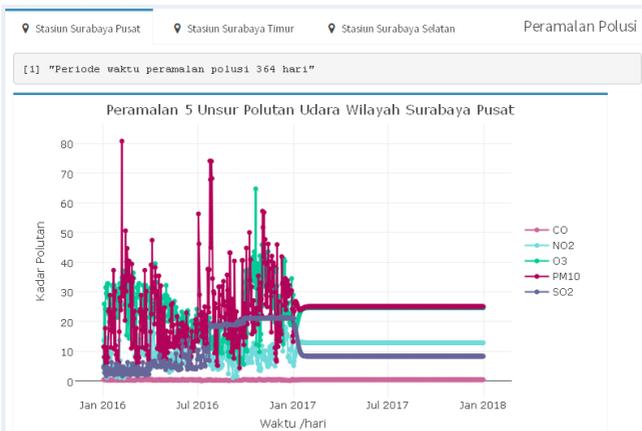
Bentuk visualisasi *bar chart* digunakan untuk merepresentasikan hasil prediksi klasifikasi dari model terbaik. Setiap bar merepresentasikan kategori status polusi dari setiap unsur polutan udara yakni CO, NO₂, O₃, PM₁₀, dan SO₂. Terdapat *input slider* yang memungkinkan *user* untuk memasukkan nilai kadar polutan pada setiap unsur sehingga pengguna dapat fleksibel memprediksi status polusi pada setiap unsur dengan masukan nilai kadar polutan yang diinginkan. Grafik *bar chart* ditunjukkan pada Gambar 5.38.



Gambar 5.38 Komponen Visualisasi *Bar Chart* untuk Klasifikasi

5.8.6 *Line Chart*

Bentuk komponen visualisasi line chart digunakan untuk menggambarkan hasil peramalan ke depan pada setiap bagian wilayah Surabaya berdasarkan model peramalan ANN terbaik. *Package* yang digunakan untuk visualisasi *line chart* adalah *package plotly*. Pengguna dapat menentukan berapa periode peramalan kedepan yang ingin diketahui atau dianalisis menggunakan *input date range*. Grafik *line chart* ditunjukkan pada Gambar 5.39.

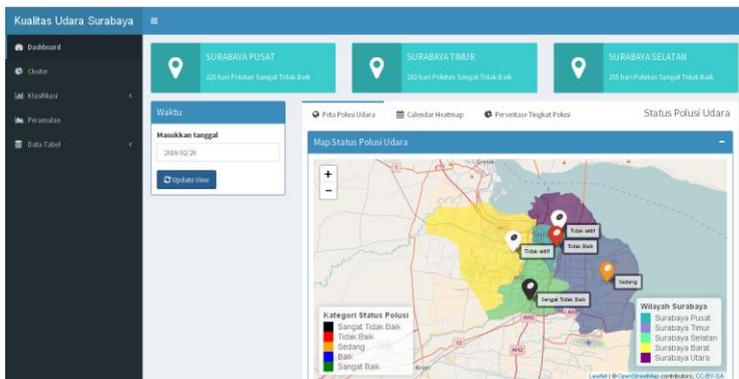


Gambar 5.39 Komponen Visualisasi *Line Chart* untuk Peramalan

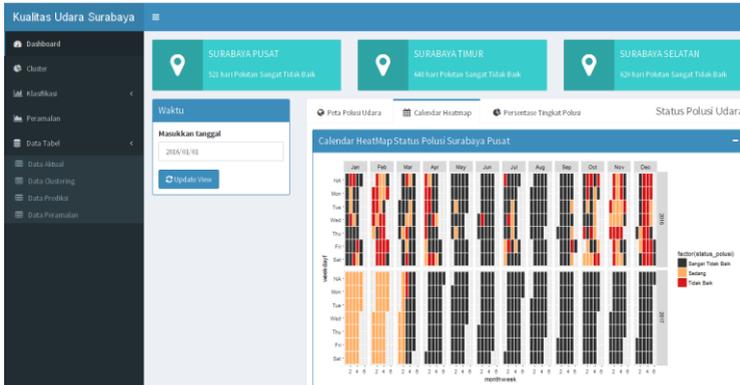
5.8.7 Shiny Dashboard

Shiny *dashboard* merupakan salah satu *package* yang ada pada *shiny* yang bertujuan untuk membantu kemudahan pembacaan data dan analisis pada data. Shiny *dashboard* pada penelitian ini digunakan untuk menampilkan keadaan data, hasil dari *clustering*, hasil peramalan, dan hasil prediksi klasifikasi. Visualisasi ini terdiri dari 5 menu utama yakni menu *dashboard*, menu *cluster*, menu klasifikasi, menu peramalan, dan menu data tabel.

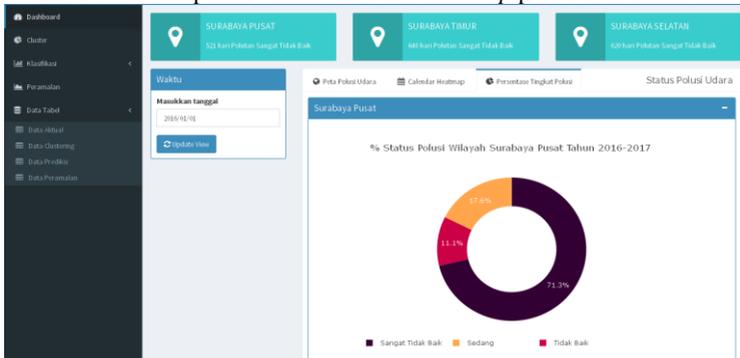
Menu pertama adalah *dashboard* yang merupakan visualisasi data secara umum dan terangkum. Pada halaman ini memuat tiga grafik yaitu *leaflet map*, *calendar heatmap* dan *donut chart*. Selain grafik pada halaman ini juga disediakan *infobox* yang memberikan informasi mengenai berapa hari yang memiliki polutan sangat tidak baik. Tampilan *dashboard* terlihat seperti Gambar 5.40, Gambar 5.41 dan Gambar 5.42



Gambar 5.40 Komponen Visual *Leaflet Map* pada Menu Dashboard

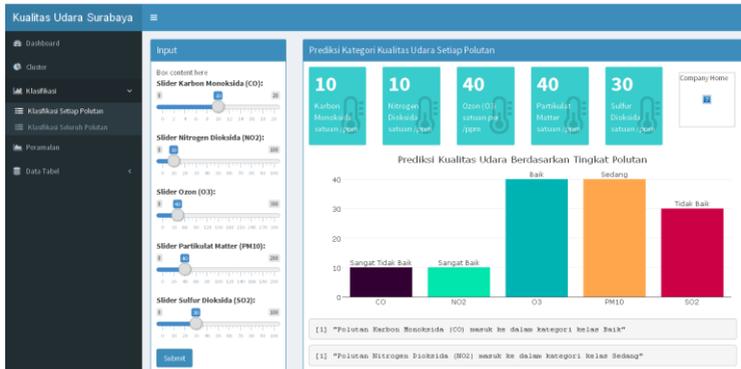


Gambar 5.41 Komponen Visual *Calendar Heatmap* pada Menu Dashboard

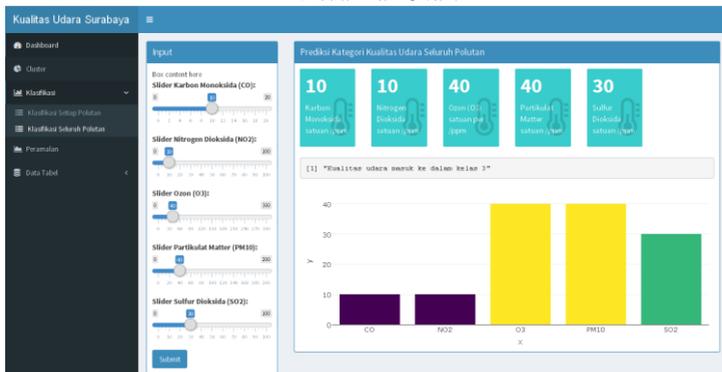


Gambar 5.42 Komponen Visual *Donut Chart* pada Menu Dashboard

Pada menu klasifikasi terdiri dari dua sub menu yakni klasifikasi setiap polutan dan klasifikasi seluruh unsur polutan. Pada sub menu klasifikasi setiap unsur polutan yang ditunjukkan Gambar 5.43, pengguna memungkinkan memasukkan berapa kadar polutan yang ingin diketahui masuk ke dalam kategori status polusi seperti apa melalui *input slider* pada setiap unsur polutan udara. Sedangkan sub menu klasifikasi seluruh unsur polutan pada Gambar 5.44 memungkinkan pengguna juga memasukkan namun kadar polutan ke *input slider* dan menghasilkan *output* masuk ke dalam kelas berapa.



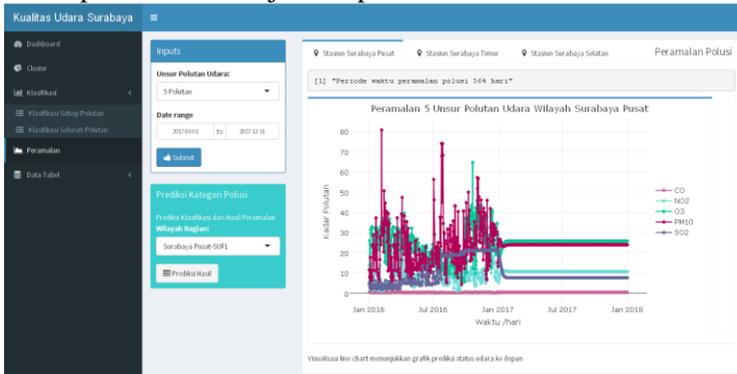
Gambar 5.43 Sub Menu Klasifikasi Setiap Unsur Polutan dengan Komponen Visual *Bar Chart*



Gambar 5.44 Sub Menu Klasifikasi Seluruh Unsur Polutan dengan Komponen Visual *Bar Chart*

Pada menu peramalan terdiri dari peramalan pada wilayah Surabaya Pusat, Surabaya Timur dan Surabaya Selatan. Visualisasi yang digunakan pada peramalan adalah menggunakan komponen visual *line chart* dan menggunakan model terbaik ANN yang berbeda di setiap wilayah. Tahapan ini memungkinkan pengguna untuk memasukkan rentang waktu periode yang diinginkan untuk meramalkan berapa periode ke depan melalui *input date range*. Selain itu pengguna juga memungkinkan memilih *line chart* yang ditampilkan

adalah grafik semua polutan atau setiap unsur polutan udara. Menu peramalan ditunjukkan pada Gambar 5.45.



Gambar 5.45 Menu Peramalan Menggunakan Komponen Visual *Line Chart* Pada menu Data Tabel terdiri dari empat sub menu yakni sub menu data aktual, data *clustering*, data prediksi, dan data peramalan seperti yang ditunjukkan pada Gambar 5.46, Gambar 5.47 dan Gambar 5.48.

Date	CO	NO2	O3	PM10	SO2	stasiun	wilayah
01/01/2016	0.47	13.67	4.99	11.5	4.52	smf1	Surabaya Pusat
02/01/2016	0.30	2.81	25.94	6.95	4.5	smf1	Surabaya Pusat
03/01/2016	0.4	6.16	4.99	4.93	2.8	smf1	Surabaya Pusat
04/01/2016	0.6	2.66	24.28	17.77	3.64	smf1	Surabaya Pusat
05/01/2016	0.63	3.92	31.45	3.69	2.56	smf1	Surabaya Pusat
06/01/2016	0.52	5.58	29.45	11.25	1.74	smf1	Surabaya Pusat
07/01/2016	0.34	1.17	31.8	0.55	4.05	smf1	Surabaya Pusat
08/01/2016	0.36	14.44	32.01	6.25	4.09	smf1	Surabaya Pusat
09/01/2016	0.36	10.38	32.86	7.86	3.35	smf1	Surabaya Pusat
10/01/2016	0.37	0.25	20.34	23.43	4.21	smf1	Surabaya Pusat
11/01/2016	0.54	9.76	22.47	23.44	3.16	smf1	Surabaya Pusat
12/01/2016	0.43	10.25	19.9	24.21	3.73	smf1	Surabaya Pusat

Gambar 5.46 Sub Menu Data Aktual pada Menu Data Tabel

Tabel Cluster Polutan Karbon Monoksida (CO)

Date	CO	cluster	stasiun	kategori	wilayah
01/10/2019	0.47	1	sufl	Baik	Sarabaya Pusat
02/10/2019	0.4	1	sufl	Baik	Sarabaya Pusat
04/10/2019	0.6	1	sufl	Baik	Sarabaya Pusat
05/10/2019	0.63	1	sufl	Baik	Sarabaya Pusat
06/10/2019	0.52	1	sufl	Baik	Sarabaya Pusat
11/10/2019	0.54	1	sufl	Baik	Sarabaya Pusat
12/10/2019	0.43	1	sufl	Baik	Sarabaya Pusat
14/10/2019	0.44	1	sufl	Baik	Sarabaya Pusat
18/10/2019	0.41	1	sufl	Baik	Sarabaya Pusat
20/10/2019	0.41	1	sufl	Baik	Sarabaya Pusat

Gambar 5.47 Sub Menu Data *Clustering* pada Menu Data Tabel

Prediksi Status Polusi Udara

Date	prediksl_co	prediksl_m02	prediksl_o3	prediksl_pm10	prediksl_so2	wilayah	status_polusi
2019-03-01	Sedang	Sangat Tidak Baik	Sedang	Sangat Baik	Sangat Tidak Baik	Sarabaya Pusat	Sangat Tidak Baik
2019-03-02	Baik	Sedang	Sedang	Sangat Baik	Sangat Tidak Baik	Sarabaya Pusat	Sangat Tidak Baik
2019-03-03	Sedang	Sedang	Sedang	Sangat Baik	Sangat Tidak Baik	Sarabaya Pusat	Sangat Tidak Baik
2019-03-04	Sedang	Sedang	Sedang	Sangat Baik	Sangat Tidak Baik	Sarabaya Pusat	Sangat Tidak Baik
2019-03-05	Sedang	Sedang	Sangat Tidak Baik	Sangat Baik	Sangat Tidak Baik	Sarabaya Pusat	Sangat Tidak Baik
2019-03-06	Sedang	Sedang	Sedang	Sangat Baik	Sangat Tidak Baik	Sarabaya Pusat	Sangat Tidak Baik
2019-03-07	Baik	Sedang	Sangat Tidak Baik	Sangat Baik	Sangat Tidak Baik	Sarabaya Pusat	Sangat Tidak Baik

Gambar 5.48 Sub Menu Data Prediksi pada Menu Data Tabel

(Halaman sengaja dikosongkan)

BAB VI HASIL DAN PEMBAHASAN

Pada bab ini, akan dijelaskan tentang karakteristik dari setiap hasil klusterisasi, peramalan, dan klasifikasi dari unsur polusi udara di setiap bagian wilayah Surabaya Pusat, Surabaya Timur dan Surabaya Selatan.

6.1 Perbandingan Performa Setiap Model *Clustering*

Pada tahap ini merupakan tahap perbandingan hasil performa model *clustering* pada setiap percobaan baik meliputi seluruh Wilayah Surabaya atau yang dibagi di setiap wilayah Surabaya maupun percobaan untuk melakukan pengelompokan langsung seluruh variabel atau setiap variabel unsur polutan.

6.1.1 Model 1 - Hasil *Clustering* Seluruh Wilayah Surabaya

Pada Tabel 6.1 menunjukkan perbandingan performa *hasil clustering* dengan menggunakan SSE, Dunn Index dan *Silhouette* yang membandingkan performa *clustering* yang melibatkan langsung kelima parameter polutan udara dibandingkan dengan performa *clustering* setiap parameter polutan udara dengan menggunakan langsung keseluruhan Wilayah Surabaya.

Hasil pada Tabel 6.1 menunjukkan bahwa performa yang terbaik dari SSE dan *Dunn Index* adalah dengan menggunakan setiap parameter. Sedangkan *SSilhouette* menunjukkan bahwa performa *clustering* dengan keseluruhan parameter lebih baik.

Tabel 6.1 Performa nilai Model 1 (clustering seluruh wilayah Surabaya)

Proses	Bagian	Parameter	K	SSE	Dunn	Silhouette
1	Seluruh Surabaya (Suf1, Suf6, Suf7)	CO, NO ₂ , O ₃ , PM ₁₀ , SO ₂	5	2,967	0,014	0,701
		Nilai performa seluruh parameter		2,967	0,014	0,701
2		CO	5	0,000	0,211	0,701
3		NO ₂	5	0,045	0,002	0,545

Proses	Bagian	Parameter	K	SSE	Dunn	Silhouette
4		O ₃	5	0,596	0,001	0,571
5		PM ₁₀	5	0,173	0,002	0,560
6		SO ₂	5	0,038	0,003	0,632
		Nilai performa Rata-rata setiap parameter			0,170	0,044

6.1.2 Model 2 - Hasil *clustering* wilayah Surabaya Pusat

Pada Tabel 6.2 menunjukkan perbandingan performa *hasil clustering* dengan menggunakan SSE, Dunn Index dan *Silhouette* yang membandingkan performa *clustering* yang melibatkan langsung kelima parameter polutan udara dibandingkan dengan performa *clustering* setiap parameter polutan udara dengan menggunakan data hanya pada Wilayah Surabaya Pusat.

Hasil pada Tabel 6.2 menunjukkan bahwa performa yang terbaik dari SSE dan *Silhouette* adalah dengan menggunakan setiap parameter. Sedangkan *Dunn Index* menunjukkan bahwa performa *clustering* dengan keseluruhan parameter lebih baik.

Tabel 6.2 Performa nilai model 2 (clustering wilayah Surabaya Pusat)

Proses	Bagian	Parameter	K	SSE	Dunn	Silhouette
7	Surabaya Pusat (SufI-Taman Prestasi)	CO, NO ₂ , O ₃ , PM ₁₀ , SO ₂	5	10,998	0,049	0,334
		Nilai performa seluruh parameter		10,998	0,049	0,334
8		CO	5	7,240	0,077	0,526
9		NO ₂	5	0,140	0,013	0,566
10		O ₃	5	0,505	0,017	0,564
11		PM ₁₀	5	0,663	0,017	0,548
12		SO ₂	5	0,093	0,018	0,689
		Nilai performa Rata-rata setiap parameter			1,728	0,028

6.1.3 Model 3 - Hasil *clustering* wilayah Surabaya Timur

Pada Tabel 6.3 menunjukkan perbandingan performa *hasil clustering* dengan menggunakan SSE, Dunn Index dan *Silhouette* yang membandingkan performa *clustering* yang melibatkan langsung kelima parameter polutan udara dibandingkan dengan performa *clustering* setiap parameter polutan udara dengan menggunakan data hanya pada Wilayah Surabaya Timur.

Hasil Tabel 6.3 menunjukkan bahwa performa yang terbaik dari SSE dan *Silhouette* adalah dengan menggunakan setiap parameter. Sedangkan *Dunn Index* menunjukkan bahwa performa *clustering* dengan keseluruhan parameter lebih baik.

Tabel 6.3 Performa nilai model 3 (clustering wilayah Surabaya Timur)

Proses	Bagian	Parameter	K	SSE	Dunn	Silhouette
13	Surabaya Timur (Suf6-Wonorejo)	CO, NO ₂ , O ₃ , PM ₁₀ , SO ₂	5	7,371	0,055	0,244
		Nilai performa seluruh parameter		7,371	0,055	0,244
14		CO	5	0,000	0,016	0,654
15		NO ₂	5	0,072	0,025	0,549
16		O ₃	5	0,489	0,015	0,562
17		PM ₁₀	5	0,444	0,021	0,539
18		SO ₂	5	0,147	0,023	0,584
		Nilai performa Rata-rata setiap parameter		0,230	0,020	0,578

6.1.4 Model 4 - Hasil *clustering* wilayah Surabaya Selatan

Pada Tabel 6.4 menunjukkan perbandingan performa *hasil clustering* dengan menggunakan SSE, Dunn Index dan *Silhouette* yang membandingkan performa *clustering* yang melibatkan langsung kelima parameter polutan udara dibandingkan dengan performa *clustering* setiap parameter

polutan udara dengan menggunakan data hanya pada Wilayah Surabaya Selatan.

Hasil pada Tabel 6.4 menunjukkan bahwa performa yang terbaik dari SSE dan *Silhouette* adalah dengan menggunakan setiap parameter. Sedangkan *Dunn Index* menunjukkan bahwa performa *clustering* dengan keseluruhan parameter lebih baik.

Tabel 6.4 Performa nilai model 4 (clustering wilayah Surabaya Selatan)

Proses	Bagian	Parameter	K	SSE	Dunn	Silhouette
19	Surabaya Selatan (Suf7-Kebonsari)	CO, NO ₂ , O ₃ , PM ₁₀ , SO ₂	5	5,271	0,058	0,300
		Nilai performa seluruh parameter		5,271	0,058	0,300
20		CO	5	0,001	0,022	0,574
21		NO ₂	5	0,175	0,011	0,538
22		O ₃	5	0,141	0,011	0,548
23		PM ₁₀	5	0,830	0,023	0,553
24		SO ₂	5	0,015	0,021	0,626
		Nilai performa Rata-rata setiap parameter		0,232	0,018	0,568

Rangkuman perbandingan performa pada setiap model

Pada Tabel 6.5 berikut ini merupakan tabel perbandingan nilai uji performa dari perbandingan model yang merepresentasikan proses *clustering*. Model 1 merupakan proses *clustering* pada seluruh wilayah Surabaya yang menggunakan data gabungan seluruh stasiun pemantau udara. Model 2, 3 dan 4 merupakan proses *clustering* pada masing-masing stasiun pemantau di setiap bagian wilayah Surabaya yakni model 2 adalah Surabaya Pusat, model 3 adalah Surabaya Timur dan model 4 adalah Surabaya Selatan. Pada setiap model dilakukan percobaan implementasi *clustering* dengan melibatkan data langsung

kelima parameter udara (CO, NO₂, O₃, PM₁₀, SO₂) dan data pada masing-masing parameter yang dilakukan *clustering*.

Berdasarkan perbandingan rangkuman Tabel 6.5 menunjukkan bahwa model yang lebih baik ketika melakukan proses *clustering* dengan setiap parameter. Nilai SSE dan Silhouette pada model 2,3, dan 4 lebih baik ketika *clustering* dengan setiap parameter dibandingkan langsung melakukan *clustering* seluruh parameter secara bersamaan. Oleh karena itu *clustering* yang dipilih untuk dianalisis adalah yang menggunakan setiap parameter.

Tabel 6.5 Tabel perbandingan performa setiap model

	Model 1			Model 2			Model 3			Model 4		
	SSE	Dunn index	Silhouette									
Seluruh parameter	2,967	0,014	0,701	10,998	0,049	0,334	7,371	0,055	0,244	5,271	0,058	0,300
Setiap parameter	0,170	0,044	0,602	1,728	0,028	0,578	0,230	0,020	0,578	0,232	0,018	0,568

Pada Tabel 6.6 menunjukkan perbandingan antara model 1 yang mempertimbangkan proses *clustering* langsung seluruh wilayah Surabaya dengan model 2,3,4 yang menunjukkan model dari proses *clustering* yang mempertimbangkan setiap bagian wilayah Surabaya dengan merata-rata hasil uji performa model 2,3,4. Hasil menunjukkan bahwa model yang terbaik adalah model yang menggunakan keseluruhan data Surabaya dengan melakukan *clustering* pada setiap unsur polutan udara.

Tabel 6.6 Ringkasan perbandingan performa model 1 (seluruh wilayah Surabaya) dan model 2,3,4 (setiap bagian wilayah Surabaya) pada masing-masing parameter

	SSE	Dunn	Silhouette
Model 1 (seluruh Surabaya)	0,170	0,044	0,602
Model 2,3,4 (setiap bagian wilayah)	0,730	0,022	0,575

6.3 Analisis Hasil *Clustering*

Berikut ini merupakan hasil *clustering* seluruh wilayah Surabaya berdasarkan setiap variabel polutan udara.

6.3.1 Unsur CO

Pada tabel Tabel 6.7 menunjukkan justifikasi label pada setiap kelompok dari hasil *clustering* unsur polutan CO

Tabel 6.7 Hasil *Clustering* Unsur CO

Hasil clustering parameter CO (Karbon Monoksida) di seluruh wilayah Surabaya						
Cluster	Min	Max	Jumlah	Rata-rata	Urutan indeks	Kategori
1	0,4	0,97	233	0,53	2	Baik
2	1,77	2,52	176	2,09	4	Tidak Baik
3	0,04	0,39	413	0,27	1	Sangat Baik
4	0,99	1,76	170	1,43	3	Sedang
5	2,56	3,73	71	2,99	5	Sangat Tidak Baik

6.3.1.1 Karakterisasi Unsur CO pada Stasiun 1 - Surabaya Pusat

Berikut ini pada Tabel 6.8 merupakan profil karakteristik unsur polutan udara CO di stasiun pemantau udara 1 pada Taman Prestasi yang mewakili wilayah Surabaya Pusat

Tabel 6.8 Karakterisasi *Cluster* Unsur CO untuk Wilayah Surabaya Pusat

Unsur CO		
Cluster	Karakteristik	Hasil
Cluster 1	Jumlah anggota	137
	Persentase dari Total seluruh Surabaya	37,4%
	Nilai minimum	0,4
	Nilai maksimum	0,76
	Rata-rata nilai	0,48
	Kategori	Baik
Cluster 2	Jumlah anggota	0
	Persentase dari Total seluruh Surabaya	0%
	Nilai minimum	NA
	Nilai maksimum	NA
	Rata-rata nilai	NA
	Kategori	Tidak Baik

Unsur CO		
Cluster	Karakteristik	Hasil
<i>Cluster 3</i>	Jumlah anggota	228
	Persentase dari Total seluruh Surabaya	62,3%
	Nilai minimum	0,12
	Nilai maksimum	0,39
	Rata-rata nilai	0,31
	Kategori	Sangat Baik
<i>Cluster 4</i>	Jumlah anggota	1
	Persentase dari Total seluruh Surabaya	0,3%
	Nilai minimum	1,09
	Nilai maksimum	1,09
	Rata-rata nilai	1,09
	Kategori	Sedang
<i>Cluster 5</i>	Jumlah anggota	0
	Persentase dari Total seluruh Surabaya	0%
	Nilai minimum	NA
	Nilai maksimum	NA
	Rata-rata nilai	NA
	Kategori	Sangat Tidak Baik

Pada stasiun Surabaya Pusat yang memiliki unsur CO dan masuk ke dalam kategori tidak sehat (*cluster 4*), sangat tidak sehat (*cluster 2*) dan berbahaya (*cluster 5*) apabila dijumlahkan yakni senilai 1 hari atau 0,27% dalam satu tahun 2016 sebanyak 366 hari. tidak baik senilai 0% (*cluster 4*) dan sangat tidak baik bernilai 0% (*cluster 5*)

6.3.1.2 Karakterisasi Unsur CO pada Stasiun 6 - Surabaya Timur

Pada Tabel 6.9 berikut ini merupakan tabel profil karakteristik unsur polutan udara CO di stasiun pemantau udara 1 pada daerah Wonorejo yang mewakili wilayah Surabaya Timur.

Tabel 6.9 Karakterisasi Cluster Unsur CO untuk Wilayah Surabaya Timur

Unsur CO		
<i>Cluster</i>	Karakteristik	Hasil
Cluster 1	Jumlah anggota	61
	Persentase dari Total seluruh Surabaya	17,33%
	Nilai minimum	0,4
	Nilai maksimum	0,97
	Rata-rata nilai	0,57
	Kategori	Baik
Cluster 2	Jumlah anggota	86
	Persentase dari Total seluruh Surabaya	24,43%
	Nilai minimum	1,78
	Nilai maksimum	2,5
	Rata-rata nilai	2,07
	Kategori	Tidak Baik
Cluster 3	Jumlah anggota	172
	Persentase dari Total seluruh Surabaya	48,9%
	Nilai minimum	0,04
	Nilai maksimum	0,39
	Rata-rata nilai	0,21
	Kategori	Sangat Baik
Cluster 4	Jumlah anggota	31
	Persentase dari Total seluruh Surabaya	8,81%
	Nilai minimum	0,99
	Nilai maksimum	1,74
	Rata-rata nilai	1,27
	Kategori	Sedang
Cluster 5	Jumlah anggota	2
	Persentase dari Total seluruh Surabaya	0,57%
	Nilai minimum	2,56
	Nilai maksimum	2,66
	Rata-rata nilai	2,61
	Kategori	Sangat Tidak Baik

Pada stasiun Surabaya Timur yang memiliki unsur CO dan masuk ke dalam kategori Tidak baik senilai 24,43% (*cluster 2*)

dan sangat tidak baik senilai 0,57% (*cluster 5*) yang apabila dijumlahkan senilai 25% dalam satu tahun 2016 sebanyak 352 hari yang telah dikurangi dengan *outlier* sebanyak 14 hari.

6.3.1.3 Karakterisasi Unsur CO pada Stasiun 7 - Surabaya Selatan

Pada Tabel 6.10 berikut ini merupakan tabel profil karakteristik unsur polutan udara CO di stasiun pemantau udara 1 pada Taman Prestasi yang mewakili wilayah Surabaya Selatan.

Tabel 6.10 Karakterisasi Cluster Unsur CO untuk Wilayah Surabaya Selatan

Unsur CO		
Cluster	Karakteristik	Hasil
<i>Cluster 1</i>	Jumlah anggota	35
	Persentase dari Total seluruh Surabaya	10,14%
	Nilai minimum	0,41
	Nilai maksimum	0,97
	Rata-rata nilai	0,67
	Kategori	Baik
<i>Cluster 2</i>	Jumlah anggota	90
	Persentase dari Total seluruh Surabaya	26,1%
	Nilai minimum	1,77
	Nilai maksimum	2,52
	Rata-rata nilai	2,12
	Kategori	Tidak Baik
<i>Cluster 3</i>	Jumlah anggota	13
	Persentase dari Total seluruh Surabaya	3,77%
	Nilai minimum	0,08
	Nilai maksimum	0,39
	Rata-rata nilai	0,25%
	Kategori	Sangat Baik
<i>Cluster 4</i>	Jumlah anggota	138
	Persentase dari Total seluruh Surabaya	40%
	Nilai minimum	1
	Nilai maksimum	1,76
	Rata-rata nilai	1,47

Unsur CO		
Cluster	Karakteristik	Hasil
Cluster 5	Kategori	Sedang
	Jumlah anggota	69
	Persentase dari Total seluruh Surabaya	20%
	Nilai minimum	2,56
	Nilai maksimum	3,73
	Rata-rata nilai	3
	Kategori	Sangat Tidak Baik

Pada stasiun Surabaya Timur yang memiliki unsur CO dan masuk ke dalam Tidak baik senilai 40% (*cluster* 2) dan sangat tidak baik senilai 20% (*cluster* 5) yang apabila dijumlahkan senilai 88 hari atau 46,1% dalam satu tahun 2016 sebanyak 345 hari yang telah dikurangi dengan *outlier* sebanyak 21 hari.

Pada Tabel 6.11 menunjukkan hasil perbandingan setiap kelompok Unsur CO pada setiap Wilayah Surabaya.

Tabel 6.11 Perbandingan Status Polusi Unsur CO pada Setiap Bagian Wilayah Surabaya

Unsur CO tahun 2016	Surabaya Pusat		Surabaya Timur		Surabaya Selatan	
	Sangat Baik	228	62,3%	172	48,9%	13
Baik	137	37,4%	61	17,3%	35	10,1%
Sedang	1	0,3%	31	8,8%	138	40%
Tidak Baik	0	0%	86	24,4%	90	26,1%
Sangat Tidak Baik	0	0%	2	0,6%	69	20%
	366	100%	352	100%	345	100%

6.3.2 Unsur NO₂

Pada tabel Tabel 6.12 menunjukkan justifikasi label pada setiap kelompok dari hasil *clustering* unsur polutan NO₂.

Tabel 6.12 Hasil Clustering Unsur NO₂

Hasil clustering parameter NO ₂ (Nitrogen Dioksida) di seluruh wilayah Surabaya						
Cluster	Min	Max	Jumlah	Rata-rata	Urutan indeks	Kategori
1	30,18	44,12	132	37	4	Tidak Baik
2	18,69	29,84	210	23,01	3	Sedang
3	0,95	10,64	316	6,94	1	Sangat Baik
4	10,66	18,63	364	14,34	2	Baik
5	45,08	79,04	41	52,07	5	Sangat Tidak Baik

6.3.2.1 Karakterisasi Unsur NO₂ pada Stasiun 1-Surabaya Pusat

Pada Tabel 6.13 berikut ini merupakan tabel profil karakteristik unsur polutan udara NO₂ di stasiun pemantau udara 1 pada Taman Prestasi yang mewakili wilayah Surabaya Pusat

Tabel 6.13 Karakterisasi Cluster Unsur NO₂ untuk Wilayah Surabaya Pusat

Unsur NO ₂		
Cluster	Karakteristik	Hasil
Cluster 1	Jumlah anggota	0
	Persentase dari Total seluruh Surabaya	0%
	Nilai minimum	NA
	Nilai maksimum	NA
	Rata-rata nilai	NA
	Kategori	Tidak Baik
Cluster 2	Jumlah anggota	12
	Persentase dari Total seluruh Surabaya	3,3%
	Nilai minimum	18,69
	Nilai maksimum	24,37
	Rata-rata nilai	20,48%
	Kategori	Tidak Sehat
Cluster 3	Jumlah anggota	234

Unsur NO ₂		
Cluster	Karakteristik	Hasil
	Persentase dari Total seluruh Surabaya	63,93%
	Nilai minimum	1,07
	Nilai maksimum	10,48
	Rata-rata nilai	6,59%
	Kategori	Sangat Baik
Cluster 4	Jumlah anggota	120
	Persentase dari Total seluruh Surabaya	32,8%
	Nilai minimum	10,66
	Nilai maksimum	18,45
	Rata-rata nilai	14,2
	Kategori	Baik
Cluster 5	Jumlah anggota	0
	Persentase dari Total seluruh Surabaya	0%
	Nilai minimum	NA
	Nilai maksimum	NA
	Rata-rata nilai	NA
	Kategori	Sangat Tidak Baik

Pada stasiun Surabaya Pusat yang memiliki unsur NO₂ dan masuk ke dalam kategori tidak baik (*cluster* 1) dan sangat tidak baik (*cluster* 5) apabila dijumlahkan yakni senilai 0 hari atau 0% dalam satu tahun 2016 sebanyak 366 hari.

6.3.2.2 Karakterisasi Unsur NO₂ pada Stasiun 6 - Surabaya Timur

Pada Tabel 6.14 berikut ini merupakan tabel profil karakteristik unsur polutan udara CO di stasiun pemantau udara 6 pada daerah Wonorejo yang mewakili wilayah Surabaya Timur.

Tabel 6.14 Karakterisasi Cluster Unsur NO₂ untuk Wilayah Surabaya Timur

Unsur NO ₂		
Cluster	Karakteristik	Hasil
Cluster 1	Jumlah anggota	17
	Persentase dari Total data di stasiun 6	4,82%

Unsur NO ₂		
Cluster	Karakteristik	Hasil
	Nilai minimum	30,27
	Nilai maksimum	43,3
	Rata-rata nilai	33,1
	Kategori	Tidak Baik
<i>Cluster 2</i>	Jumlah anggota	102
	Persentase dari Total data di stasiun 6	29%
	Nilai minimum	18,72
	Nilai maksimum	29,76
	Rata-rata nilai	22,68
<i>Cluster 3</i>	Kategori	Sedang
	Jumlah anggota	69
	Persentase dari Total data di stasiun 6	19,6%
	Nilai minimum	2,13
	Nilai maksimum	10,64
<i>Cluster 4</i>	Rata-rata nilai	7,96
	Kategori	Sangat Baik
	Jumlah anggota	163
	Persentase dari Total data di stasiun 6	46,3%
	Nilai minimum	10,66
<i>Cluster 5</i>	Nilai maksimum	18,51
	Rata-rata nilai	14,21
	Kategori	Baik
	Jumlah anggota	1
	Persentase dari Total data di stasiun 6	0,3%
	Nilai minimum	51,32
	Nilai maksimum	51,31
	Rata-rata nilai	51,32
	Kategori	Sangat Tidak Baik

Pada stasiun Surabaya Timur yang memiliki unsur NO₂ dan masuk ke dalam kategori tidak baik (*cluster 1*) dan sangat tidak baik (*cluster 5*) apabila dijumlahkan yakni senilai 116 hari atau 33,6% dalam satu tahun 2016 sebanyak 352 hari yang telah dikurangi dengan *outlier* sebanyak 14 hari.

6.3.2.3 Karakterisasi Unsur NO₂ pada Stasiun 7-Surabaya Selatan

Pada Tabel 6.15 berikut ini merupakan tabel profil karakteristik unsur polutan udara NO₂ di stasiun pemantau udara 1 pada daerah Kebonsari yang mewakili wilayah Surabaya Selatan

Tabel 6.15 Karakterisasi Cluster Unsur NO₂ untuk Wilayah Surabaya Selatan

Unsur NO ₂		
Cluster	Karakteristik	Hasil
<i>Cluster 1</i>	Jumlah anggota	115
	Persentase dari Total seluruh Surabaya	33,3%
	Nilai minimum	30,18
	Nilai maksimum	44,12
	Rata-rata nilai	37,56
	Kategori	Tidak Baik
<i>Cluster 2</i>	Jumlah anggota	96
	Persentase dari Total seluruh Surabaya	27,8%
	Nilai minimum	18,71
	Nilai maksimum	29,84
	Rata-rata nilai	23,7
	Kategori	Sedang
<i>Cluster 3</i>	Jumlah anggota	13
	Persentase dari Total seluruh Surabaya	3,8%
	Nilai minimum	0,95
	Nilai maksimum	10,48
	Rata-rata nilai	7,9
	Kategori	Sangat Baik
<i>Cluster 4</i>	Jumlah anggota	81
	Persentase dari Total seluruh Surabaya	23,5%
	Nilai minimum	10,79
	Nilai maksimum	18,63
	Rata-rata nilai	14,83
	Kategori	Baik
<i>Cluster 5</i>	Jumlah anggota	40
	Persentase dari Total seluruh Surabaya	11,6%
	Nilai minimum	45,08

Unsur NO ₂		
Cluster	Karakteristik	Hasil
	Nilai maksimum	79,04
	Rata-rata nilai	52,1
	Kategori	Sangat Tidak Baik

Pada stasiun Surabaya Timur yang memiliki unsur NO₂ dan masuk ke dalam kategori sangat tidak baik (*cluster 1*) dan sangat tidak baik (*cluster 5*) apabila dijumlahkan yakni senilai 155 hari atau 44,9% dalam satu tahun 2016 sebanyak 345 hari yang telah dikurangi dengan *outlier* sebanyak 21 hari.

Pada tabel Tabel 6.16 menunjukkan hasil perbandingan setiap kelompok Unsur NO₂ pada setiap Wilayah Surabaya.

Tabel 6.16 Perbandingan Status Polusi Unsur NO₂ pada Setiap Bagian Wilayah Surabaya

Unsur NO ₂ tahun 2016	Surabaya Pusat		Surabaya Timur		Surabaya Selatan	
Sangat Baik	234	63,9%	69	19,6%	13	3,8%
Baik	120	32,8%	163	46,3%	81	23,5%
Sedang	12	3,3%	102	29,9%	96	27,8%
Tidak Baik	0	0 %	115	33,3%	115	33,3%
Sangat Tidak Baik	0	0 %	1	0,3%	40	11,6%
Total	366	100%	352	100%	345	100%

6.3.3 Unsur O₃

Pada tabel Tabel 6.17 menunjukkan justifikasi label pada setiap kelompok dari hasil *clustering* unsur polutan O₃.

Tabel 6.17 Hasil Clustering Unsur O₃

Hasil clustering parameter O ₃ (Ozon) di seluruh wilayah Surabaya						
Cluster	Min	Max	Jumlah	Rata-rata	Urutan indeks	Kategori
1	226,91	486,52	5	301,29	5	Sangat Tidak Baik
2	51,93	83,69	238	64,78	3	Sedang
3	85,05	195,17	88	104,57	4	Tidak Baik
4	4,99	29,94	389	21,01	1	Sangat Baik
5	30,08	51,83	343	38,98	2	Baik

6.3.3.1 Karakterisasi Unsur O₃ pada Stasiun 1-Surabaya Pusat

Pada Tabel 6.18 berikut ini merupakan tabel profil karakteristik unsur polutan udara O₃ di stasiun pemantau udara 1 pada Taman Prestasi yang mewakili wilayah Surabaya Pusat

Tabel 6.18 Karakterisasi Cluster Unsur O₃ untuk Wilayah Surabaya Pusat

Unsur O ₃		
Cluster	Karakteristik	Hasil
Cluster 1	Jumlah anggota	0
	Persentase dari Total seluruh Surabaya	0%
	Nilai minimum	NA
	Nilai maksimum	NA
	Rata-rata nilai	NA
	Kategori	Sangat Tidak Baik
Cluster 2	Jumlah anggota	1
	Persentase dari Total seluruh Surabaya	0,3%
	Nilai minimum	64,66
	Nilai maksimum	64,66
	Rata-rata nilai	64,66
	Kategori	Sedang
Cluster 3	Jumlah anggota	0
	Persentase dari Total seluruh Surabaya	0%
	Nilai minimum	NA
	Nilai maksimum	NA
	Rata-rata nilai	NA
	Kategori	Tidak Baik
Cluster 4	Jumlah anggota	283
	Persentase dari Total seluruh Surabaya	77,3%
	Nilai minimum	4,99
	Nilai maksimum	29,59
	Rata-rata nilai	19,28
	Kategori	Sangat Baik
Cluster 5	Jumlah anggota	82
	Persentase dari Total seluruh Surabaya	22,4%
	Nilai minimum	30,16
	Nilai maksimum	45,84

Unsur O ₃		
Cluster	Karakteristik	Hasil
	Rata-rata nilai	34,93
	Kategori	Baik

Pada stasiun Surabaya Pusat yang memiliki unsur O₃ dan masuk ke dalam kategori tidak baik (*cluster* 3) dan sangat tidak baik (*cluster* 1) apabila dijumlahkan yakni senilai 0 % dalam satu tahun 2016 sebanyak 366 hari.

6.3.3.2 Karakterisasi Unsur O₃ pada Stasiun 6-Surabaya Timur

Pada Tabel 6.19 berikut ini merupakan tabel profil karakteristik unsur polutan udara O₃ di stasiun pemantau udara 1 pada daerah Wonorejo yang mewakili wilayah Surabaya Timur.

Tabel 6.19 Karakterisasi Cluster Unsur O₃ untuk Wilayah Surabaya Timur

Unsur O ₃		
Cluster	Karakteristik	Hasil
<i>Cluster 1</i>	Jumlah anggota	3
	Persentase dari Total data di stasiun 6	0,8%
	Nilai minimum	226,91
	Nilai maksimum	486,52
	Rata-rata nilai	313,45
	Kategori	Sangat Tidak Baik
<i>Cluster 2</i>	Jumlah anggota	193
	Persentase dari Total data di stasiun 6	54,8%
	Nilai minimum	51,93
	Nilai maksimum	83,69
	Rata-rata nilai	66,19
	Kategori	Sedang
<i>Cluster 3</i>	Jumlah anggota	68
	Persentase dari Total data di stasiun 6	19,3%
	Nilai minimum	85,05
	Nilai maksimum	154,02
	Rata-rata nilai	98,19
	Kategori	Tidak Baik
<i>Cluster 4</i>	Jumlah anggota	0

Unsur O ₃		
Cluster	Karakteristik	Hasil
	Persentase dari Total data di stasiun 6	0%
	Nilai minimum	NA
	Nilai maksimum	NA
	Rata-rata nilai	NA
	Kategori	Sangat Baik
Cluster 5	Jumlah anggota	88
	Persentase dari Total data di stasiun 6	25%
	Nilai minimum	30,5
	Nilai maksimum	51,83
	Rata-rata nilai	42,33
	Kategori	Baik

Pada stasiun Surabaya Timur yang memiliki unsur O₃ dan masuk ke dalam kategori tidak baik (*cluster* 3) dan sangat tidak baik (*cluster* 1) apabila dijumlahkan yakni senilai 71 hari atau 20,1% dalam satu tahun 2016 sebanyak 352 hari yang telah dikurangi dengan *outlier* sebanyak 14 hari.

6.3.3.3 Karakterisasi Unsur O₃ pada Stasiun 7-Surabaya Selatan

Pada Tabel 6.20 berikut ini merupakan tabel profil karakteristik unsur polutan udara O₃ di stasiun pemantau udara 1 pada daerah Kebonsari yang mewakili wilayah Surabaya Selatan.

Tabel 6.20 Karakterisasi Cluster Unsur O₃ untuk Wilayah Surabaya Selatan

Unsur O ₃ – Surabaya Selatan		
Cluster	Karakteristik	Hasil
Cluster 1	Jumlah anggota	2
	Persentase dari Total seluruh Surabaya	0,6%
	Nilai minimum	253,41
	Nilai maksimum	312,7
	Rata-rata nilai	283,05
	Kategori	Sangat Tidak Baik
Cluster 2	Jumlah anggota	44

Unsur O ₃ – Surabaya Selatan		
Cluster	Karakteristik	Hasil
	Persentase dari Total seluruh Surabaya	12,7%
	Nilai minimum	52,04
	Nilai maksimum	80,39
	Rata-rata nilai	58,6
	Kategori	Sedang
<i>Cluster 3</i>	Jumlah anggota	20
	Persentase dari Total seluruh Surabaya	5,8%
	Nilai minimum	87,39
	Nilai maksimum	195,17
	Rata-rata nilai	126,26
<i>Cluster 4</i>	Kategori	Tidak Baik
	Jumlah anggota	106
	Persentase dari Total seluruh Surabaya	30,7%
	Nilai minimum	14,05
	Nilai maksimum	29,94
<i>Cluster 5</i>	Rata-rata nilai	25,6
	Kategori	Sangat Baik
	Jumlah anggota	173
	Persentase dari Total seluruh Surabaya	50,14%
	Nilai minimum	30,08
	Nilai maksimum	51,7
	Rata-rata nilai	39,2
	Kategori	Baik

Pada stasiun Surabaya Timur yang memiliki unsur O₃ dan masuk ke dalam kategori tidak baik (*cluster 3*) dan sangat tidak baik (*cluster 1*) apabila dijumlahkan yakni senilai 22 hari atau 6,38% dalam satu tahun 2016 sebanyak 345 hari yang telah dikurangi dengan *outlier* sebanyak 21 hari.

Pada Tabel 6.21 menunjukkan perbandingan setiap status polusi udara pada unsur polutan O₃ di setiap bagian wilayah Surabaya.

Tabel 6.21 Perbandingan Status Polusi Unsur O_3 pada Setiap Bagian Wilayah Surabaya

<i>Unsur O_3 tahun 2016</i>	Surabaya Pusat		Surabaya Timur		Surabaya Selatan	
	Sangat Baik	283	77,3%	0	0%	106
Baik	82	22,4%	88	25%	173	53,1%
Sedang	1	0,3%	193	54,8%	44	12,7%
Tidak Baik	0	0%	68	19,3%	20	5,8%
Sangat Tidak Baik	0	0%	3	0,8%	2	0,58%
Total	366	100%	352	100%	345	100%

6.3.4 Unsur PM_{10}

Pada tabel Tabel 6.22 menunjukkan justifikasi label pada setiap kelompok dari hasil *clustering* unsur polutan PM_{10}

Tabel 6.22 Hasil *Clustering* Unsur PM_{10}

Hasil clustering parameter PM_{10} (Partikulat matter) di seluruh wilayah Surabaya						
Cluster	Min	Max	Jumlah	Rata-rata	Urutan indeks	Kategori
1	39,58	60,27	220	48,74	3	Sedang
2	22,55	39,38	289	30,21	2	Baik
3	3,69	22,34	253	14,63	1	Sangat Baik
4	60,44	86,52	207	71,93	4	Tidak Baik
5	86,91	131,29	94	101,65	5	Sangat Tidak Baik

6.3.4.1 Karakterisasi Unsur PM_{10} pada Stasiun 1-Surabaya Pusat

Pada Tabel 6.23 berikut ini merupakan tabel profil karakteristik unsur polutan udara PM_{10} di stasiun pemantau udara 1 pada Taman Prestasi yang mewakili wilayah Surabaya Pusat.

Tabel 6.23 Karakterisasi Cluster Unsur PM_{10} untuk Wilayah Surabaya Pusat

Unsur PM_{10} – Surabaya Pusat		
Cluster	Karakteristik	Hasil
Cluster 1	Jumlah anggota	29
	Persentase dari Total seluruh Surabaya	7,9%

Unsur PM ₁₀ – Surabaya Pusat		
Cluster	Karakteristik	Hasil
	Nilai minimum	39,79
	Nilai maksimum	57,16
	Rata-rata nilai	45,01
	Kategori	Sedang
Cluster 2	Jumlah anggota	130
	Persentase dari Total seluruh Surabaya	35,5%
	Nilai minimum	22,55
	Nilai maksimum	39,38
	Rata-rata nilai	29,22
Cluster 3	Kategori	Baik
	Jumlah anggota	202
	Persentase dari Total seluruh Surabaya	55,2%
	Nilai minimum	3,69
	Nilai maksimum	22,27
	Rata-rata nilai	13,77
Cluster 4	Kategori	Sangat Baik
	Jumlah anggota	5
	Persentase dari Total seluruh Surabaya	1,4%
	Nilai minimum	67,76
	Nilai maksimum	80,7
	Rata-rata nilai	72,91
Cluster 5	Kategori	Tidak Baik
	Jumlah anggota	0
	Persentase dari Total seluruh Surabaya	0%
	Nilai minimum	NA
	Nilai maksimum	NA
	Rata-rata nilai	NA
	Kategori	Sangat Tidak Baik

Pada stasiun Surabaya Pusat yang memiliki unsur PM₁₀ dan masuk ke dalam kategori tidak baik (*cluster 4*) dan sangat tidak baik (*cluster 5*) apabila dijumlahkan yakni senilai 5 hari atau 1,4 % dalam satu tahun 2016 sebanyak 366 hari.

6.3.4.2 Karakterisasi Unsur PM₁₀ pada Stasiun 6-Surabaya Timur

Pada Tabel 6.24 berikut ini merupakan tabel profil karakteristik unsur polutan udara PM₁₀ di stasiun pemantau udara 6 pada daerah Wonorejo yang mewakili wilayah Surabaya Timur.

Tabel 6.24 Karakterisasi *Cluster* Unsur PM₁₀ untuk Wilayah Surabaya Timur

Unsur PM ₁₀ – Surabaya Timur		
<i>Cluster</i>	Karakteristik	Hasil
<i>Cluster 1</i>	Jumlah anggota	114
	Persentase dari Total data di stasiun 6	32,4%
	Nilai minimum	39,58
	Nilai maksimum	60,27
	Rata-rata nilai	48,
	Kategori	Sedang
<i>Cluster 2</i>	Jumlah anggota	114
	Persentase dari Total data di stasiun 6	32,4%
	Nilai minimum	23,03
	Nilai maksimum	38,97
	Rata-rata nilai	30,93
	Kategori	Baik
<i>Cluster 3</i>	Jumlah anggota	32
	Persentase dari Total data di stasiun 6	9,09%
	Nilai minimum	12,24
	Nilai maksimum	22,34
	Rata-rata nilai	18,32
	Kategori	Sangat Baik
<i>Cluster 4</i>	Jumlah anggota	86
	Persentase dari Total data di stasiun 6	24,4%
	Nilai minimum	60,46
	Nilai maksimum	85,52
	Rata-rata nilai	71,55
	Kategori	Tidak Baik
<i>Cluster 5</i>	Jumlah anggota	6
	Persentase dari Total data di stasiun 6	1,7%

Unsur PM ₁₀ – Surabaya Timur		
Cluster	Karakteristik	Hasil
	Nilai minimum	87,59
	Nilai maksimum	105,97
	Rata-rata nilai	93,05
	Kategori	Sangat Tidak Baik

Pada stasiun Surabaya Timur yang memiliki unsur PM₁₀ dan masuk ke dalam kategori tidak baik (*cluster* 4) dan sangat tidak baik (*cluster* 5) apabila dijumlahkan yakni senilai 94 hari atau 26,7% dalam satu tahun 2016 sebanyak 352 hari yang telah dikurangi dengan *outlier* sebanyak 14 hari.

6.3.4.3 Karakterisasi Unsur O₃ pada Stasiun 7-Surabaya Selatan

Pada Tabel 6.25 berikut ini merupakan tabel menunjukkan profil karakteristik unsur polutan udara PM₁₀ di stasiun pemantau udara pada daerah Kebonsari yang mewakili wilayah Surabaya Selatan.

Tabel 6.25 Karakterisasi *Cluster* Unsur PM₁₀ untuk Wilayah Surabaya Selatan

Unsur PM ₁₀ – Surabaya Selatan		
Cluster	Karakteristik	Hasil
<i>Cluster 1</i>	Jumlah anggota	77
	Persentase dari Total seluruh Surabaya	22,3%
	Nilai minimum	39,78
	Nilai maksimum	60,21
	Rata-rata nilai	50,2
	Kategori	Sedang
<i>Cluster 2</i>	Jumlah anggota	45
	Persentase dari Total seluruh Surabaya	13%
	Nilai minimum	22,87
	Nilai maksimum	39,1
	Rata-rata nilai	31,22
	Kategori	Baik
<i>Cluster 3</i>	Jumlah anggota	19

Unsur PM ₁₀ – Surabaya Selatan		
Cluster	Karakteristik	Hasil
	Persentase dari Total seluruh Surabaya	5,5%
	Nilai minimum	9,31
	Nilai maksimum	21,68
	Rata-rata nilai	17,56
	Kategori	Sangat Baik
Cluster 4	Jumlah anggota	116
	Persentase dari Total seluruh Surabaya	33,6%
	Nilai minimum	60,44
	Nilai maksimum	86,26
	Rata-rata nilai	72,18
	Kategori	Tidak Baik
Cluster 5	Jumlah anggota	88
	Persentase dari Total seluruh Surabaya	25,5%
	Nilai minimum	86,91
	Nilai maksimum	131,29
	Rata-rata nilai	102,239
	Kategori	Sangat Tidak Baik

Pada stasiun Surabaya Timur yang memiliki unsur PM₁₀ dan masuk ke dalam kategori tidak sehat (*cluster5*), sangat tidak sehat (*cluster2*) dan berbahaya (*cluster 4*) apabila dijumlahkan yakni senilai 205 hari atau 59,4% dalam satu tahun 2016 sebanyak 345 hari yang telah dikurangi dengan *outlier* sebanyak 21 hari.

Pada Tabel 6.26 menunjukkan perbandingan setiap status polusi udara pada unsur polutan PM₁₀ di setiap bagian wilayah Surabaya.

Tabel 6.26 Perbandingan Status Polusi Unsur PM₁₀ pada Setiap Bagian Wilayah Surabaya

Unsur PM ₁₀ tahun 2016	Surabaya Pusat		Surabaya Timur		Surabaya Selatan	
Sangat Baik	202	55,2%	32	9,1%	19	5,5%
Baik	129	35,2%	114	32,4%	45	13 %
Sedang	30	8,2%	112	31,8%	76	22 %
Tidak Baik	5	1,4%	88	25%	117	33,9%

<i>Unsur PM₁₀</i> <i>tahun 2016</i>		Surabaya Pusat		Surabaya Timur		Surabaya Selatan	
Sangat Baik	Tidak Baik	0	0%	6	1,7%	88	25,5%
Total		366	100%	352	100%	345	100%

6.3.5 Unsur SO₂

Pada tabel Tabel 6.27 menunjukkan justifikasi label pada setiap kelompok dari hasil *clustering* unsur polutan SO₂.

Tabel 6.27 Justifikasi Kelompok Hasil *Clustering* Unsur SO₂

Hasil clustering parameter SO ₂ (Sulfur Dioksida) di seluruh wilayah Surabaya						
Cluster	Min	Max	Jumlah	Rata-rata	Urutan indeks	Kategori
1	7,93	13,96	179	10,75	2	Baik
2	33,57	66	71	42,46	5	Sangat Tidak Baik
3	1,74	7,29	209	4,25	1	Sangat Baik
4	20,5	32,87	212	23,68	4	Tidak Baik
5	14,07	20,47	392	17,28	3	Sedang

6.3.5.1 Karakterisasi Unsur SO₂ pada Stasiun 1-Surabaya Pusat

Pada Tabel 6.28 berikut ini merupakan tabel menunjukkan profil karakteristik unsur polutan udara SO₂ di stasiun pemantau udara 1 pada Taman Prestasi yang mewakili wilayah Surabaya Pusat.

Tabel 6.28 Karakterisasi Cluster Unsur SO₂ untuk Wilayah Surabaya Pusat

Unsur SO ₂ – Surabaya Pusat		
Cluster	Karakteristik	Hasil
<i>Cluster 1</i>	Jumlah anggota	29
	Persentase dari Total seluruh Surabaya	7,9%
	Nilai minimum	7,93
	Nilai maksimum	13,89
	Rata-rata nilai	9,75
	Kategori	Baik
<i>Cluster 2</i>	Jumlah anggota	0

Unsur SO ₂ – Surabaya Pusat		
Cluster	Karakteristik	Hasil
	Persentase dari Total seluruh Surabaya	0%
	Nilai minimum	NA
	Nilai maksimum	NA
	Rata-rata nilai	NA
	Kategori	Sangat Tidak Baik
<i>Cluster 3</i>	Jumlah anggota	175
	Persentase dari Total seluruh Surabaya	47,8%
	Nilai minimum	1,74
	Nilai maksimum	7,29
	Rata-rata nilai	4,4
	Kategori	Sangat Baik
<i>Cluster 4</i>	Jumlah anggota	97
	Persentase dari Total seluruh Surabaya	26,5%
	Nilai minimum	20,9
	Nilai maksimum	21,71
	Rata-rata nilai	21,12
	Kategori	Tidak Baik
<i>Cluster 5</i>	Jumlah anggota	65
	Persentase dari Total seluruh Surabaya	17,7%
	Nilai minimum	18,34
	Nilai maksimum	20,42
	Rata-rata nilai	18,9
	Kategori	Sedang

Pada stasiun Surabaya Pusat yang memiliki unsur SO₂ dan masuk ke dalam kategori tidak baik (*cluster 4*) dan sangat tidak baik (*cluster 2*) apabila dijumlahkan yakni senilai 97 hari atau 26,5 % dalam satu tahun 2016 sebanyak 366 hari.

6.3.5.2 Karakterisasi Unsur SO₂ pada Stasiun 6-Surabaya Timur

Pada Tabel 6.29 berikut ini merupakan tabel menunjukkan profil karakteristik unsur polutan udara SO₂ di stasiun pemantau udara 6 pada daerah Wonorejo yang mewakili wilayah Surabaya Timur.

Tabel 6.29 Karakterisasi Cluster Unsur SO₂ untuk Wilayah Surabaya Timur

Unsur SO₂ – Surabaya Timur		
<i>Cluster</i>	Karakteristik	Hasil
<i>Cluster 1</i>	Jumlah anggota	27
	Persentase dari Total data di stasiun 6	7,4%
	Nilai minimum	8,15
	Nilai maksimum	13,95
	Rata-rata nilai	10,88
	Kategori	Baik
<i>Cluster 2</i>	Jumlah anggota	71
	Persentase dari Total data di stasiun 6	19,4%
	Nilai minimum	33,57
	Nilai maksimum	66
	Rata-rata nilai	42,46
	Kategori	Sangat Tidak Baik
<i>Cluster 3</i>	Jumlah anggota	6
	Persentase dari Total data di stasiun 6	1,6%
	Nilai minimum	4,8
	Nilai maksimum	5,28
	Rata-rata nilai	5,04
	Kategori	Sangat Baik
<i>Cluster 4</i>	Jumlah anggota	105
	Persentase dari Total data di stasiun 6	28,7%
	Nilai minimum	20,5
	Nilai maksimum	32,87
	Rata-rata nilai	26,22
	Kategori	Tidak Baik
<i>Cluster 5</i>	Jumlah anggota	143
	Persentase dari Total data di stasiun 6	39,1%
	Nilai minimum	14,14
	Nilai maksimum	20,47
	Rata-rata nilai	143
	Kategori	Sedang

Pada stasiun Surabaya Timur yang memiliki unsur SO₂ dan masuk ke dalam kategori tidak baik (*cluster 4*) dan sangat tidak baik (*cluster 2*) apabila dijumlahkan yakni senilai 176 hari atau

47,3% dalam satu tahun 2016 sebanyak 352 hari yang telah dikurangi dengan *outlier* sebanyak 14 hari.

6.3.5.3 Karakterisasi Unsur SO₂ pada Stasiun 7-Surabaya Selatan

Pada Tabel 6.30 berikut ini merupakan tabel menunjukkan profil karakteristik unsur polutan udara SO₂ di stasiun pemantau udara 1 pada daerah Kebonsari yang mewakili wilayah Surabaya Selatan.

Tabel 6.30 Karakterisasi Cluster Unsur SO₂ untuk Wilayah Surabaya Selatan
Unsur SO₂ – Surabaya Selatan

<i>Cluster</i>	Karakteristik	Hasil
<i>Cluster 1</i>	Jumlah anggota	123
	Persentase dari Total seluruh Surabaya	33,6%
	Nilai minimum	8,26
	Nilai maksimum	13,96
	Rata-rata nilai	10,9
	Kategori	Baik
<i>Cluster 2</i>	Jumlah anggota	0
	Persentase dari Total seluruh Surabaya	0%
	Nilai minimum	NA
	Nilai maksimum	NA
	Rata-rata nilai	NA
	Kategori	Sangat Tidak Baik
<i>Cluster 3</i>	Jumlah anggota	28
	Persentase dari Total seluruh Surabaya	7,6%
	Nilai minimum	2,54
	Nilai maksimum	6,05
	Rata-rata nilai	3,32
	Kategori	Sangat Baik
<i>Cluster 4</i>	Jumlah anggota	10
	Persentase dari Total seluruh Surabaya	2,7%
	Nilai minimum	20,61
	Nilai maksimum	22,72
	Rata-rata nilai	21,35

Unsur SO ₂ – Surabaya Selatan		
Cluster	Karakteristik	Hasil
Cluster 5	Kategori	Tidak Baik
	Jumlah anggota	184
	Persentase dari Total seluruh Surabaya	50,3%
	Nilai minimum	14,07
	Nilai maksimum	20,33
	Rata-rata nilai	17,2
	Kategori	Sedang

Pada stasiun Surabaya Timur yang memiliki unsur SO₂ dan masuk ke dalam kategori tidak baik (*cluster* 4) dan sangat tidak baik (*cluster* 2) apabila dijumlahkan yakni senilai 10 hari atau 2,7% dalam satu tahun 2016 sebanyak 345 hari yang telah dikurangi dengan *outlier* sebanyak 21 hari.

Pada Tabel 6.31 menunjukkan perbandingan setiap status polusi udara pada unsur polutan SO₂ di setiap bagian wilayah Surabaya.

Tabel 6.31 Perbandingan Status Polusi Unsur SO₂ pada Setiap Bagian Wilayah Surabaya

Unsur SO ₂ tahun 2016	Surabaya Pusat		Surabaya Timur		Surabaya Selatan	
	Sangat Baik	175	47,8%	6	1,6%	28
Baik	29	7,9%	27	7,4%	123	33,6%
Sedang	65	17,8%	143	39,1%	184	50,3%
Tidak Baik	97	26,5%	105	28,7%	10	2,7%
Sangat Tidak Baik	0	0%	71	19,4%	0	0%
Total	366	100%	352	100%	345	100%

6.3.6 Perbandingan Titik Rawan Polusi Setiap Bagian Wilayah Surabaya

Pada Tabel 6.32 menunjukkan perbandingan titik rawan polusi di setiap bagian wilayah Surabaya berdasarkan berdasarkan lima unsur polutan udara. Hasil menunjukkan bahwa titik rawan polusi yang paling banyak adalah daerah wilayah Surabaya Selatan dimana unsur polutan yang paling tercemar adalah Karbon Monoksida, Nitrogen Dioksida dan Partikulat Matter

atau debu. Sedangkan titik rawan polusi kedua adalah Surabaya Timur dimana memiliki unsur yang paling tercemar dibandingkan daerah lain yakni Ozon dan dan Sulfur Dioksida.

Tabel 6.32 Perbandingan Rawan Polusi Pada Setiap Unsur Polutan dan Setiap Wilayah Surabaya

	Kategori	CO	NO ₂	O ₃	PM ₁₀	SO ₂
Surabaya Pusat	Tidak Baik	0%	0%	0%	1,4%	26,5%
	Sangat Tidak Baik	0%	0%	0%	0%	0%
	Total	0%	0%	0%	1,4%	26,5%
Surabaya Timur	Tidak Sehat	24,4%	33,3%	19,3%	25%	28,7%
	Sangat Tidak Baik	0,6%	0,3%	0,8%	1,7%	19,4%
	Total	25%	33,6%	20,1%	26,7%	48,1%
Surabaya Selatan	Tidak Baik	26,1%	33,3%	5,8%	33,9%	2,7%
	Sangat Tidak Baik	20%	11,6%	0,58%	25,5%	0%
	Total	46,1%	44,9%	6,38%	59,4%	2,7%

6.4 Pembuatan Model Klasifikasi dengan Metode Naive Bayes

Pada penelitian ini dilakukan pembuatan model klasifikasi untuk setiap unsur polutan udara yakni 5 unsur polutan yang diantaranya adalah CO, NO₂, O₃, PM₁₀, SO₂. Pembuatan model menggunakan metode Naive Bayes dengan K-Fold cross validation untuk menemukan pembagian data *training* dan *testing* yang cocok dengan model.

6.4.1 Klasifikasi Unsur Karbon Monoksida

Pada Tabel 6.33 menunjukkan hasil perbandingan akurasi model klasifikasi unsur Karbon Monoksida dengan menggunakan beberapa pembagian proporsi data. Hasil menunjukkan bahwa akurasi terbaik ketika melakukan pelatihan model maupun menguji model adalah dengan proporsi data *training data* 80% dan *testing data* 20% yakni dengan akurasi 99,8% pada proses pelatihan model dan 100%

akurasi pada pengujian model. Oleh karena itu model yang akan digunakan adalah model dengan hasil pengujian model terbaik yakni dengan proporsi data 80% dan 20%.

Model prediksi klasifikasi dengan proporsi data *training* & *testing* 80% dan 20% merupakan model terbaik karena memiliki akurasi di atas 80% yakni akurasi pengujian model sebesar 100% yang berarti dapat dikatakan model untuk memprediksi tersebut sangat baik. Akurasi sebesar 100% menunjukkan berarti dari total pengujian data sebesar 319 data dari model, maka semua jumlah data telah terprediksi kelas dengan benar dan tidak ada prediksi yang salah.

Tabel 6.33 Perbandingan Akurasi Model Unsur Karbon Monoksida (CO)

Percobaan Data	Akurasi data <i>training</i>	Akurasi data <i>testing</i>
Training 60% & testing 40%	99,7%	99,1%
Training 70% & testing 30%	98,1%	98,4%
Training 80% & testing 20%	99,8%	100%

Pada Tabel 6.34 menunjukkan hasil *confusion matrix* prediksi data pengujian dari proporsi data terbaik yakni data *training* 80% dan data *testing* 20%. Dapat ditunjukkan dari matriks bahwa semua total data terklasifikasi dengan benar.

Tabel 6.34 Confusion matrix data testing unsur polutan udara CO

Prediction	Reference				Tidak Baik	Sedang	Tidak Baik
	Baik	Sangat Baik	Baik	Sangat Tidak Baik			
Baik	170	0	0	0	0	0	
Sangat Baik	0	56	0	0	0	0	
Sangat Tidak Baik	0	0	0	30	0	0	
Sedang	0	0	0	0	92	0	
Tidak Baik	0	0	0	0	0	78	

Pada Tabel 6.35 menunjukkan hasil *sensitivity* dari masing-masing kelas yang bernilai 1 atau berarti sama dengan 100% yang berarti tingkat kebenaran dari masing-masing label kelas yang terklasifikasi benar sesuai dengan kelasnya adalah semua data benar. Sedangkan *specivity* semua kelas menunjukkan nilai 1 yang berarti semua prediksi yang terklasifikasi selain pada kelasnya atau negatif semuanya benar.

Tabel 6.35 Statistik Hasil Klasifikasi dengan data testing 20% unsur polutan CO

```

overall Statistics
  Accuracy : 1
    95% CI : (0.9914, 1)
  No Information Rate : 0.3991
  P-Value [Acc > NIR] : < 2.2e-16

  Kappa : 1
  Mcnemar's Test P-Value : NA

Statistics by Class:
  Class: Baik Class: Sangat Baik Class: Sangat Tidak Baik Class: Sedang Class: Tidak Baik
sensitivity      1.0000      1.0000      1.00000      1.000      1.0000
specificity      1.0000      1.0000      1.00000      1.000      1.0000

```

6.4.2 Klasifikasi Unsur Nitrogen Dioksida

Pada Tabel 6.36 menunjukkan hasil perbandingan akurasi model klasifikasi unsur Nitrogen Dioksida dengan menggunakan beberapa pembagian proporsi data. Hasil menunjukkan bahwa akurasi terbaik ketika melakukan pelatihan model maupun menguji model adalah dengan proporsi data *training data* 70% dan *testing data* 30% yakni dengan akurasi 99,5% pada proses pelatihan model dan 99,4% akurasi pada pengujian model. Oleh karena itu model yang akan digunakan adalah model dengan hasil pengujian model terbaik yakni dengan proporsi data 70% dan 30%.

Model prediksi klasifikasi unsur NO₂ dengan proporsi data *training & testing* 70% dan 30% merupakan model terbaik karena memiliki akurasi di atas 80% yakni akurasi pengujian model sebesar 99,4% yang berarti dapat dikatakan model untuk memprediksi tersebut sangat baik. Akurasi sebesar 99,4% menunjukkan berarti dari total pengujian data sebesar 319 data dari model, maka jumlah yang terprediksi kelas dengan benar adalah sebanyak 317 data dan hanya dua data terprediksi salah.

Tabel 6.36 Perbandingan Akurasi Model Unsur Nitrogen Dioksida (NO₂)

Percobaan Data	Akurasi data <i>training</i>	Akurasi data <i>testing</i>
Training 60% & testing 40%	99,1%	98,4%
Training 70% & testing 30%	99,5%	99,4%
Training 80% & testing 20%	99,8%	97,2%

Pada Tabel 6.37 menunjukkan hasil *confussion matrix* prediksi data pengujian dari proporsi data terbaik dari unsur NO₂ yakni

data *training* 70% dan data *testing* 30%. Dapat ditunjukkan dari matriks bahwa data yang terprediksi salah tidak sesuai dengan aktual terdapat 5 data yakni 1 data terprediksi salah pada label kelas baik dan 4 data pada label kelas sedang.

Tabel 6.37 Confusion matrix data testing unsur polutan udara NO2

Confusion Matrix and Statistics

Prediction	Reference					
	Baik	Sangat Baik	Baik	Sangat Tidak Baik	Sedang	Tidak Baik
Baik	67	0	0	1	0	0
Sangat Baik	0	11	0	0	0	0
Sangat Tidak Baik	0	0	102	0	0	0
Sedang	0	0	4	96	0	0
Tidak Baik	0	0	0	0	0	38

Pada Tabel 6.38 menunjukkan hasil *sensitivity* dari masing-masing kelas yang bernilai 1 atau berarti sama dengan 100% yang berarti tingkat kebenaran dari masing-masing label kelas yang terklasifikasi benar sesuai dengan kelasnya adalah semua label kelas kecuali pada label 'sangat tidak baik'. Sedangkan *specivity* semua kelas menunjukkan nilai 1 yang berarti semua prediksi yang terklasifikasi selain pada kelasnya atau negatif semuanya benar kecuali pada label kelas 'baik' dan 'sedang'.

Tabel 6.38 Statistik Hasil Klasifikasi dengan data testing 30% unsur polutan NO2

Overall Statistics

Accuracy : 0.9843
 95% CI : (0.9638, 0.9949)
 No Information Rate : 0.3354
 P-Value [Acc > NIR] : < 2.2e-16

Kappa : 0.9788
 McNemar's Test P-Value : NA

Statistics by Class:

	Class: Baik	Class: Sangat Baik	Class: Sangat Tidak Baik	Class: Sedang	Class: Tidak Baik
Sensitivity	1.0000	1.00000	0.9533	1.0000	1.0000
Specificity	0.9960	1.00000	1.0000	0.9821	1.0000

6.4.3 Klasifikasi Unsur Ozon

Pada Tabel 6.39 menunjukkan hasil perbandingan akurasi model klasifikasi unsur Ozon dengan menggunakan beberapa pembagian proporsi data. Hasil menunjukkan bahwa akurasi terbaik ketika melakukan pelatihan model maupun menguji model adalah dengan proporsi data *training data* 80% dan *testing data* 20% yakni dengan akurasi 99,4% pada proses pelatihan model dan 100% akurasi pada pengujian model. Oleh

karena itu model yang akan digunakan adalah model dengan hasil pengujian model terbaik yakni dengan proporsi data 80% dan 20%.

Model prediksi klasifikasi O₃ dengan proporsi data *training* & *testing* 80% dan 20% merupakan model terbaik karena memiliki akurasi di atas 80% yakni akurasi pengujian model sebesar 100% yang berarti dapat dikatakan model untuk memprediksi tersebut sangat baik. Akurasi sebesar 100% menunjukkan berarti dari total pengujian data sebesar 319 data dari model, maka semua jumlah data telah terprediksi kelas dengan benar dan tidak ada prediksi yang salah.

Tabel 6.39 Perbandingan Akurasi Model Unsur Ozon (O₃)

Percobaan Data	Akurasi data <i>training</i>	Akurasi data <i>testing</i>
Training 60% & testing 40%	99,1%	98,6%
Training 70% & testing 30%	99,2%	88,7%
Training 80% & testing 20%	99,4%	100%

Pada Tabel 6.40 menunjukkan hasil *confussion matrix* prediksi data pengujian dari proporsi data terbaik dari unsur O₃ yakni data *training* 80% dan data *testing* 20%. Dapat ditunjukkan dari matriks bahwa semua data terprediksi benar sesuai dengan label kelas masing-masing.

Tabel 6.40 Confussion matrix data testing unsur polutan udara O₃

```
> table(predict(ModelNB_O3$finalModel, a3)$class, b3)
      b3
      Baik Sangat Baik Sangat Tidak Baik Sedang
Baik      23          0          0          0
Sangat Baik  0          58          0          0
Sangat Tidak Baik  0          0          60          0
Sedang      0          0          0          72
Tidak Baik  0          0          0          0
```

6.4.4 Klasifikasi Unsur Partikulat Matter

Pada Tabel 6.41 menunjukkan hasil perbandingan akurasi model klasifikasi unsur Partikulat Matter dengan menggunakan beberapa pembagian proporsi data. Hasil menunjukkan bahwa akurasi terbaik ketika melakukan pelatihan model maupun

menguji model adalah dengan proporsi data *training data* 70% dan *testing data* 30% yakni dengan akurasi 99,2% pada proses pelatihan model dan 99,4% akurasi pada pengujian model. Oleh karena itu model yang akan digunakan adalah model dengan hasil pengujian model terbaik yakni dengan proporsi data 70% dan 30%.

Model prediksi klasifikasi unsur PM₁₀ dengan proporsi data *training & testing* 70% dan 30% merupakan model terbaik karena memiliki akurasi di atas 80% yakni akurasi pengujian model sebesar 99,4% yang berarti dapat dikatakan model untuk memprediksi tersebut sangat baik. Akurasi sebesar 99,1% menunjukkan berarti dari total pengujian data sebesar 319 data dari model, maka jumlah yang terprediksi kelas dengan benar adalah sebanyak 316 data dan hanya 3 data terprediksi salah.

Tabel 6.41 Perbandingan Akurasi Model Unsur Partikulat Matter (PM10)

Percobaan Data	Akurasi data <i>training</i>	Akurasi data <i>testing</i>
Training 60% & testing 40%	98,6%	98,6%
Training 70% & testing 30%	99,3%	99,1%
Training 80% & testing 20%	99,2%	98,6%

Pada Tabel 6.42 menunjukkan hasil *confussion matrix* prediksi data pengujian dari proporsi data terbaik dari unsur NO₂ yakni data *training* 70% dan data *testing* 30%. Dapat ditunjukkan dari matriks bahwa data yang terprediksi salah tidak sesuai dengan aktual terdapat 3 data yakni 2 data terprediksi salah pada label kelas baik dan 1 data pada label kelas sedang.

Tabel 6.42 Confussion matrix data testing unsur polutan udara PM10

Prediction	Reference					
	Baik	Sangat Baik	Baik	Sangat Tidak Baik	Tidak Baik	Sedang
Baik	58	0	2	0	0	0
Sangat Baik	0	82	0	0	0	0
Sangat Tidak Baik	0	0	58	0	0	0
Sedang	0	1	0	92	0	0
Tidak Baik	0	0	0	0	0	26

Pada Tabel 6.43 menunjukkan hasil *sensivity* dari masing-masing kelas yang bernilai 1 atau berarti sama dengan 100% yang berarti tingkat kebenaran dari masing-masing label kelas

yang terklasifikasi benar sesuai dengan kelasnya adalah semua label kelas kecuali pada label ‘sangat baik’ dan ‘sangat tidak baik’. Sedangkan *specivity* semua kelas menunjukkan nilai 1 yang berarti semua prediksi yang terklasifikasi selain pada kelasnya atau negatif semuanya benar kecuali pada label kelas ‘baik’ dan ‘sedang’.

Tabel 6.43 Statistik Hasil Klasifikasi dengan data testing 30% unsur polutan PM10

```

overall Statistics
    Accuracy : 0,9906
    95% CI : (0,9728, 0,9981)
    No Information Rate : 0,2884
    P-value [Acc > NIR] : < 2.2e-16
    Kappa : 0,9878
    McNemar's Test P-value : NA

Statistics by class:
    Class: Baik Class: Sangat Baik Class: Sangat Tidak Baik Class: Sedang Class: Tidak Baik
Sensitivity    1.0000    0.9880    0.9667    1.0000    1.0000
Specificity    0.9923    1.0000    1.0000    0.9956    1.0000

```

6.4.5 Klasifikasi Unsur Sulfur Dioksida

Pada Tabel 6.44 menunjukkan hasil perbandingan akurasi model klasifikasi unsur Sulfur Dioksida dengan menggunakan beberapa pembagian proporsi data. Hasil menunjukkan bahwa akurasi terbaik ketika melakukan pelatihan model maupun menguji model adalah dengan proporsi data *training data* 70% dan *testing data* 30% yakni dengan akurasi 98,9% pada proses pelatihan model dan 99,1% akurasi pada pengujian model. Oleh karena itu model yang akan digunakan adalah model dengan hasil pengujian model terbaik yakni dengan proporsi data 70% dan 30%.

Model prediksi klasifikasi unsur SO₂ dengan proporsi data *training & testing* 70% dan 30% merupakan model terbaik karena memiliki akurasi di atas 80% yakni akurasi pengujian model sebesar 99,4% yang berarti dapat dikatakan model untuk memprediksi tersebut sangat baik. Akurasi sebesar 99,1% menunjukkan berarti dari total pengujian data sebesar 319 data dari model, maka jumlah yang terprediksi kelas dengan benar adalah sebanyak 316 data dan hanya 3 data terprediksi salah.

Tabel 6.44 Perbandingan Akurasi Model Unsur Sulfur Dioksida (SO₂)

Percobaan Data	Akurasi data <i>training</i>	Akurasi data <i>testing</i>
Training 60% & testing 40%	98,9%	98,1%
Training 70% & testing 30%	98,9%	99,1%
Training 80% & testing 20%	98,7%	98,1%

Pada Tabel 6.45 menunjukkan hasil *confussion matrix* prediksi data pengujian dari proporsi data terbaik dari unsur NO₂ yakni data *training* 70% dan data *testing* 30%. Dapat ditunjukkan dari matriks bahwa data yang terprediksi salah tidak sesuai dengan aktual terdapat 3 data yakni data terprediksi salah pada label kelas ‘sedang’.

Tabel 6.45 Confussion matrix data testing unsur polutan udara SO₂

Confusion Matrix and Statistics

Prediction	Reference					
	Baik	Sangat Baik	Baik	Sangat Tidak Baik	Tidak Baik	Sangat Tidak Baik
Baik	18	0	0	0	0	0
Sangat Baik	0	114	0	0	0	0
Sangat Tidak Baik	0	0	68	0	0	0
Sedang	0	3	0	64	0	0
Tidak Baik	0	0	0	0	0	52

Pada Tabel 6.46 menunjukkan hasil *sensivity* dari masing-masing kelas yang bernilai 1 atau berarti sama dengan 100% yang berarti tingkat kebenaran dari masing-masing label kelas yang terklasifikasi benar sesuai dengan kelasnya adalah semua label kelas kecuali pada label ‘sedang’. Sedangkan *specivity* semua kelas menunjukkan nilai 1 yang berarti semua prediksi yang terklasifikasi selain pada kelasnya atau negatif semuanya benar kecuali pada label kelas ‘sedang’.

Tabel 6.46 Statistik Hasil Klasifikasi dengan data testing 30% unsur polutan SO₂

```

overall Statistics
Accuracy : 0.9906
95% CI : (0.9728, 0.9981)
No Information Rate : 0.3668
P-Value [Acc > NIR] : < 2.2e-16

Kappa : 0.9875
McNemar's Test P-Value : NA

Statistics by Class:
Class: Baik Class: Sangat Baik Class: Sangat Tidak Baik Class: Sedang Class: Tidak Baik
sensitivity 1.00000 0.9744 1.0000 1.0000 1.0000 1.000
specificity 1.00000 1.0000 1.0000 1.0000 0.9882 1.000

```

6.5 Analisis Uji Korelasi

Pada Tabel 6.47 menunjukkan tabel hasil uji korelasi dari kelima variabel data kualitas udara (CO, NO₂, O₃, PM₁₀, SO₂) dengan keempat variabel data meteorologi (suhu, tekanan, jarak pandang, kecepatan angin). Berdasarkan hasil *correlation coefficient* dengan metode Kendall Tau menunjukkan bahwa seluruh variabel dari data meteorologi menunjukkan tidak ada korelasi terhadap data utama yakni unsur polutan udara. Oleh karena itu pada proses peramalan selanjutnya hanya akan menggunakan data unsur polutan sebagai *input*.

Tabel 6.47 Hasil uji korelasi data meteorologi terhadap data polutan udara

No	Variabel	Hasil		Kesimpulan
		Cor. coefficient (tau)	p-value	
1	CO – Suhu	0,069	0,053	Tidak berkorelasi
2	CO – tekanan	0,041	0,251	Tidak berkorelasi
3	CO – Jarak pandang	0,019	0,627	Tidak berkorelasi
4	CO – Kecepatan angin	- 0,069	0,051	Tidak berkorelasi
5	NO ₂ – Suhu	0,042	0,23	Tidak berkorelasi
6	NO ₂ – Tekanan	-0,035	0,323	Tidak berkorelasi
7	NO ₂ – Jarak pandang	-0,053	0,173	Tidak berkorelasi
8	NO ₂ – Kecepatan angin	0,0096	0,788	Tidak berkorelasi
9	O ₃ – Suhu	-0,090	0,011	Tidak berkorelasi
10	O ₃ – Tekanan	-0,089	0,011	Tidak berkorelasi
11	O ₃ – Jarak pandang	-0,090	0,019	Tidak berkorelasi
12	O ₃ – Kecepatan angin	0,003	0,921	Tidak berkorelasi
13	PM ₁₀ – Suhu	-0,044	0,212	Tidak berkorelasi
14	PM ₁₀ – Tekanan	-0,070	0,050	Tidak berkorelasi
15	PM ₁₀ – Jarak pandang	-0,006	0,873	Tidak berkorelasi

No	Variabel	Hasil		Kesimpulan
		Cor. coefficient (tau)	p-value	
16	PM10 – Kecepatan angin	0,045	0,204	Tidak berkorelasi
17	SO2 – Suhu	0,017	0,621	Tidak berkorelasi
18	SO2 – Tekanan	-0,047	0,185	Tidak berkorelasi
19	SO2 – Jarak pandang	-0,056	0,178	Tidak berkorelasi
20	SO2 – Kecepatan angin	-0,005	0,873	Tidak berkorelasi

6.6 Analisis Hasil Peramalan

Pada sub bagian analisis hasil peramalan dilakukan dua tahapan yakni tahap pembentukan model dengan melakukan pelatihan data dan pengujian data, serta tahap peramalan dengan menggunakan model yang dianggap paling baik.

6.6.1 Pembentukan Model

Pada sub bab ini dijelaskan proses percobaan model yang telah dilakukan pada penelitian tugas akhir ini. Model yang perlu dicari pada tahap ini adalah tiga model yang terdiri dari model untuk stasiun 1 yang berlokasi di Taman Prestasi, model untuk stasiun 6 yang berlokasi di daerah Wonorejo, dan stasiun 7 yang berlokasi di daerah Kebonsari. Pada penelitian tugas akhir ini menggunakan 10 periode waktu percobaan dimana setiap periode terdiri dari 5 node yakni lima variabel polutan udara. Percobaan model dilakukan dengan mengujicobakan jumlah *input node* dan *hidden node* serta parameter-parameter seperti *activation function*, *learning rate*, *stepmax*. Penjelasan lebih lanjut pada percobaan model dijelaskan pada sub bab selanjutnya.

6.6.1.1 Model ANN 1 Periode 5 *Input Node*

Percobaan Model ANN 1 merupakan *input data* dari satu periode sebelumnya yang dimulai dari tanggal 1 Januari 2016. Satu periode terdiri dari 5 *input node* dan memiliki target 5 *output node*. Berikut ini adalah percobaan model 1 periode 5

input node pada setiap stasiun pemantau udara yang aktif pada tahun 2016

A. Model ANN 5 *Nodes Input* SUF 1(Surabaya Pusat)

Pada penelitian tugas akhir ini, memiliki 395 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 5 nodes pada 1 periode yakni sehari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes, activation function, learning rate, stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.48. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 29,70% untuk hasil pelatihan model dan 24,60% untuk hasil pengujian model. Model tersebut memiliki 6 node pada *hidden layer* dengan fungsi aktivasi *logistic*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.48 Hasil Percobaan Model 1 periode 5 *Nodes Input* Stasiun Surabaya Pusat

Hidden	Stepmax/ epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
6	100000	logistic	0.1	29.70%	24.60%
6	200000	logistic	0.1	29.70%	24.60%
6	300000	logistic	0.1	29.70%	24.60%
6	100000	logistic	0.2	29.70%	24.60%
6	200000	logistic	0.2	29.70%	24.60%
6	300000	logistic	0.2	29.70%	24.60%
6	100000	logistic	0.3	29.70%	24.60%
6	200000	logistic	0.3	29.70%	24.60%
6	300000	logistic	0.3	29.70%	24.60%
6	100000	logistic	0.4	29.70%	24.60%
...

B. Model ANN 5 *Nodes Input* SUF 6 (Surabaya Timur)

Pada penelitian tugas akhir ini, memiliki 270 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 5 nodes pada 1 periode yakni sehari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes*, *activation function*, *learning rate*, *stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.49. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 33,90% untuk hasil pelatihan model dan 34,20% untuk hasil pengujian model. Model tersebut memiliki 4 node pada *hidden layer* dengan fungsi aktivasi *tanh*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.49 Hasil Percobaan Model 1 periode 5 *Nodes Input* Stasiun Surabaya Timur

Hidden	Stepmax/ epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
4	100000	tanh	0.1	33.90%	34.20%
4	200000	tanh	0.1	33.90%	34.20%
4	300000	tanh	0.1	33.90%	34.20%
4	100000	tanh	0.2	33.90%	34.20%
4	200000	tanh	0.2	33.90%	34.20%
4	300000	tanh	0.2	33.90%	34.20%
4	100000	tanh	0.3	33.90%	34.20%
4	200000	tanh	0.3	33.90%	34.20%
4	300000	tanh	0.3	33.90%	34.20%
4	100000	tanh	0.4	33.90%	34.20%
...

C. Model ANN 5 *Nodes Input* SUF 7 (Surabaya Selatan)

Pada penelitian tugas akhir ini, memiliki 324 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari

jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 5 nodes pada 1 periode yakni sehari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes*, *activation function*, *learning rate*, *stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.50. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 30,40% untuk hasil pelatihan model dan 34,0% untuk hasil pengujian model. Model tersebut memiliki 4 node pada *hidden layer* dengan fungsi aktivasi *tanh*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.50 Hasil Percobaan Model 1 periode 5 Nodes Input Stasiun Surabaya Selatan

Hidden	Stepmax/ epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
6	100000	logistic	0.1	30.40%	34%
6	200000	logistic	0.1	30.40%	34%
6	300000	logistic	0.1	30.40%	34%
6	100000	logistic	0.2	30.40%	34%
6	200000	logistic	0.2	30.40%	34%
6	300000	logistic	0.2	30.40%	34%
6	100000	logistic	0.3	30.40%	34%
6	200000	logistic	0.3	30.40%	34%
6	300000	logistic	0.3	30.40%	34%
6	100000	logistic	0.4	30.40%	34%
...

6.6.1.2 Model ANN 2 Periode 10 Input Node

Percobaan Model ANN 2 periode merupakan *input data* dari dua periode sebelumnya yang dimulai dari tanggal 1 Januari 2016. Satu periode terdiri dari 10 *input node* dan memiliki target 5 *output node*. Berikut ini adalah percobaan model 2 periode 10 *input node* pada setiap stasiun pemantau udara yang aktif pada tahun 2016.

A. Model ANN 10 *Nodes Input* SUF 1(Surabaya Pusat)

Pada penelitian tugas akhir ini, memiliki 395 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan *node* pada *input layer* berjumlah 10 nodes pada 2 periode yakni dua hari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes*, *activation function*, *learning rate*, *stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.51. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 28,30% untuk hasil pelatihan model dan 27,40% untuk hasil pengujian model. Model tersebut memiliki 6 *node* pada *hidden layer* dengan fungsi aktivasi *logistic*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.51 Hasil Percobaan Model 2 periode 10 Nodes Input Stasiun Surabaya Pusat

Hidden	Stepmax/ epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
6	100000	logistic	0.1	28.30%	27.40%
6	200000	logistic	0.1	28.30%	27.40%
6	300000	logistic	0.1	28.30%	27.40%
6	100000	logistic	0.2	28.30%	27.40%
6	200000	logistic	0.2	28.30%	27.40%
6	300000	logistic	0.2	28.30%	27.40%
6	100000	logistic	0.3	28.30%	27.40%
6	200000	logistic	0.3	28.30%	27.40%
6	300000	logistic	0.3	28.30%	27.40%
6	100000	logistic	0.4	28.30%	27.40%
...

B. Model ANN 10 *Nodes Input* SUF 6 (Surabaya Timur)

Pada penelitian tugas akhir ini, memiliki 270 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari

jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 10 nodes pada 2 periode yakni 2 hari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes*, *activation function*, *learning rate*, *stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.52. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 66,50% untuk hasil pelatihan model dan 61,20% untuk hasil pengujian model. Model tersebut memiliki 1 node pada *hidden layer* dengan fungsi aktivasi *tanh*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.52 Hasil Percobaan Model 2 periode 10 Nodes Input Stasiun Surabaya Timur

Hidden	Stepmax/ epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
1	100000	tanh	0.1	66.50%	61.20%
1	200000	tanh	0.1	66.50%	61.20%
1	300000	tanh	0.1	66.50%	61.20%
1	100000	tanh	0.2	66.50%	61.20%
1	200000	tanh	0.2	66.50%	61.20%
1	300000	tanh	0.2	66.50%	61.20%
1	100000	tanh	0.3	66.50%	61.20%
1	200000	tanh	0.3	66.50%	61.20%
1	300000	tanh	0.3	66.50%	61.20%
1	100000	tanh	0.4	66.50%	61.20%
...

C. Model ANN 10 *Nodes Input* SUF 7 (Surabaya Selatan)

Pada penelitian tugas akhir ini, memiliki 324 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 10 nodes pada 1 periode yakni

sepuluh hari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes*, *activation function*, *learning rate*, *stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.53. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 28,30% untuk hasil pelatihan model dan 27,40% untuk hasil pengujian model. Model tersebut memiliki 6 *node* pada *hidden layer* dengan fungsi aktivasi *logistic*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.53 Hasil Percobaan Model 2 periode 10 Nodes Input Stasiun Surabaya Selatan

Hidden	Stepmax/ epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
6	100000	logistic	0.1	28.30%	27.40%
6	200000	logistic	0.1	28.30%	27.40%
6	300000	logistic	0.1	28.30%	27.40%
6	100000	logistic	0.2	28.30%	27.40%
6	200000	logistic	0.2	28.30%	27.40%
6	300000	logistic	0.2	28.30%	27.40%
6	100000	logistic	0.3	28.30%	27.40%
6	200000	logistic	0.3	28.30%	27.40%
6	300000	logistic	0.3	28.30%	27.40%
6	100000	logistic	0.4	28.30%	27.40%
...

6.6.1.3 Model ANN 3 Periode 15 Input Node

Percobaan Model ANN 3 periode merupakan *input data* dari satu periode sebelumnya yang dimulai dari tanggal 1 Januari 2016. Satu periode terdiri dari 15 *input node* dan memiliki target 5 *output node*. Berikut ini adalah percobaan model 3 periode 15 *input node* pada setiap stasiun pemantau udara yang aktif pada tahun 2016.

A. Model ANN 15 *Nodes Input* SUF 1 (Surabaya Pusat)

Pada penelitian tugas akhir ini, memiliki 395 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 15 nodes pada 3 periode yakni 3 hari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes*, *activation function*, *learning rate*, *stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.54. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 29,30% untuk hasil pelatihan model dan 29,50% untuk hasil pengujian model. Model tersebut memiliki 4 *node* pada *hidden layer* dengan fungsi aktivasi *tanh*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.54 Hasil Percobaan Model 3 periode 15 Nodes Input Stasiun Surabaya Pusat

Hidden	Stepmax/ epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
4	100000	tanh	0.1	29.30%	29.50%
4	200000	tanh	0.1	29.30%	29.50%
4	300000	tanh	0.1	29.30%	29.50%
4	100000	tanh	0.2	29.30%	29.50%
4	200000	tanh	0.2	29.30%	29.50%
4	300000	tanh	0.2	29.30%	29.50%
4	100000	tanh	0.3	29.30%	29.50%
4	200000	tanh	0.3	29.30%	29.50%
4	300000	tanh	0.3	29.30%	29.50%
4	100000	tanh	0.4	29.30%	29.50%
...

B. Model ANN 15 *Nodes Input* SUF 6 (Surabaya Timur)

Pada penelitian tugas akhir ini, memiliki 270 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari

jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 15 nodes pada 3 periode yakni 3 hari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes*, *activation function*, *learning rate*, *stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.55. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 32,70% untuk hasil pelatihan model dan 41,70% untuk hasil pengujian model. Model tersebut memiliki 4 node pada *hidden layer* dengan fungsi aktivasi *logistic*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.55 Hasil Percobaan Model 3 periode 15 *Nodes Input* Stasiun Surabaya Timur

Hidden	Stepmax/ epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
4	100000	logistic	0.1	32.70%	41.70%
4	200000	logistic	0.1	32.70%	41.70%
4	300000	logistic	0.1	32.70%	41.70%
4	100000	logistic	0.2	32.70%	41.70%
4	200000	logistic	0.2	32.70%	41.70%
4	300000	logistic	0.2	32.70%	41.70%
4	100000	logistic	0.3	32.70%	41.70%
4	200000	logistic	0.3	32.70%	41.70%
4	300000	logistic	0.3	32.70%	41.70%
4	100000	logistic	0.4	32.70%	41.70%
...

C. Model ANN 15 *Nodes Input* SUF 7 (Surabaya Selatan)

Pada penelitian tugas akhir ini, memiliki 324 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 15 nodes pada 3 periode yakni

tiga hari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes, activation function, learning rate, stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.56. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 27,60% untuk hasil pelatihan model dan 31,30% untuk hasil pengujian model. Model tersebut memiliki 5 *node* pada *hidden layer* dengan fungsi aktivasi *tanh*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.56 Hasil Percobaan Model 3 periode 15 Nodes Input Stasiun Surabaya Selatan

Hidden	Stepmax/ epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
5	100000	tanh	0.1	27.60%	31.30%
5	200000	tanh	0.1	27.60%	31.30%
5	300000	tanh	0.1	27.60%	31.30%
5	100000	tanh	0.2	27.60%	31.30%
5	200000	tanh	0.2	27.60%	31.30%
5	300000	tanh	0.2	27.60%	31.30%
5	100000	tanh	0.3	27.60%	31.30%
5	200000	tanh	0.3	27.60%	31.30%
5	300000	tanh	0.3	27.60%	31.30%
5	100000	tanh	0.4	27.60%	31.30%
...

6.6.1.4 Model ANN 4 Periode 20 Input Node

Percobaan Model ANN 4 periode merupakan *input data* dari satu periode sebelumnya yang dimulai dari tanggal 1 Januari 2016. Satu periode terdiri dari 20 *input node* dan memiliki target 5 *output node*. Berikut ini adalah percobaan model 4 periode 20 *input node* pada setiap stasiun pemantau udara yang aktif pada tahun 2016.

A. Model ANN 20 *Nodes Input* SUF 1 (Surabaya Pusat)

Pada penelitian tugas akhir ini, memiliki 395 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 20 nodes pada 4 periode yakni 4 hari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes*, *activation function*, *learning rate*, *stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.57. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 41,40% untuk hasil pelatihan model dan 34,60% untuk hasil pengujian model. Model tersebut memiliki 1 *node* pada *hidden layer* dengan fungsi aktivasi *logistic*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.57 Hasil Percobaan Model 4 periode 20 *Nodes Input* Stasiun Surabaya Pusat

Hidden	Stepmax / epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
1	100000	logistic	0.1	41.40%	34.60%
1	200000	logistic	0.1	41.40%	34.60%
1	300000	logistic	0.1	41.40%	34.60%
1	100000	logistic	0.2	41.40%	34.60%
1	200000	logistic	0.2	41.40%	34.60%
1	300000	logistic	0.2	41.40%	34.60%
1	100000	logistic	0.3	41.40%	34.60%
1	200000	logistic	0.3	41.40%	34.60%
1	300000	logistic	0.3	41.40%	34.60%
1	100000	logistic	0.4	41.40%	34.60%
...

B. Model ANN 20 *Nodes Input* SUF 6 (Surabaya Timur)

Pada penelitian tugas akhir ini, memiliki 270 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari

jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 20 nodes pada 4 periode yakni 4 hari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes*, *activation function*, *learning rate*, *stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.58. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 67,80% untuk hasil pelatihan model dan 62,50% untuk hasil pengujian model. Model tersebut memiliki 1 node pada *hidden layer* dengan fungsi aktivasi *logistic*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.58 Hasil Percobaan Model 4 periode 20 Nodes Input Stasiun Surabaya Timur

Hidden	Stepmax / epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
1	100000	logistic	0.1	67.80%	62.50%
1	200000	logistic	0.1	67.80%	62.50%
1	300000	logistic	0.1	67.80%	62.50%
1	100000	logistic	0.2	67.80%	62.50%
1	200000	logistic	0.2	67.80%	62.50%
1	300000	logistic	0.2	67.80%	62.50%
1	100000	logistic	0.3	67.80%	62.50%
1	200000	logistic	0.3	67.80%	62.50%
1	300000	logistic	0.3	67.80%	62.50%
1	100000	logistic	0.4	67.80%	62.50%
...

C. Model ANN 20 Nodes Input SUF 7 (Surabaya Selatan)

Pada penelitian tugas akhir ini, memiliki 324 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 20 nodes pada 4 periode yakni tiga hari sebelumnya. Hasil percobaan pada penelitian tugas

akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes*, *activation function*, *learning rate*, *stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.59. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 32% untuk hasil pelatihan model dan 48,40% untuk hasil pengujian model. Model tersebut memiliki 3 *node* pada *hidden layer* dengan fungsi aktivasi *logistic*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.59 Hasil Percobaan Model 4 periode 20 Nodes Input Stasiun Surabaya Selatan

Hidden	Stepmax/ epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
3	100000	logistic	0.1	32%	48.40%
3	200000	logistic	0.1	32%	48.40%
3	300000	logistic	0.1	32%	48.40%
3	100000	logistic	0.2	32%	48.40%
3	200000	logistic	0.2	32%	48.40%
3	300000	logistic	0.2	32%	48.40%
3	100000	logistic	0.3	32%	48.40%
3	200000	logistic	0.3	32%	48.40%
3	300000	logistic	0.3	32%	48.40%
3	100000	logistic	0.4	32%	48.40%
...

6.6.1.5 Model ANN 5 Periode 25 Input Node

Percobaan Model ANN 5 periode merupakan *input data* dari satu periode sebelumnya yang dimulai dari tanggal 1 Januari 2016. Satu periode terdiri dari 25 *input node* dan memiliki target 5 *output node*. Berikut ini adalah percobaan model 4 periode 25 *input node* pada setiap stasiun pemantau udara yang aktif pada tahun 2016

A. Model ANN 25 Nodes Input SUF 1(Surabaya Pusat)

Pada penelitian tugas akhir ini, memiliki 395 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari

jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 25 nodes pada 5 periode yakni 5 hari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes*, *activation function*, *learning rate*, *stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.60. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 26,40% untuk hasil pelatihan model dan 30,40% untuk hasil pengujian model. Model tersebut memiliki 6 *node* pada *hidden layer* dengan fungsi aktivasi *logistic*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.60 Hasil Percobaan Model 5 periode 25 Nodes Input Stasiun Surabaya Pusat

Hidden	Stepmax/ epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
6	100000	logistic	0.1	26.40%	30.40%
6	200000	logistic	0.1	26.40%	30.40%
6	300000	logistic	0.1	26.40%	30.40%
6	100000	logistic	0.2	26.40%	30.40%
6	200000	logistic	0.2	26.40%	30.40%
6	300000	logistic	0.2	26.40%	30.40%
6	100000	logistic	0.3	26.40%	30.40%
6	200000	logistic	0.3	26.40%	30.40%
6	300000	logistic	0.3	26.40%	30.40%
6	100000	logistic	0.4	26.40%	30.40%
...

B. Model ANN 25 *Nodes Input* SUF 6 (Surabaya Timur)

Pada penelitian tugas akhir ini, memiliki 270 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 25 nodes pada 5 periode yakni lima hari sebelumnya. Hasil percobaan pada penelitian tugas

akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes*, *activation function*, *learning rate*, *stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.61. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 67% untuk hasil pelatihan model dan 61,50% untuk hasil pengujian model. Model tersebut memiliki 1 node pada *hidden layer* dengan fungsi aktivasi *tanh*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.61 Hasil Percobaan Model 5 periode 25 Nodes Input Stasiun Surabaya Timur

Hidden	Stepmax/ epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
1	100000	tanh	0.1	67%	61.50%
1	200000	tanh	0.1	67%	61.50%
1	300000	tanh	0.1	67%	61.50%
1	100000	tanh	0.2	67%	61.50%
1	200000	tanh	0.2	67%	61.50%
1	300000	tanh	0.2	67%	61.50%
1	100000	tanh	0.3	67%	61.50%
1	200000	tanh	0.3	67%	61.50%
1	300000	tanh	0.3	67%	61.50%
1	100000	tanh	0.4	67%	61.50%
...

C. Model ANN 25 Nodes Input SUF 7 (Surabaya Selatan)

Pada penelitian tugas akhir ini, memiliki 324 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 25 nodes pada 5 periode yakni lima hari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes*,

activation function, learning rate, stepmax) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.62. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 27% untuk hasil pelatihan model dan 36,10% untuk hasil pengujian model. Model tersebut memiliki 5 *node* pada *hidden layer* dengan fungsi aktivasi *logistic*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.62 Hasil Percobaan Model 5 periode 25 Nodes Input Stasiun Surabaya Selatan

Hidden	Stepmax /epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
5	100000	logistic	0.1	27%	36.10%
5	200000	logistic	0.1	27%	36.10%
5	300000	logistic	0.1	27%	36.10%
5	100000	logistic	0.2	27%	36.10%
5	200000	logistic	0.2	27%	36.10%
5	300000	logistic	0.2	27%	36.10%
5	100000	logistic	0.3	27%	36.10%
5	200000	logistic	0.3	27%	36.10%
5	300000	logistic	0.3	27%	36.10%
5	100000	logistic	0.4	27%	36.10%
...

6.6.1.6 Model ANN 6 Periode 30 Input Node

Percobaan Model ANN 6 merupakan *input data* dari satu periode sebelumnya yang dimulai dari tanggal 1 Januari 2016. Satu periode terdiri dari 30 *input node* dan memiliki target 5 *output node*. Berikut ini adalah percobaan model 6 periode 30 *input node* pada setiap stasiun pemantau udara yang aktif pada tahun 2016.

A. Model ANN 30 Nodes Input SUF 1(Surabaya Pusat)

Pada penelitian tugas akhir ini, memiliki 395 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada

sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 30 nodes pada 6 periode yakni 6 hari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes*, *activation function*, *learning rate*, *stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.63. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 32,20% untuk hasil pelatihan model dan 34,40% untuk hasil pengujian model. Model tersebut memiliki 2 *node* pada *hidden layer* dengan fungsi aktivasi *tanh*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.63 Hasil Percobaan Model 6 periode 30 Nodes Input Stasiun Surabaya Pusat

Hidden	Stepmax / epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
2	100000	tanh	0.1	32.20%	34.40%
2	200000	tanh	0.1	32.20%	34.40%
2	300000	tanh	0.1	32.20%	34.40%
2	100000	tanh	0.2	32.20%	34.40%
2	200000	tanh	0.2	32.20%	34.40%
2	300000	tanh	0.2	32.20%	34.40%
2	100000	tanh	0.3	32.20%	34.40%
2	200000	tanh	0.3	32.20%	34.40%
2	300000	tanh	0.3	32.20%	34.40%
2	100000	tanh	0.4	32.20%	34.40%
...

B. Model ANN 30 Nodes Input SUF 6 (Surabaya Timur)

Pada penelitian tugas akhir ini, memiliki 270 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 30 nodes pada 6 periode yakni enam hari sebelumnya. Hasil percobaan pada penelitian tugas

akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes*, *activation function*, *learning rate*, *stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.64. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 41,80% untuk hasil pelatihan model dan 57% untuk hasil pengujian model. Model tersebut memiliki 3 node pada *hidden layer* dengan fungsi aktivasi *tanh*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.64 Hasil Percobaan Model 6 periode 30 Nodes Input Stasiun Surabaya Timur

Hidden	Stepmax/ epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
3	100000	tanh	0.1	41.80%	57%
3	200000	tanh	0.1	41.80%	57%
3	300000	tanh	0.1	41.80%	57%
3	100000	tanh	0.2	41.80%	57%
3	200000	tanh	0.2	41.80%	57%
3	300000	tanh	0.2	41.80%	57%
3	100000	tanh	0.3	41.80%	57%
3	200000	tanh	0.3	41.80%	57%
3	300000	tanh	0.3	41.80%	57%
3	100000	tanh	0.4	41.80%	57%
...

C. Model ANN 30 Nodes Input SUF 7 (Surabaya Selatan)

Pada penelitian tugas akhir ini, memiliki 324 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 30 nodes pada 6 periode yakni enam hari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes*, *activation function*, *learning rate*, *stepmax*) dari pengolahan

data (*training* dan *testing*) yang ditampilkan pada Tabel 6.65. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 28% untuk hasil pelatihan model dan 35,70% untuk hasil pengujian model. Model tersebut memiliki 4 *node* pada *hidden layer* dengan fungsi aktivasi *logistic*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.65 Hasil Percobaan Model 6 periode 30 Nodes Input Stasiun Surabaya Selatan

Hidden	Stepmax / epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
4	100000	logistic	0.1	28%	35.70%
4	200000	logistic	0.1	28%	35.70%
4	300000	logistic	0.1	28%	35.70%
4	100000	logistic	0.2	28%	35.70%
4	200000	logistic	0.2	28%	35.70%
4	300000	logistic	0.2	28%	35.70%
4	100000	logistic	0.3	28%	35.70%
4	200000	logistic	0.3	28%	35.70%
4	300000	logistic	0.3	28%	35.70%
4	100000	logistic	0.4	28%	35.70%
...

6.6.1.7 Model ANN 7 Periode 35 Input Node

Percobaan Model ANN 7 periode merupakan *input data* dari satu periode sebelumnya yang dimulai dari tanggal 1 Januari 2016. Satu periode terdiri dari 35 *input node* dan memiliki target 5 *output node*. Berikut ini adalah percobaan model 7 periode 35 *input node* pada setiap stasiun pemantau udara yang aktif pada tahun 2016

A. Model ANN 35 Nodes Input SUF 1(Surabaya Pusat)

Pada penelitian tugas akhir ini, memiliki 395 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan

node pada *input layer* berjumlah 35 nodes pada 7 periode yakni 7 hari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes*, *activation function*, *learning rate*, *stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.66. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 32,20% untuk hasil pelatihan model dan 34,40% untuk hasil pengujian model. Model tersebut memiliki 2 *node* pada *hidden layer* dengan fungsi aktivasi *tanh*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.66 Hasil Percobaan Model 7 periode 35 Nodes Input Stasiun Surabaya Pusat

Hidden	Stepmax / epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
2	100000	tanh	0.1	32.20%	34.40%
2	200000	tanh	0.1	32.20%	34.40%
2	300000	tanh	0.1	32.20%	34.40%
2	100000	tanh	0.2	32.20%	34.40%
2	200000	tanh	0.2	32.20%	34.40%
2	300000	tanh	0.2	32.20%	34.40%
2	100000	tanh	0.3	32.20%	34.40%
2	200000	tanh	0.3	32.20%	34.40%
2	300000	tanh	0.3	32.20%	34.40%
2	100000	tanh	0.4	32.20%	34.40%
...

B. Model ANN 35 Nodes Input SUF 6 (Surabaya Timur)

Pada penelitian tugas akhir ini, memiliki 270 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 35 nodes pada 7 periode yakni tujuh hari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan

MAPE serta parameter yang digunakan (*hidden nodes*, *activation function*, *learning rate*, *stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.67. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 43,40% untuk hasil pelatihan model dan 59,20% untuk hasil pengujian model. Model tersebut memiliki 3 node pada *hidden layer* dengan fungsi aktivasi *logistic*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.67 Hasil Percobaan Model 7 periode 35 Nodes Input Stasiun Surabaya Timur

Hidden	Stepmax/ epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
3	100000	logistic	0.1	43.40%	59.20%
3	200000	logistic	0.1	43.40%	59.20%
3	300000	logistic	0.1	43.40%	59.20%
3	100000	logistic	0.2	43.40%	59.20%
3	200000	logistic	0.2	43.40%	59.20%
3	300000	logistic	0.2	43.40%	59.20%
3	100000	logistic	0.3	43.40%	59.20%
3	200000	logistic	0.3	43.40%	59.20%
3	300000	logistic	0.3	43.40%	59.20%
3	100000	logistic	0.4	43.40%	59.20%
...

C. Model ANN 35 Nodes Input SUF 7 (Surabaya Selatan)

Pada penelitian tugas akhir ini, memiliki 324 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 35 nodes pada 7 periode yakni tujuh hari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes*, *activation function*, *learning rate*, *stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.68. Dari proses tersebut dicari nilai MAPE yang paling minimum

yakni diperoleh nilai sebesar 29,90% untuk hasil pelatihan model dan 48,10% untuk hasil pengujian model. Model tersebut memiliki 3 node pada *hidden layer* dengan fungsi aktivasi *logistic*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.68 Hasil Percobaan Model 7 periode 35 Nodes Input Stasiun Surabaya Selatan

Hidden	Stepmax / epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
3	100000	tanh	0.1	29.90%	48.10%
3	100000	logistic	0.1	30.10%	52.70%
3	200000	logistic	0.1	30.10%	52.70%
3	300000	logistic	0.1	30.10%	52.70%
4	100000	logistic	0.1	27.50%	53.30%
4	200000	logistic	0.1	27.50%	53.30%
4	300000	logistic	0.1	27.50%	53.30%
1	100000	logistic	0.1	39.80%	58.10%
1	200000	logistic	0.1	39.80%	58.10%
1	300000	logistic	0.1	39.80%	58.10%
...

6.6.1.8 Model ANN 8 Periode 40 Input Node

Percobaan Model ANN 8 merupakan *input data* dari satu periode sebelumnya yang dimulai dari tanggal 1 Januari 2016. Satu periode terdiri dari 40 *input node* dan memiliki target 5 *output node*. Berikut ini adalah percobaan model 7 periode 40 *input node* pada setiap stasiun pemantau udara yang aktif pada tahun 2016.

A. Model ANN 40 Nodes Input SUF 1(Surabaya Pusat)

Pada penelitian tugas akhir ini, memiliki 395 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 40 nodes pada 8 periode yakni 8 hari sebelumnya. Hasil percobaan pada penelitian tugas akhir

ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes*, *activation function*, *learning rate*, *stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.69. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 40,20% untuk hasil pelatihan model dan 33,90% untuk hasil pengujian model. Model tersebut memiliki 1 *node* pada *hidden layer* dengan fungsi aktivasi *tanh*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.69 Hasil Percobaan Model 8 periode 40 Nodes Input Stasiun Surabaya Pusat

Hidden	Stepmax/ epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
1	100000	tanh	0.1	40.20%	33.90%
1	200000	tanh	0.1	40.20%	33.90%
1	300000	tanh	0.1	40.20%	33.90%
1	100000	tanh	0.2	40.20%	33.90%
1	200000	tanh	0.2	40.20%	33.90%
1	300000	tanh	0.2	40.20%	33.90%
1	100000	tanh	0.3	40.20%	33.90%
1	200000	tanh	0.3	40.20%	33.90%
1	300000	tanh	0.3	40.20%	33.90%
1	100000	tanh	0.4	40.20%	33.90%
...

B. Model ANN 40 Nodes Input SUF 6 (Surabaya Timur)

Pada penelitian tugas akhir ini, memiliki 270 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 40 nodes pada 8 periode yakni sehari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes*, *activation function*, *learning rate*, *stepmax*) dari pengolahan

data (*training* dan *testing*) yang ditampilkan pada Tabel 6.70. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 39,30% untuk hasil pelatihan model dan 55,30% untuk hasil pengujian model. Model tersebut memiliki 3 node pada *hidden layer* dengan fungsi aktivasi *logistic*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.70 Hasil Percobaan Model 8 periode 40 Nodes Input Stasiun Surabaya Timur

Hidden	Stepmax /epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
3	100000	logistic	0.1	39.30%	55.30%
3	200000	logistic	0.1	39.30%	55.30%
3	300000	logistic	0.1	39.30%	55.30%
3	100000	logistic	0.2	39.30%	55.30%
3	200000	logistic	0.2	39.30%	55.30%
3	300000	logistic	0.2	39.30%	55.30%
3	100000	logistic	0.3	39.30%	55.30%
3	200000	logistic	0.3	39.30%	55.30%
3	300000	logistic	0.3	39.30%	55.30%
3	100000	logistic	0.4	39.30%	55.30%
...

C. Model ANN 40 Nodes Input SUF 7 (Surabaya Selatan)

Pada penelitian tugas akhir ini, memiliki 324 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 5 nodes pada 1 periode yakni sehari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes*, *activation function*, *learning rate*, *stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.71. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 28,90% untuk hasil pelatihan

model dan 51,90% untuk hasil pengujian model. Model tersebut memiliki 3 node pada *hidden layer* dengan fungsi aktivasi *tanh*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.71 Hasil Percobaan Model 8 periode 40 Nodes Input Stasiun Surabaya Selatan

Hidden	Stepmax /epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
3	100000	tanh	0.1	28.90%	51.90%
3	200000	tanh	0.1	28.90%	51.90%
3	300000	tanh	0.1	28.90%	51.90%
3	100000	tanh	0.2	28.90%	51.90%
3	200000	tanh	0.2	28.90%	51.90%
3	300000	tanh	0.2	28.90%	51.90%
3	100000	tanh	0.3	28.90%	51.90%
3	200000	tanh	0.3	28.90%	51.90%
3	300000	tanh	0.3	28.90%	51.90%
3	100000	tanh	0.4	28.90%	51.90%
...

6.6.1.9 Model ANN 9 Periode 45 Input Node

Percobaan Model ANN 9 periode merupakan *input data* dari satu periode sebelumnya yang dimulai dari tanggal 1 Januari 2016. Satu periode terdiri dari 45 *input node* dan memiliki target 5 *output node*. Berikut ini adalah percobaan model 9 periode 45 *input node* pada setiap stasiun pemantau udara yang aktif pada tahun 2016.

A. Model ANN 45 Nodes Input SUF 1(Surabaya Pusat)

Pada penelitian tugas akhir ini, memiliki 395 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 45 nodes pada 9 periode yakni 9 hari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes*,

activation function, learning rate, stepmax) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.72. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 32% untuk hasil pelatihan model dan 34% untuk hasil pengujian model. Model tersebut memiliki 2 *node* pada *hidden layer* dengan fungsi aktivasi *logistic*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.72 Hasil Percobaan Model 9 periode 45 Nodes Input Stasiun Surabaya Pusat

Hidden	Stepmax/ epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
2	100000	logistic	0.1	32%	34%
2	200000	logistic	0.1	32%	34%
2	300000	logistic	0.1	32%	34%
1	100000	logistic	0.1	40.30%	34.10%
1	200000	logistic	0.1	40.30%	34.10%
1	300000	logistic	0.1	40.30%	34.10%
1	100000	tanh	0.1	40.40%	34.20%
2	100000	tanh	0.1	31.90%	34.60%
5	100000	logistic	0.1	24.70%	37%
5	200000	logistic	0.1	24.70%	37%
...

B. Model ANN 45 *Nodes Input* SUF 6 (Surabaya Timur)

Pada penelitian tugas akhir ini, memiliki 270 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 45 nodes pada 9 periode yakni sembilan hari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes, activation function, learning rate, stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.73. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 33,50% untuk hasil pelatihan model dan 55,40% untuk hasil pengujian model.

Model tersebut memiliki 5 node pada *hidden layer* dengan fungsi aktivasi *logistic*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.73 Hasil Percobaan Model 9 periode 45 Nodes Input Stasiun Surabaya Timur

Hidden	Stepmax/ epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
5	100000	logistic	0.1	33.50%	55.40%
5	200000	logistic	0.1	33.50%	55.40%
5	300000	logistic	0.1	33.50%	55.40%
5	100000	logistic	0.2	33.50%	55.40%
5	200000	logistic	0.2	33.50%	55.40%
5	300000	logistic	0.2	33.50%	55.40%
5	100000	logistic	0.3	33.50%	55.40%
5	200000	logistic	0.3	33.50%	55.40%
5	300000	logistic	0.3	33.50%	55.40%
5	100000	logistic	0.4	33.50%	55.40%
...

C. Model ANN 45 Nodes Input SUF 7 (Surabaya Selatan)

Pada penelitian tugas akhir ini, memiliki 324 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 45 nodes pada 9 periode yakni sembilan hari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes*, *activation function*, *learning rate*, *stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.74. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 28,20% untuk hasil pelatihan model dan 45,30% untuk hasil pengujian model. Model tersebut memiliki 3 node pada *hidden layer* dengan fungsi aktivasi *logistic*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.74 Hasil Percobaan Model 9 periode 45 Nodes Input Stasiun Surabaya Selatan

Hidden	Stepmax /epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
3	100000	logistic	0.1	28.20%	45.30%
3	200000	logistic	0.1	28.20%	45.30%
3	300000	logistic	0.1	28.20%	45.30%
3	100000	logistic	0.2	28.20%	45.30%
3	200000	logistic	0.2	28.20%	45.30%
3	300000	logistic	0.2	28.20%	45.30%
3	100000	logistic	0.3	28.20%	45.30%
3	200000	logistic	0.3	28.20%	45.30%
3	300000	logistic	0.3	28.20%	45.30%
3	100000	logistic	0.4	28.20%	45.30%
...

6.6.1.10 Model ANN 10 Periode 50 Input Node

Percobaan Model ANN 10 periode merupakan *input data* dari satu periode sebelumnya yang dimulai dari tanggal 1 Januari 2016. Satu periode terdiri dari 50 *input node* dan memiliki target 5 *output node*. Berikut ini adalah percobaan model 10 periode 50 *input node* pada setiap stasiun pemantau udara yang aktif pada tahun 2016.

A. Model ANN 50 Nodes Input SUF 1 (Surabaya Pusat)

Pada penelitian tugas akhir ini, memiliki 395 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 50 nodes pada 10 periode yakni 10 hari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes, activation function, learning rate, stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.75. Berdasarkan proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 40,20%

untuk hasil pelatihan model dan 34% untuk hasil pengujian model. Model tersebut memiliki 1 *node* pada *hidden layer* dengan fungsi aktivasi *logistic*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.75 Hasil Percobaan Model 10 periode 50 Nodes Input Stasiun Surabaya Pusat

Hidden	Stepmax/ epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
1	100000	logistic	0.1	40.20%	34%
1	200000	logistic	0.1	40.20%	34%
1	300000	logistic	0.1	40.20%	34%
1	100000	logistic	0.2	40.20%	34%
1	200000	logistic	0.2	40.20%	34%
1	300000	logistic	0.2	40.20%	34%
1	100000	logistic	0.3	40.20%	34%
1	200000	logistic	0.3	40.20%	34%
1	300000	logistic	0.3	40.20%	34%
1	100000	logistic	0.4	40.20%	34%
...

B. Model ANN 50 Nodes Input SUF 6 (Surabaya Timur)

Pada penelitian tugas akhir ini, memiliki 270 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 50 nodes pada 10 periode yakni sepuluh hari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes*, *activation function*, *learning rate*, *stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.76. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 34,90% untuk hasil pelatihan model dan 58,10% untuk hasil pengujian model. Model tersebut memiliki 4 node pada *hidden layer* dengan

fungsi aktivasi *tanh*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.76 Hasil Percobaan Model 10 periode 50 Nodes Input Stasiun Surabaya Timur

Hidden	Stepmax /epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
4	100000	tanh	0.1	34.90%	58.10%
4	200000	tanh	0.1	34.90%	58.10%
4	300000	tanh	0.1	34.90%	58.10%
4	100000	tanh	0.2	34.90%	58.10%
4	200000	tanh	0.2	34.90%	58.10%
4	300000	tanh	0.2	34.90%	58.10%
4	100000	tanh	0.3	34.90%	58.10%
4	200000	tanh	0.3	34.90%	58.10%
4	300000	tanh	0.3	34.90%	58.10%
4	100000	tanh	0.4	34.90%	58.10%
...

C. Model ANN 50 Nodes Input SUF 7 (Surabaya Selatan)

Pada penelitian tugas akhir ini, memiliki 324 jenis model pada setiap percobaan satu periode yang merupakan kombinasi dari jumlah *hidden nodes* dan parameter yang sudah dijelaskan pada sub bab 4.3.7. Percobaan pertama dilakukan menggunakan node pada *input layer* berjumlah 50 nodes pada 10 periode yakni sepuluh hari sebelumnya. Hasil percobaan pada penelitian tugas akhir ini adalah sebuah tabel yang berisi informasi perhitungan MAPE serta parameter yang digunakan (*hidden nodes, activation function, learning rate, stepmax*) dari pengolahan data (*training* dan *testing*) yang ditampilkan pada Tabel 6.77. Dari proses tersebut dicari nilai MAPE yang paling minimum yakni diperoleh nilai sebesar 32,80% untuk hasil pelatihan model dan 56,80% untuk hasil pengujian model. Model tersebut memiliki 2 node pada *hidden layer* dengan fungsi aktivasi *logistic*. Untuk hasil dari pengolahan data dapat dilihat pada bagian lampiran B.

Tabel 6.77 Hasil Percobaan Model 10 periode 50 Nodes Input Stasiun Surabaya Selatan

Hidden	Stepmax/ epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
...
2	100000	logistic	0.1	32.80%	56.80%
2	200000	logistic	0.1	32.80%	56.80%
2	300000	logistic	0.1	32.80%	56.80%
2	100000	logistic	0.2	32.80%	56.80%
2	200000	logistic	0.2	32.80%	56.80%
2	300000	logistic	0.2	32.80%	56.80%
2	100000	logistic	0.3	32.80%	56.80%
2	200000	logistic	0.3	32.80%	56.80%
2	300000	logistic	0.3	32.80%	56.80%
2	100000	logistic	0.4	32.80%	56.80%
...

6.6.2 Hasil Perbandingan Model

Pada tahap ini dilakukan perbandingan model-model yang telah diujicobakan untuk mencari model terbaik untuk melakukan peramalan polusi udara pada stasiun pemantau udara yang aktif di setiap wilayah bagian Surabaya pada tahun 2016 yakni Surabaya Pusat, Surabaya Timur, Surabaya Selatan.

6.6.2.1 Perbandingan Model Surabaya Pusat

Pada Tabel 6.78 menunjukkan hasil uji performa menggunakan MAPE dari pelatihan model (*MAPE data training*) dan pengujian model (*MAPE data testing*) pada data polusi udara stasiun pemantau udara wilayah Surabaya Pusat. Model yang cukup baik berdasarkan Tabel 6.78 yang dilihat dari MAPE percobaan data *testing* adalah model dengan 1 periode yakni 5 *nodes input*. Sedangkan parameter yang tepat dari model 5 *nodes input* salah satunya adalah dengan 6 *nodes hidden*, fungsi aktivasi *logistic*, *learning rate* 0,1 dan *stepmax* 100000 seperti ditunjukkan Tabel 6.54.

Tabel 6.78 Perbandingan MAPE *training* dan *testing* untuk Model Stasiun Pemantau Wilayah Surabaya Pusat

Model	Minimum nilai MAPE <i>Training</i>	Minimum nilai MAPE <i>Testing</i>
Model 5 <i>nodes input</i>	29.70%	24.60%
Model 10 <i>nodes input</i>	28.30%	27.40%
Model 15 <i>nodes input</i>	29.30%	29.50%
Model 20 <i>nodes input</i>	41.40%	34.60%
Model 25 <i>nodes input</i>	26.40%	30.40%
Model 30 <i>nodes input</i>	32.20%	34.40%
Model 35 <i>nodes input</i>	32.20%	34.40%
Model 40 <i>nodes input</i>	40.20%	33.90%
Model 45 <i>nodes input</i>	32%	34%
Model 50 <i>nodes input</i>	40.20%	34%

Model 1 periode hari sebelumnya yakni 5 *nodes input* merupakan model terbaik dibandingkan dengan model lain karena memiliki nilai MAPE pada pengujian model yang terkecil dan masuk kategori cukup.

Percobaan untuk mencari model ANN wilayah Surabaya Pusat telah dilakukan dengan menggunakan perpaduan *input node* setiap kelipatan 5 *nodes* di setiap periode dan *hidden node* antara 1 sampai dengan 6 *nodes*. Begitu pula percobaan dilakukan dengan perpaduan parameter di antaranya *learning rate* antara 0.1 sampai dengan 0.9, *transfer function* yakni logistic & tanh, serta jumlah *epoch/ stepmax* antara 100000, 200000, dan 300000.

Uji coba sebanyak 396 kali dari *trial & error* parameter di setiap periode hari dengan *input nodes* berbeda yang telah dilakukan menunjukkan bahwa semakin banyak jumlah *epoch* (iterasi) dan semakin besar nilai *learning rate* (lr) serta jumlah *hidden node* yang digunakan belum tentu dapat menghasilkan nilai MAPE yang lebih kecil. Model ANN yang telah dicoba dari percobaan 1 periode hingga 10 periode menunjukkan bahwa semakin banyak periode, maka nilai MAPE semakin besar. Kemudian penggunaan jumlah *hidden node* yang lebih dari 6 *nodes* menunjukkan hasil yang konvergen sehingga proses

training dihentikan sebelum mencapai percobaan *hidden nodes* keenam.

Uji coba pembentukan model menghasilkan nilai performa model yang cukup karena beberapa kelemahan dari *tools* analitik dimana tidak adanya fungsi *training function*. Sedangkan *training function* sendiri sangat berguna untuk menyesuaikan bentuk data ketika dalam *training*.

6.6.2.2 Perbandingan Model Surabaya Timur

Pada Tabel 6.79 menunjukkan hasil uji performa menggunakan MAPE dari pelatihan model (*MAPE data training*) dan pengujian model (*MAPE data testing*) pada data polusi udara stasiun pemantau udara wilayah Surabaya Pusat. Model yang cukup berdasarkan Tabel 6.79 yang dilihat dari MAPE terkecil percobaan data *testing* adalah model dengan 1 periode yakni 5 *nodes input*. Sedangkan parameter yang tepat dari model 5 *nodes input* salah satunya adalah dengan 4 *nodes hidden*, fungsi aktivasi *tanh*, *learning rate* 0,1 dan *stepmax* 100000 seperti ditunjukkan Tabel 6.55.

Tabel 6.79 Perbandingan MAPE *training* dan *testing* untuk Model Stasiun Pemantau Wilayah Surabaya Timur

Model	Minimum nilai MAPE <i>Training</i>	Minimum nilai MAPE <i>Testing</i>
Model 5 <i>nodes input</i>	33.90%	34.20%
Model 10 <i>nodes input</i>	66.50%	61.20%
Model 15 <i>nodes input</i>	32.70%	41.70%
Model 20 <i>nodes input</i>	67.80%	62.50%
Model 25 <i>nodes input</i>	67%	61.50%
Model 30 <i>nodes input</i>	41.80%	57%
Model 35 <i>nodes input</i>	43.40%	59.20%
Model 40 <i>nodes input</i>	39.30%	55.30%
Model 45 <i>nodes input</i>	33.50%	55.40%
Model 50 <i>nodes input</i>	34.90%	58.10%

Percobaan untuk mencari model ANN wilayah Surabaya Timur telah dilakukan dengan menggunakan perpaduan *input node* setiap kelipatan 5 *nodes* di setiap periode dan *hidden node*

antara 1 sampai dengan 5 *nodes*. Begitu pula percobaan dilakukan dengan perpaduan parameter di antaranya *learning rate* antara 0.1 sampai dengan 0.9, *transfer function* yakni logistic & tanh, serta jumlah *epoch/ stepmax* antara 100000, 200000, dan 300000.

Uji coba sebanyak 270 kali dari *trial & error* parameter di setiap periode hari dengan *input nodes* berbeda yang telah dilakukan menunjukkan bahwa semakin banyak jumlah *epoch* (iterasi) dan semakin besar nilai *learning rate* (lr) serta jumlah *hidden node* yang digunakan belum tentu dapat menghasilkan nilai MAPE yang lebih kecil. Model ANN yang telah dicoba dari percobaan 1 periode hingga 10 periode menunjukkan bahwa semakin banyak periode, maka nilai MAPE semakin besar. Kemudian penggunaan jumlah *hidden node* yang lebih dari 5 *nodes* menunjukkan hasil yang konvergen sehingga proses *training* diberhentikan sebelum mencapai percobaan *hidden nodes* keenam.

Uji coba pembentukan model menghasilkan nilai performa model yang cukup karena beberapa kelemahan dari *tools* analitik dimana tidak adanya fungsi *training function*. Sedangkan *training function* sendiri sangat berguna untuk menyesuaikan bentuk data ketika dalam *training*.

6.6.2.3 Perbandingan Model Surabaya Selatan

Pada Tabel 6.80 menunjukkan hasil uji performa menggunakan MAPE dari pelatihan model (*MAPE data training*) dan pengujian model (*MAPE data testing*) pada data polusi udara stasiun pemantau udara wilayah Surabaya Pusat. Model yang cukup baik berdasarkan Tabel 6.80 yang dilihat dari MAPE percobaan data *testing* adalah model dengan 1 periode yakni 5 *nodes input*. Sedangkan parameter yang tepat dari model 5 *nodes input* salah satunya adalah dengan 6 *nodes hidden*, fungsi aktivasi *logistic*, *learning rate* 0,1 dan *stepmax* 100000 seperti ditunjukkan Tabel 6.59.

Tabel 6.80 Perbandingan MAPE *training* dan *testing* untuk Model Stasiun Pemantau Wilayah Surabaya Selatan

Model	Minimum nilai MAPE <i>Training</i>	Minimum nilai MAPE <i>Testing</i>
Model 5 <i>nodes input</i>	30.40%	34%
Model 10 <i>nodes input</i>	28.30%	27.40%
Model 15 <i>nodes input</i>	27.60%	31.30%
Model 20 <i>nodes input</i>	32%	48.40%
Model 25 <i>nodes input</i>	27%	36.10%
Model 30 <i>nodes input</i>	28%	35.70%
Model 35 <i>nodes input</i>	32.20%	34.40%
Model 40 <i>nodes input</i>	28.90%	51.90%
Model 45 <i>nodes input</i>	28.20%	45.30%
Model 50 <i>nodes input</i>	32.80%	56.80%

Percobaan untuk mencari model ANN wilayah Surabaya Selatan telah dilakukan dengan menggunakan perpaduan *input node* setiap kelipatan 5 *nodes* di setiap periode dan *hidden node* antara 1 sampai dengan 5 *nodes*. Begitu pula percobaan dilakukan dengan perpaduan parameter di antaranya *learning rate* antara 0.1 sampai dengan 0.9, *transfer function* yakni logistic & tanh, serta jumlah *epoch/ stepmax* antara 100000, 200000, dan 300000.

Uji coba sebanyak 324 kali dari *trial & error* parameter di setiap periode hari dengan *input nodes* berbeda yang telah dilakukan menunjukkan bahwa semakin banyak jumlah *epoch* (iterasi) dan semakin besar nilai *learning rate* (*lr*) serta jumlah *hidden node* yang digunakan belum tentu dapat menghasilkan nilai MAPE yang lebih kecil. Model ANN yang telah dicoba dari percobaan 1 periode hingga 10 periode menunjukkan bahwa semakin banyak periode, maka nilai MAPE semakin besar. Kemudian penggunaan jumlah *hidden node* yang lebih dari 6 *nodes* menunjukkan hasil yang konvergen sehingga proses *training* diberhentikan sebelum mencapai percobaan *hidden nodes* keenam.

Uji coba pembentukan model menghasilkan nilai performa model yang cukup karena beberapa kelemahan dari *tools*

analitik dimana tidak adanya fungsi *training function*. Sedangkan *training function* sendiri sangat berguna untuk menyesuaikan bentuk data ketika dalam *training*.

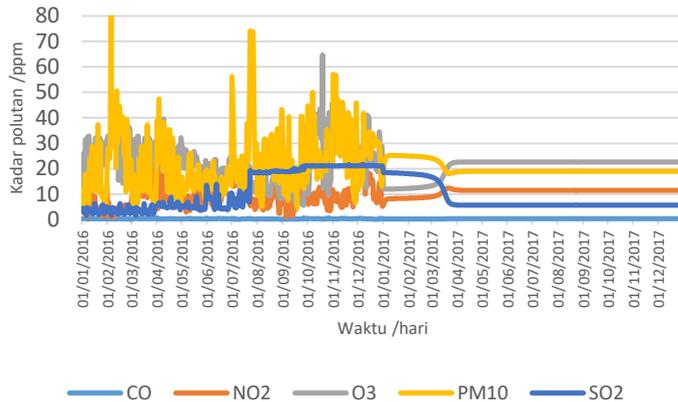
6.6.3 Hasil Peramalan dari Penerapan Model

Pada tahap analisis hasil peramalan dari penerapan model adalah melakukan penerapan model yang telah dipilih dianggap cukup baik untuk meramalkan kondisi kualitas udara ke depan, yakni kadar polutan dari lima unsur polutan udara. Peramalan dilakukan pada tiga stasiun pemantau udara aktif yang masing-masing telah ditentukan model terbaiknya yakni stasiun udara wilayah Surabaya Pusat, wilayah Surabaya Timur dan wilayah Surabaya Selatan.

6.6.3.1 Hasil Peramalan Stasiun Udara Wilayah Surabaya Pusat

Pada Gambar 6.1 menunjukkan hasil peramalan 5 unsur polutan udara di stasiun pemantau udara wilayah Surabaya Pusat. Dapat dilihat bahwa unsur polutan udara karbon monoksida, nitrogen dioksida dan ozon mengalami kenaikan secara perlahan mulai dari Januari 2017 hingga bulan Maret 2017. Sedangkan partikulat matter atau debu dan sulfur dioksida cenderung menurun sejak Januari 2017 hingga Bulan Maret 2017. Kemudian sejak Bulan April 2017 kadar 5 unsur polutan cenderung stationer.

Hasil Peramalan Unsur Polutan Udara Wilayah Surabaya Pusat Sampai dengan Desember 2017



Gambar 6.1 Hasil Peramalan 5 Unsur Polutan Udara Wilayah Surabaya Pusat

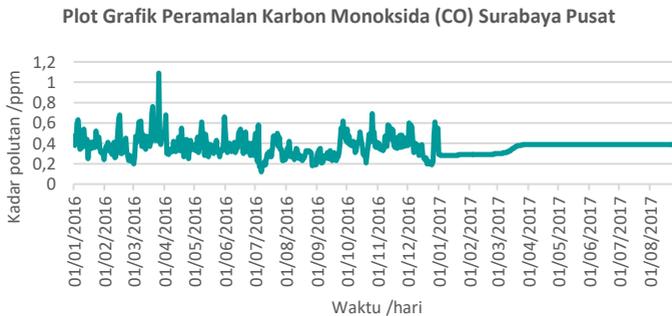
Tabel 6.81 menunjukkan hasil peramalan unsur polutan di Wilayah Surabaya Pusat yang menunjukkan sekilas adanya penurunan kadar polutan pada unsur karbon monoksida dan ozon. Lalu unsur polutan lain cenderung naik seperti nitrogen dioksida, partikulat matter dan sulfur dioksida.

Tabel 6.81 Ringkasan Hasil Peramalan Unsur Polutan Wilayah Surabaya Pusat

Tanggal	CO	NO ₂	O ₃	PM ₁₀	SO ₂
01/01/2017	0.29	5.87	12.17	19.73	18.5
02/01/2017	0.29	6.87	12.1	22.2	18.5
03/01/2017	0.28	7.47	12.05	23.59	18.5
04/01/2017	0.28	7.81	12.03	24.36	18.5
05/01/2017	0.28	8.01	12.01	24.78	18.49
06/01/2017	0.28	8.12	12.01	25.01	18.48
07/01/2017	0.28	8.19	12.01	25.13	18.47
08/01/2017	0.28	8.23	12.02	25.19	18.46
09/01/2017	0.28	8.25	12.03	25.21	18.44
10/01/2017	0.28	8.27	12.04	25.23	18.43
...
30/06/2017	0.39	11.54	22.68	18.93	5.72
01/07/2017	0.39	11.54	22.68	18.93	5.72

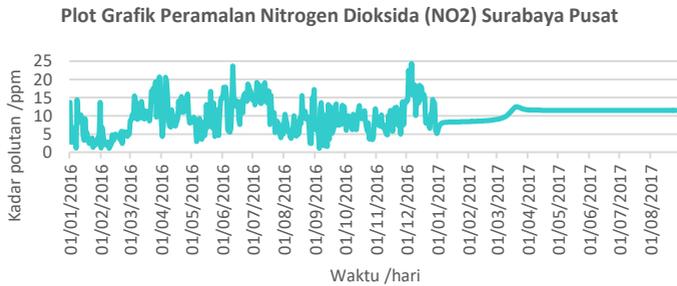
02/07/2017	0.39	11.54	22.68	18.93	5.72
03/07/2017	0.39	11.54	22.68	18.93	5.72
04/07/2017	0.39	11.54	22.68	18.93	5.72
05/07/2017	0.39	11.54	22.68	18.93	5.72
...

Pada Gambar 6.2 menunjukkan plot grafik hasil peramalan unsur polutan Karbon Monoksida di wilayah Surabaya Pusat yang cenderung konstan pada Bulan Januari hingga Bulan Februari 2017. Kemudian mulai mengalami kenaikan pada Bulan Maret hingga April 2017.



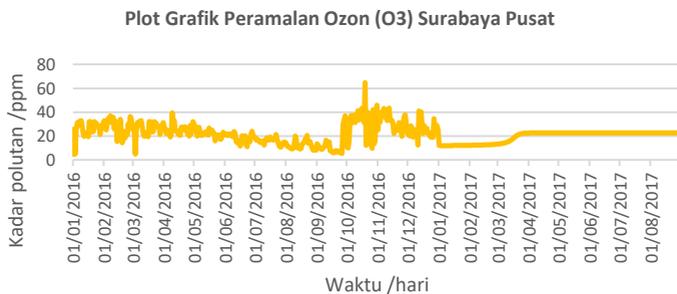
Gambar 6.2 Plot grafik peramalan unsur polutan Karbon Monoksida wilayah Surabaya Pusat

Pada Gambar 6.3 menunjukkan plot grafik hasil peramalan unsur polutan Nitrogen Dioksida di wilayah Surabaya Pusat yang cenderung mengalami kenaikan mulai dari Januari 2017 hingga Bulan Maret 2017. Kemudian pada akhir Bulan Maret 2017 sedikit mengalami penurunan.



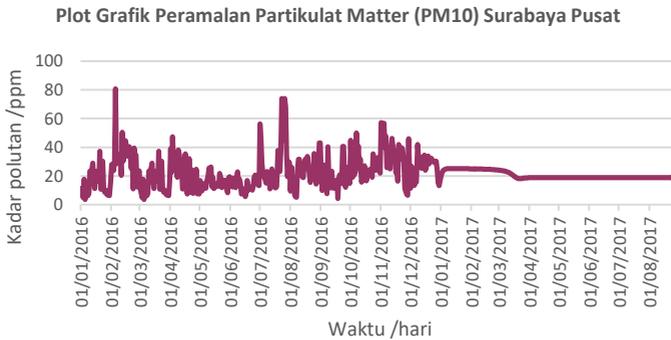
Gambar 6.3 Plot grafik peramalan unsur polutan Nitrogen Dioksida wilayah Surabaya Pusat

Pada Gambar 6.4 menunjukkan plot grafik hasil peramalan unsur polutan Ozon di wilayah Surabaya Pusat yang cenderung stabil pada awal Bulan Januari 2017 hingga awal Maret 2017. Kemudian pada Bulan Maret 2017 mulai mengalami kenaikan hingga Bulan awal April 2017



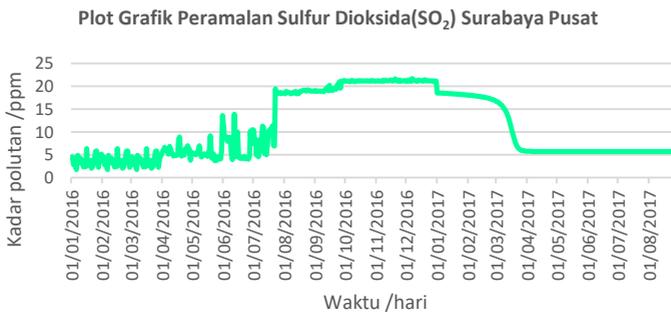
Gambar 6.4 Plot grafik peramalan unsur polutan Ozon wilayah Surabaya Pusat

Pada Gambar 6.5 menunjukkan plot grafik hasil peramalan unsur polutan Partikulat Matter di wilayah Surabaya Pusat yang cenderung stabil pada awal Bulan Januari 2017 hingga awal Maret 2017. Kemudian pada Bulan akhir Maret 2017 mulai mengalami penurunan hingga Bulan awal April 2017.



Gambar 6.5 Plot grafik peramalan unsur polutan Partikulat Matter wilayah Surabaya Pusat

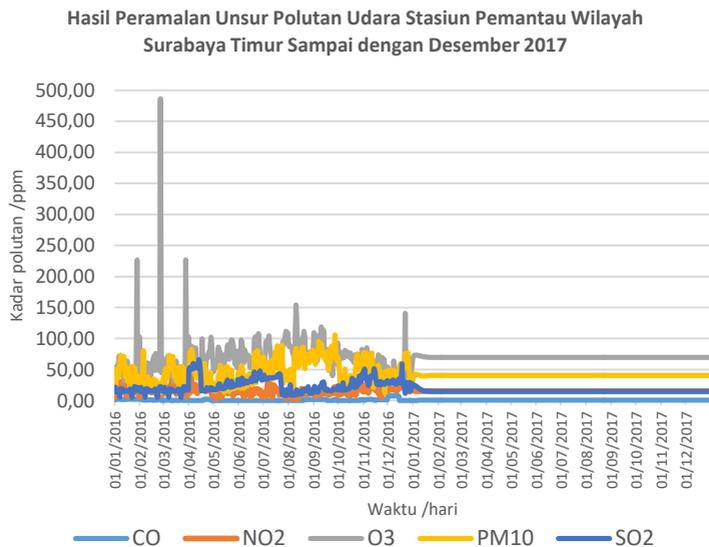
Pada Gambar 6.6 menunjukkan plot grafik hasil peramalan unsur polutan Sulfur Dioksida di wilayah Surabaya Pusat yang cenderung mengalami penurunan secara perlahan pada akhir Februari 2017. Kemudian pada awal Bulan Maret 2017 mulai mengalami penurunan yang signifikan hingga awal Bulan April 2017.



Gambar 6.6 Plot grafik peramalan unsur polutan Sulfur Dioksida wilayah Surabaya Pusat

6.6.3.2 Hasil Peramalan Stasiun Udara Wilayah Surabaya Timur

Pada Gambar 6.7 menunjukkan hasil peramalan 5 unsur polutan udara di stasiun pemantau udara wilayah Surabaya Pusat. Dapat dilihat bahwa unsur polutan udara karbon monoksida, mengalami kenaikan secara perlahan mulai dari Januari 2017 hingga bulan Maret 2017. Unsur nitrogen dioksida, ozon, dan Sulfur Dioksida cenderung menurun sedikit dan kemudian relatif stationer sejak akhir Bulan Januari 2017. Unsur polutan Partikulat Matter di wilayah Surabaya Timur yang cenderung mengalami kenaikan secara perlahan pada awal Bulan Januari 2017 hingga 6 Januari 2017 dan mengalami sedikit penurunan hingga 18 Januari 2017 dimana selanjutnya kadar polutan menjadi relatif stabil.



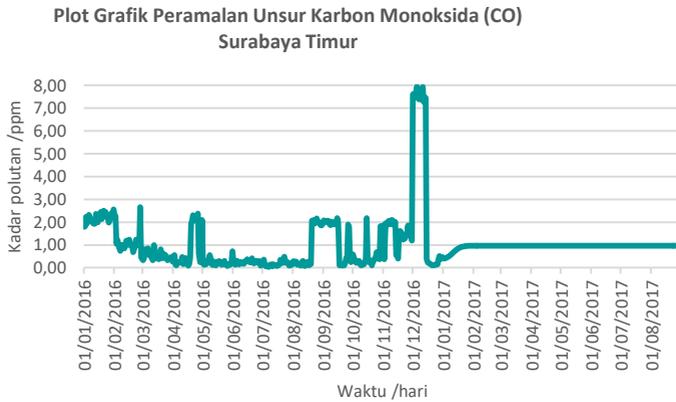
Gambar 6.7 Hasil Peramalan 5 Unsur Polutan Udara Wilayah Surabaya Timur

Tabel 6.82 menunjukkan hasil peramalan unsur polutan di Wilayah Surabaya Timur yang menunjukkan sekilas adanya penurunan kadar polutan pada unsur Nitrogen Dioksida dan Sulfur Dioksida. Lalu unsur polutan Karbon Monoksida cenderung naik. Sedangkan Ozon dan Partikulat Matter cenderung naik pada awalnya dan kemudian turun.

Tabel 6.82 Ringkasan Hasil Peramalan Unsur Polutan Wilayah Surabaya Timur

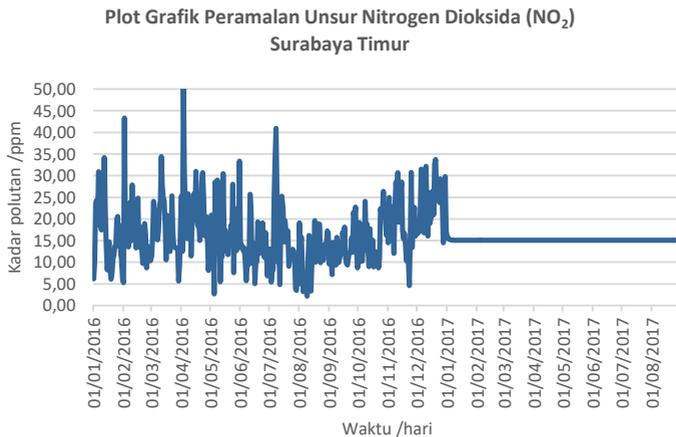
Tanggal	CO	NO ₂	O ₃	PM ₁₀	SO ₂
01/01/2017	0.42	16.11	70.59	38.59	25.29
02/01/2017	0.40	15.59	72.56	41.66	25.08
03/01/2017	0.41	15.34	73.30	42.68	24.37
04/01/2017	0.43	15.22	73.48	42.77	23.44
05/01/2017	0.45	15.16	73.37	42.45	22.43
06/01/2017	0.48	15.12	73.14	41.99	21.41
07/01/2017	0.52	15.11	72.84	41.49	20.43
08/01/2017	0.55	15.09	72.52	41.02	19.50
09/01/2017	0.59	15.09	72.18	40.60	18.65
10/01/2017	0.63	15.08	71.85	40.27	17.89
...
30/06/2017	0.97	15.05	69.59	40.69	14.97
01/07/2017	0.97	15.05	69.59	40.69	14.97
02/07/2017	0.97	15.05	69.59	40.69	14.97
03/07/2017	0.97	15.05	69.59	40.69	14.97
04/07/2017	0.97	15.05	69.59	40.69	14.97
05/07/2017	0.97	15.05	69.59	40.69	14.97
...

Pada Gambar 6.8 menunjukkan plot grafik hasil peramalan unsur polutan Karbon Monoksida di wilayah Surabaya Timur yang cenderung mengalami kenaikan pada awal Bulan Januari hingga awal Bulan Februari 2017. Kemudian mulai mengalami kadar polutan yang stabil pada Bulan Februari 2017.



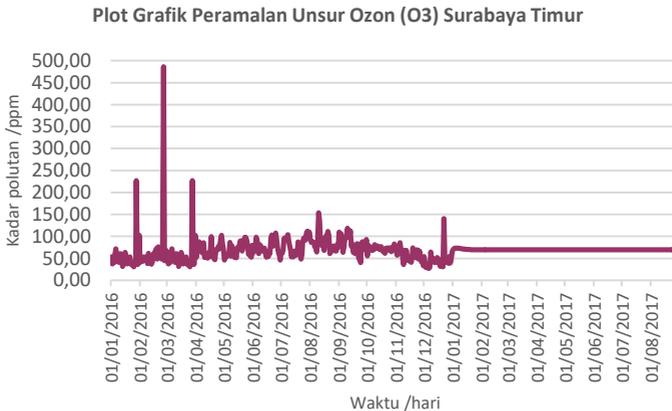
Gambar 6.8 Plot grafik peramalan unsur polutan Karbon Monoksida wilayah Surabaya Timur

Pada Gambar 6.9 menunjukkan plot grafik hasil peramalan unsur polutan Nitrogen Dioksida di wilayah Surabaya Timur yang cenderung mengalami penurunan mulai dari awal Januari 2017 dan kemudian cenderung konstan.



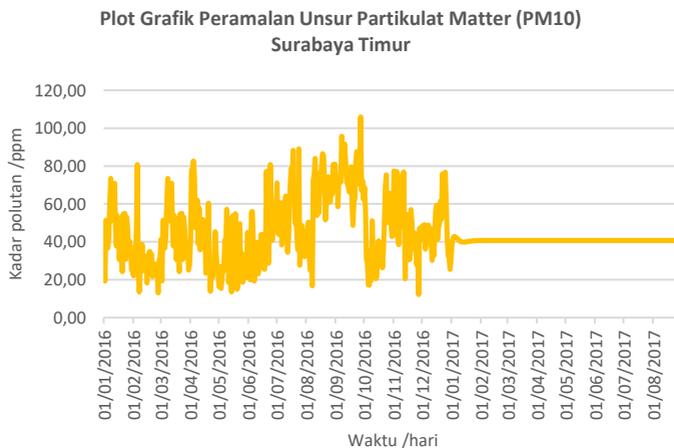
Gambar 6.9 Plot grafik peramalan unsur polutan Nitrogen Dioksida wilayah Surabaya Timur

Pada Gambar 6.10 menunjukkan plot grafik hasil peramalan unsur polutan ozon di wilayah Surabaya Timur yang cenderung naik pada awal Bulan Januari 2017, lalu mengalami sedikit penurunan dan selanjutnya terlihat lebih konstan.



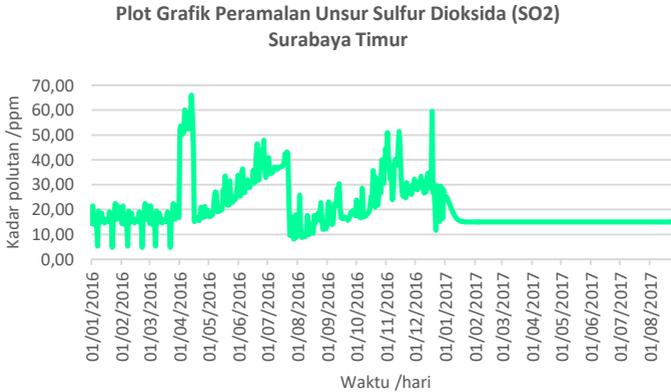
Gambar 6.10 Plot grafik peramalan unsur polutan Ozon wilayah Surabaya Timur

Pada Gambar 6.11 menunjukkan plot grafik hasil peramalan unsur polutan Partikulat Matter di wilayah Surabaya Timur yang cenderung mengalami kenaikan secara perlahan pada awal Bulan Januari 2017 hingga 6 Januari 2017. Kemudian mengalami sedikit penurunan hingga 18 Januari 2017 dan selanjutnya kadar polutan menjadi relatif stabil.



Gambar 6.11 Plot grafik peramalan unsur polutan Partikulat Matter wilayah Surabaya Timur

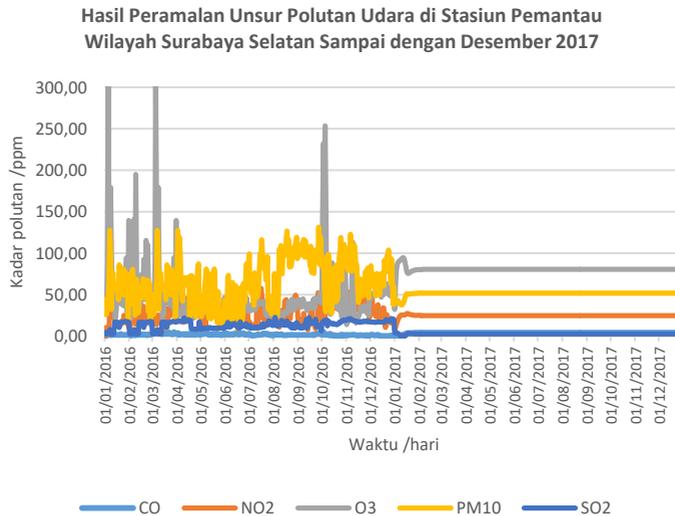
Pada Gambar 6.12 menunjukkan plot grafik hasil peramalan unsur polutan Sulfur Dioksida di wilayah Surabaya Timur yang cenderung mengalami penurunan secara perlahan pada awal Januari 2017 hingga pertengahan Januari 2017. Kemudian kadar polutan cenderung stabil.



Gambar 6.12 Plot grafik peramalan unsur polutan Sulfur Dioksida wilayah Surabaya Timur

6.6.3.3 Hasil Peramalan Stasiun Udara Wilayah Surabaya Selatan

Pada Gambar 6.13 menunjukkan hasil peramalan 5 unsur polutan udara di stasiun pemantau udara wilayah Surabaya Selatan. Dapat dilihat bahwa unsur polutan udara Karbon monoksida, nitrogen dioksida, ozon dan partikulat matter cenderung naik pada awal bulan Januari 2017 dan kemudian sedikit menurun lalu pola data relatif stationer. Sedangkan sulfur dioksida cenderung menurun pada awal bulan Januari 2017 dan pada akhir bulan naik secara perlahan hingga bulan Februari 2017 pola data relatif stationer.



Gambar 6.13 Hasil Peramalan 5 Unsur Polutan Udara Wilayah Surabaya Selatan

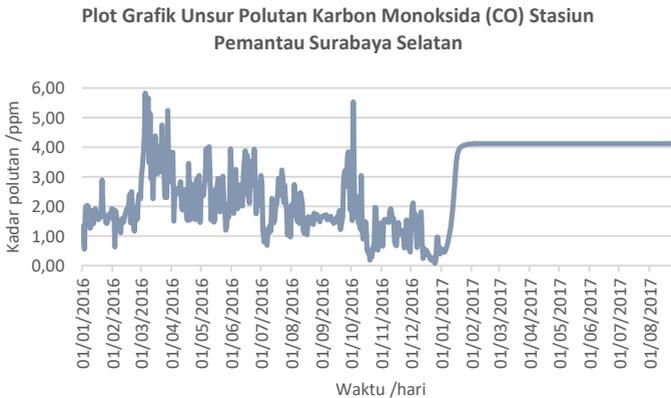
Tabel 6.83 menunjukkan hasil peramalan unsur polutan di Wilayah Surabaya Selatan yang menunjukkan sekilas adanya kenaikan kadar polutan pada unsur Nitrogen Dioksida dan Ozon. Lalu unsur polutan lainnya cenderung naik turun.

Tabel 6.83 Ringkasan Hasil Peramalan Unsur Polutan Wilayah Surabaya Selatan

Tanggal	CO	NO ₂	O ₃	PM ₁₀	SO ₂
01/01/2017	0.55	7.27	32.18	39.06	4.27
02/01/2017	0.51	11.04	62.34	42.29	4.36
03/01/2017	0.45	14.16	78.60	43.17	4.25
04/01/2017	0.46	17.11	86.01	43.55	3.88
05/01/2017	0.53	19.77	88.87	43.02	3.31
06/01/2017	0.61	22.01	89.93	41.51	2.59
07/01/2017	0.73	23.75	90.60	39.69	1.77
08/01/2017	0.87	24.94	91.46	38.22	0.94
09/01/2017	1.06	25.59	92.63	37.52	0.18
10/01/2017	1.29	25.78	93.87	37.73	0.44
...
30/06/2017	4.12	24.95	80.56	51.90	2.66

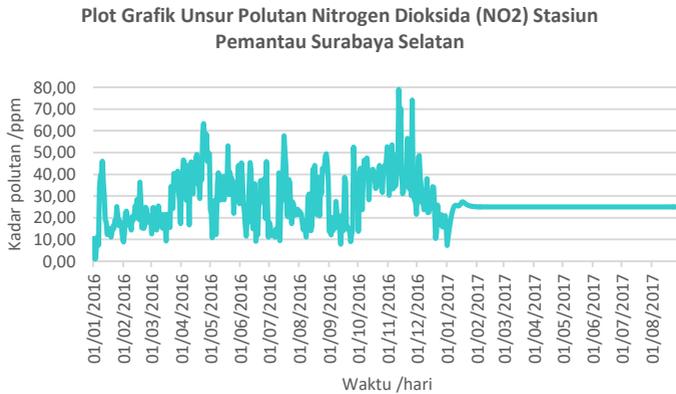
Tanggal	CO	NO ₂	O ₃	PM ₁₀	SO ₂
01/07/2017	4.12	24.95	80.56	51.90	2.66
02/07/2017	4.12	24.95	80.56	51.90	2.66
03/07/2017	4.12	24.95	80.56	51.90	2.66
04/07/2017	4.12	24.95	80.56	51.90	2.66
05/07/2017	4.12	24.95	80.56	51.90	2.66
...

Pada Gambar 6.14 menunjukkan plot grafik hasil peramalan unsur polutan Karbon Monoksida di wilayah Surabaya Selatan yang cenderung mengalami kenaikan secara signifikan pada awal Bulan Januari hingga awal Bulan Februari 2017. Kemudian mulai mengalami kadar polutan yang stabil pada Bulan Februari 2017.



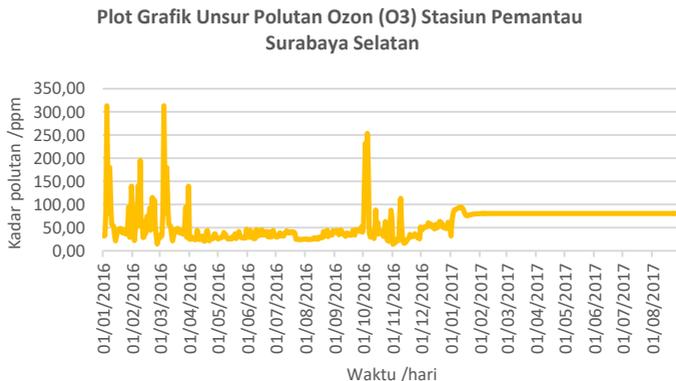
Gambar 6.14 Plot grafik peramalan unsur polutan Karbon Monoksida wilayah Surabaya Timur

Pada Gambar 6.15 menunjukkan plot grafik hasil peramalan unsur polutan Nitrogen Dioksida di wilayah Surabaya Selatan yang cenderung mengalami penurunan mulai dari awal Januari 2017 dan kemudian selanjutnya relatif lebih konstan.



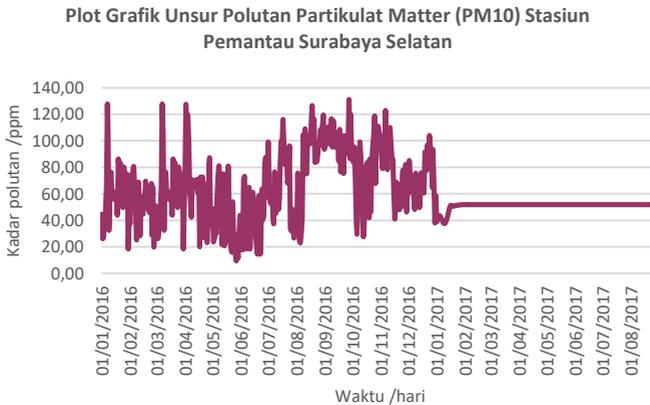
Gambar 6.15 Plot grafik peramalan unsur polutan Nitrogen Dioksida wilayah Surabaya Selatan

Pada Gambar 6.16 menunjukkan plot grafik hasil peramalan unsur polutan ozon di wilayah Surabaya Selatan yang cenderung naik pada awal Bulan Januari 2017, lalu mengalami sedikit penurunan dan selanjutnya terlihat lebih konstan.



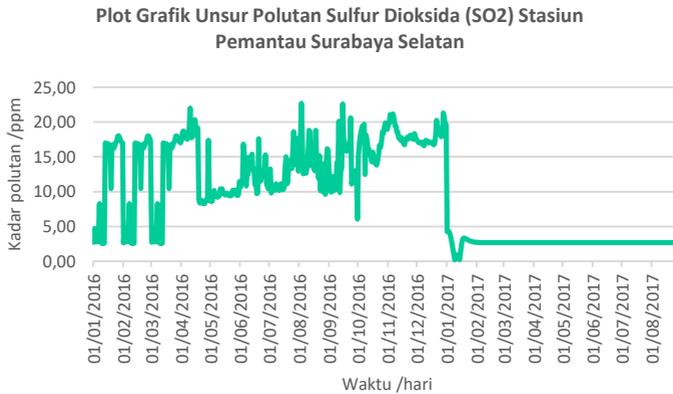
Gambar 6.16 Plot grafik peramalan unsur polutan Ozon wilayah Surabaya Selatan

Pada Gambar 6.17 menunjukkan plot grafik hasil peramalan unsur polutan Partikulat Matter di wilayah Surabaya Timur yang cenderung mengalami penurunan secara perlahan pada awal Bulan Januari 2017, namun kemudian pertengahan Januari mulai mengalami kenaikan. Selanjutnya kadar polutan cenderung lebih stabil.



Gambar 6.17 Plot grafik peramalan unsur polutan Partikulat Matter wilayah Surabaya Selatan

Pada Gambar 6.18 menunjukkan plot grafik hasil peramalan unsur polutan Sulfur Dioksida di wilayah Surabaya Selatan yang cenderung menurun secara signifikan pada awal Bulan Januari 2017 dan kemudian meningkat pada pertengahan Bulan Januari 2017.



Gambar 6.18 Plot grafik peramalan unsur polutan Sulfur Dioksida wilayah Surabaya Selatan

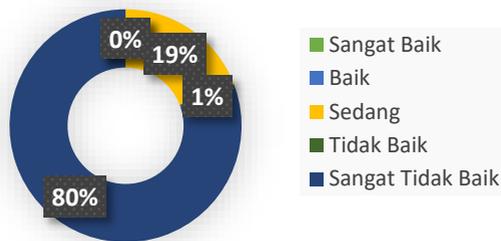
6.7 Klasifikasi Hasil Peramalan

Pada sub bab analisis klasifikasi dari hasil peramalan merupakan tahap analisis hasil dari penerapan model klasifikasi pada data hasil peramalan. Hasil analisis ini bertujuan mengetahui kedepannya pada setiap wilayah bagian Surabaya memiliki status polusi seperti apa.

Penerapan model klasifikasi dilakukan pada setiap unsur polutan di setiap bagian Wilayah Surabaya. Kemudian kesimpulan status polusi harian di setiap bagian wilayah Surabaya merupakan kesimpulan dari kelima status kategori polutan harian pada masing-masing wilayah Surabaya. Jika salah satu unsur polutan dari kelima polutan udara memiliki kategori polutan “sangat tidak baik”, maka kesimpulan status polusi pada hari tersebut adalah “sangat tidak baik”. Begitu pula jika salah satu unsur polutan udara memiliki kategori polutan “tidak baik”, maka kesimpulan status polusi udara pada hari itu adalah “tidak baik”. Dapat dikatakan jika semakin buruk kategori status polusi udara, maka kesimpulan status polusi

Pada Gambar 6.19 menunjukkan persentase perbandingan status polusi pada Wilayah Surabaya Pusat berdasarkan klasifikasi Hasil Peramalan. Status polusi udara wilayah Surabaya Pusat menunjukkan bahwa 80% status polusi udara sangat tidak baik, 1% status polusi udara tidak baik, dan 19% status polusi udara sedang.

Persentase Status Polusi Hasil Peramalan Surabaya Pusat



Gambar 6.19 Persentase Status Polusi Hasil Peramalan Wilayah Surabaya Pusat

6.7.2 Klasifikasi Hasil Peramalan Wilayah Surabaya Timur

Pada Tabel 6.85 menunjukkan bahwa hasil peramalan pada setiap unsur polutan udara seperti CO, NO₂, O₃, PM₁₀, SO₂ yang masing-masing telah terprediksi masuk ke dalam kelas kategori status polusi seperti apa.

Status polusi udara harian yang merupakan kesimpulan status polusi udara ditarik dari hasil kategori status polusi pada masing-masing lima unsur polutan udara. Indeks Pencemar Udara yang dilaporkan ke media massa (display, koran harian setempat /televsion stasiun setempat) adalah Indeks Standar Pencemar Udara yang paling tinggi [29]. Apabila ada salah satu saja unsur polutan udara yang masuk ke dalam kelas kategori status polusi yang buruk, maka kesimpulan status polusi udara harian adalah dengan kondisi kategori status polusi dari kelima unsur polutan udara yang paling buruk. Apabila diurutkan

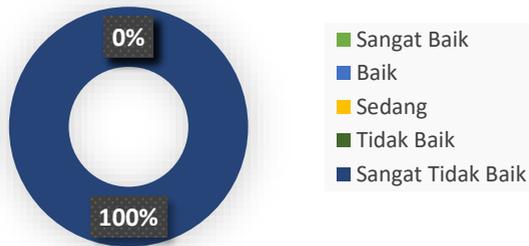
kategori status polusi udara berdasarkan rentang dari yang terburuk sampai dengan yang terbaik adalah “sangat tidak baik”, “tidak baik”, “sedang”, “baik”, dan “sangat baik”. Sehingga penarikan kesimpulan status polusi udara adalah ditarik dari kategori status polusi berdasarkan urutan dari yang terburuk hingga yang terbaik.

Tabel 6.85 Klasifikasi Hasil Peramalan Wilayah Surabaya Timur

No	CO	pred_co	NO2	prediksi_no2	O3	pred_o3	PM10	pred_pm10	SO2	prediksi_so2	status_polusi
1	0.48	Sedang	18.00	Sangat Tidak Baik	72.18	Sangat Baik	43.34	Sangat Tidak Baik	31.87	Sedang	Sangat Tidak Baik
2	0.33	Baik	14.97	Sangat Tidak Baik	78.09	Sangat Baik	50.44	Sangat Tidak Baik	32.25	Sedang	Sangat Tidak Baik
3	0.36	Baik	14.45	Sangat Tidak Baik	79.75	Sangat Baik	53.59	Sangat Tidak Baik	32.09	Sedang	Sangat Tidak Baik
4	0.43	Sedang	14.30	Sangat Tidak Baik	79.92	Sangat Baik	54.61	Sangat Tidak Baik	31.43	Sedang	Sangat Tidak Baik
...

Pada Gambar 6.20 menunjukkan persentase perbandingan status polusi pada Wilayah Surabaya Timur berdasarkan klasifikasi hasil Peramalan. Status polusi udara wilayah Surabaya Timur menunjukkan bahwa 100% status polusi udara sangat tidak baik.

Persentase Status Polusi Hasil Peramalan Surabaya Timur



Gambar 6.20 Persentase Status Polusi Hasil Peramalan Wilayah Surabaya Timur

6.7.3 Klasifikasi Hasil Peramalan Wilayah Surabaya Selatan

Pada Tabel 6.86 menunjukkan bahwa hasil peramalan pada setiap unsur polutan udara seperti CO, NO₂, O₃, PM₁₀, SO₂ yang masing-masing telah terprediksi masuk ke dalam kelas kategori status polusi seperti apa.

Status polusi udara harian yang merupakan kesimpulan status polusi udara ditarik dari hasil kategori status polusi pada masing-masing lima unsur polutan udara. Indeks Pencemar Udara yang dilaporkan ke media massa (display, koran harian setempat /televise stasiun setempat) adalah Indeks Standar Pencemar Udara yang paling tinggi [29]. Apabila ada salah satu saja unsur polutan udara yang masuk ke dalam kelas kategori status polusi yang buruk, maka kesimpulan status polusi udara harian adalah dengan kondisi kategori status polusi dari kelima unsur polutan udara yang paling buruk. Apabila diurutkan kategori status polusi udara berdasarkan rentang dari yang terburuk sampai dengan yang terbaik adalah “sangat tidak baik”, “tidak baik”, “sedang”, “baik”, dan “sangat baik”. Sehingga penarikan kesimpulan status polusi udara adalah

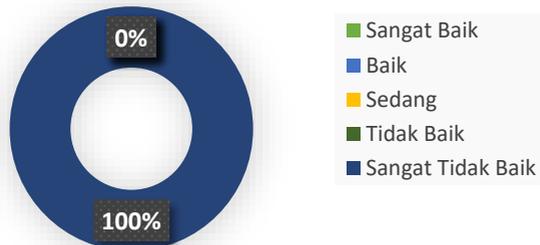
ditarik dari kategori status polusi berdasarkan urutan dari yang terburuk hingga yang terbaik.

Tabel 6.86 Klasifikasi Hasil Peramalan Wilayah Surabaya Selatan

No	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
1	0.48	Sedang	18.00	Sangat Tidak Baik	72.18	Sangat Baik	43.34	Sangat Tidak Baik	31.87	Sedang	Sangat Tidak Baik
2	0.33	Baik	14.97	Sangat Tidak Baik	78.09	Sangat Baik	50.44	Sangat Tidak Baik	32.25	Sedang	Sangat Tidak Baik
3	0.36	Baik	14.45	Sangat Tidak Baik	79.75	Sangat Baik	53.59	Sangat Tidak Baik	32.09	Sedang	Sangat Tidak Baik
4	0.43	Sedang	14.30	Sangat Tidak Baik	79.92	Sangat Baik	54.61	Sangat Tidak Baik	31.43	Sedang	Sangat Tidak Baik
...

Pada Gambar 6.21 menunjukkan persentase perbandingan status polusi pada Wilayah Surabaya Selatan berdasarkan klasifikasi hasil Peramalan. Status polusi udara wilayah Surabaya Pusat menunjukkan bahwa 100% status polusi udara sangat tidak baik.

Persentase Status Polusi Hasil Peramalan Surabaya Selatan



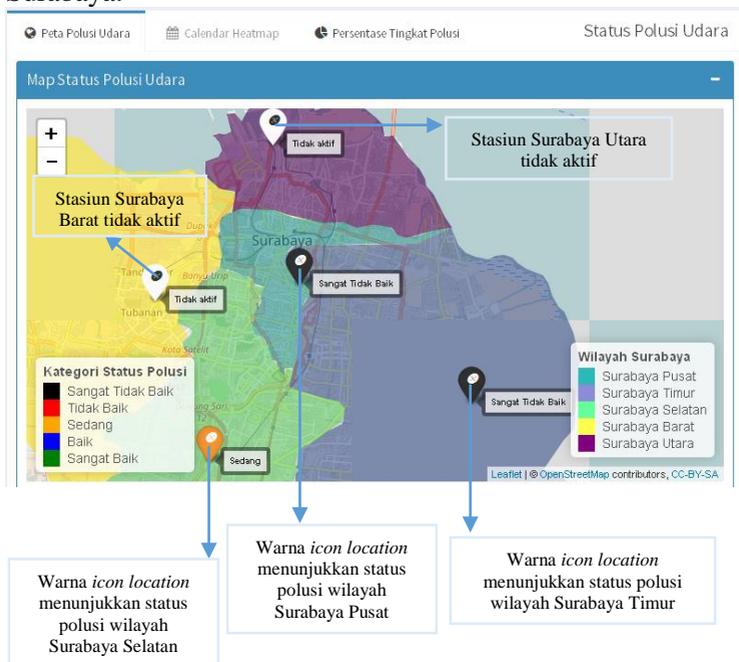
Gambar 6.21 Persentase Status Polusi Hasil Peramalan Wilayah Surabaya Selatan

6.8 Analisis Hasil Visualisasi

6.8.1 Leaflet Map Status Polusi

Leaflet map digunakan untuk melihat status polusi yang memudahkan pengguna memahami status polusi berdasarkan lokasi geografis masing-masing wilayah bagian Surabaya yang diwakili oleh stasiun pemantau udara.

Pada Gambar 6.22 menunjukkan cara pembacaan atau interpretasi bentuk komponen visual *leaflet map* yang merepresentasikan status polusi di setiap bagian wilayah Surabaya.



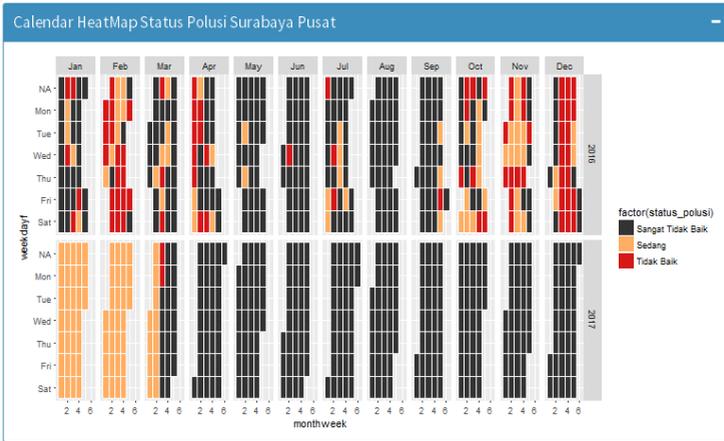
Gambar 6.22 Interpretasi *Leaflet Map* Status Polusi

6.8.2 Calendar Heatmap Status Polusi

Calendar Heatmap digunakan untuk menunjukkan status polusi udara di setiap bagian wilayah Surabaya secara terangkum dengan bentuk pembacaan data menggunakan *calendar* dan

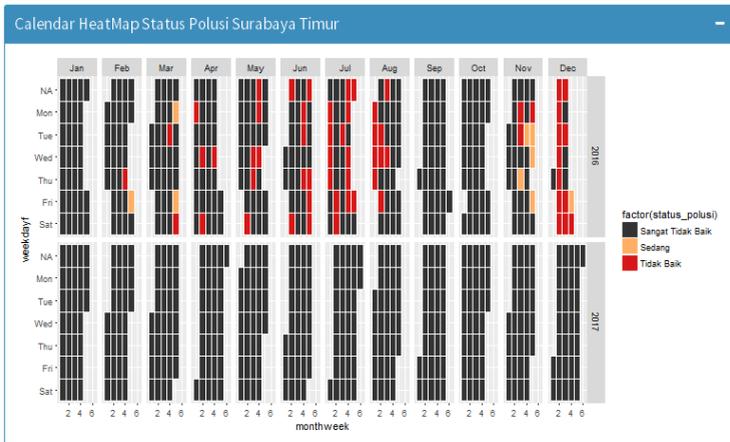
heatmap yang merepresentasikan warna-warna dari status polusi.

Pada Gambar 6.23 menunjukkan bahwa dari hasil peramalan pada tahun 2017 wilayah Surabaya Pusat di awal bulan Januari 2017 hingga minggu kedua Maret 2017 status polusi udara masih menunjukkan sedang, kemudian status polusi udara mulai menunjukkan tidak baik dan sangat tidak baik.



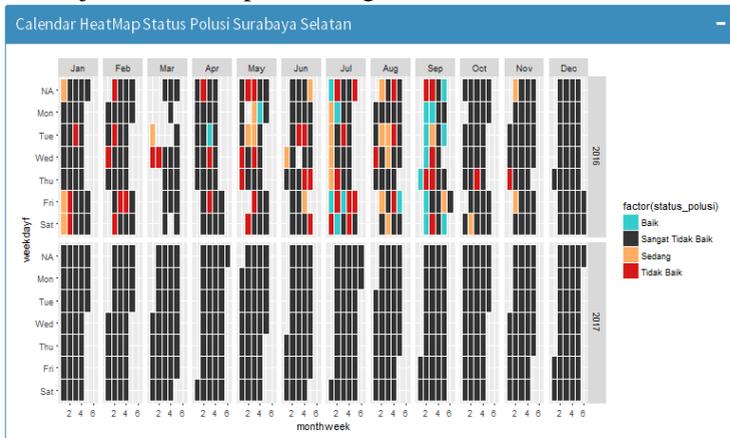
Gambar 6.23 *Calendar Heatmap* status polusi Wilayah Surabaya Pusat

Pada Gambar 6.24 menunjukkan bahwa dari hasil peramalan pada tahun 2017 wilayah Surabaya Timur di awal bulan Januari 2017 hingga akhir Desember 2017 status polusi udara menunjukkan status polusi sangat tidak baik.



Gambar 6.24 *Calendar Heatmap* status polusi Wilayah Surabaya Timur

Pada Gambar 6.26 menunjukkan bahwa dari hasil peramalan pada tahun 2017 wilayah Surabaya Selatan di awal bulan Januari 2017 hingga akhir Desember 2017 status polusi udara menunjukkan status polusi sangat tidak baik.

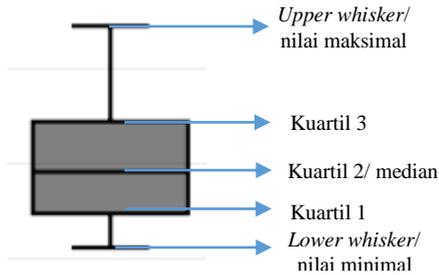


Gambar 6.25 *Calendar Heatmap* status polusi Wilayah Surabaya Selatan

6.8.3 Box Plot Rentang Index Cluster

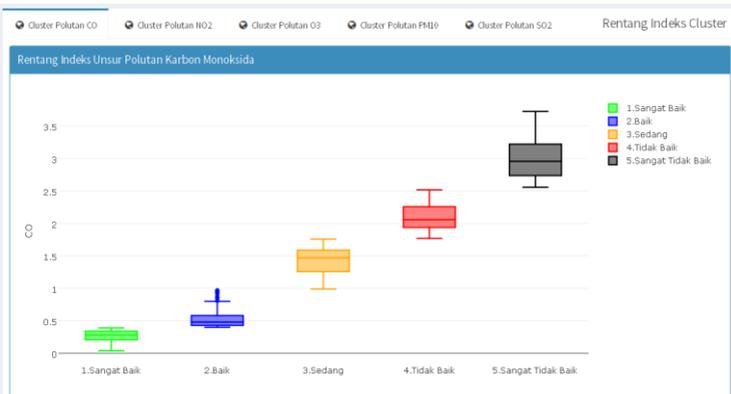
Box Plot digunakan untuk merepresentasikan rentang indeks *cluster* per unsur polutan udara di Surabaya yang menunjukkan batas bawah atau minimal, kuartil 1, median atau kuartil tengah, kuartil 3, dan batas atas atau maksimal.

Pada Gambar 6.26 menunjukkan *interpretasi box plot* untuk pembacaan rentang indeks *cluster*.



Gambar 6.26 Interpretasi *Box Plot*

Pada Gambar 6.27 menunjukkan *box plot* rentang indeks *cluster* unsur polutan CO dengan interpretasi hasil di setiap kategori bahwa batas bawah atau minimal, kuartil 1, median, kuartil 3, dan batas atas.



Gambar 6.27 *Box Plot* Rentang Indeks Unsur Polutan CO

Pada Gambar 6.28 menunjukkan *box plot* rentang indeks *cluster* unsur polutan NO₂ dengan interpretasi hasil di setiap kategori bahwa batas bawah atau minimal, kuartil 1, median, kuartil 3, dan batas atas.



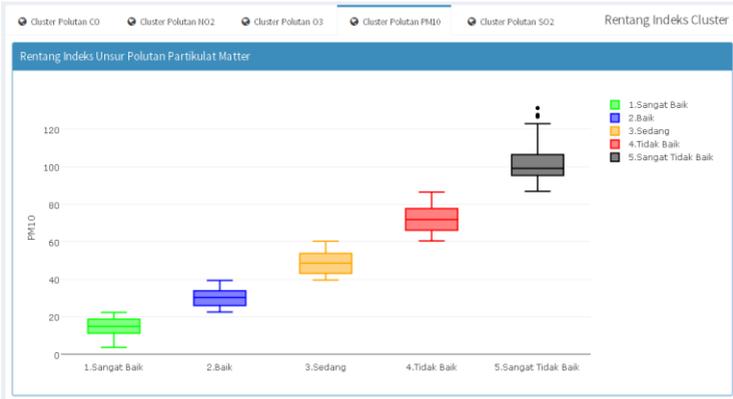
Gambar 6.28 *Box Plot* Rentang Indeks Unsur Polutan NO₂

Pada Gambar 6.29 menunjukkan *box plot* rentang indeks *cluster* unsur polutan O₃ dengan interpretasi hasil di setiap kategori bahwa batas bawah atau minimal, kuartil 1, median, kuartil 3, dan batas atas.



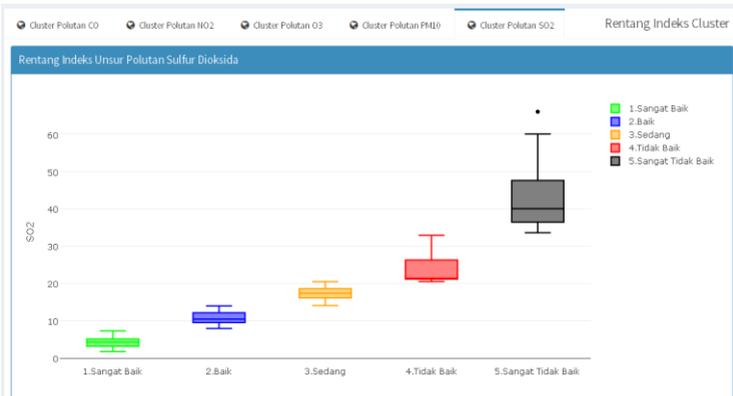
Gambar 6.29 *Box Plot* Rentang Indeks Unsur Polutan O₃

Pada Gambar 6.30 menunjukkan *box plot* rentang indeks *cluster* unsur polutan PM₁₀ dengan interpretasi hasil di setiap kategori bahwa batas bawah atau minimal, kuartil 1, median, kuartil 3, dan batas atas.



Gambar 6.30 *Box Plot* Rentang Indeks Unsur Polutan PM10

Pada Gambar 6.31 menunjukkan *box plot* rentang indeks *cluster* unsur polutan SO₂ dengan interpretasi hasil di setiap kategori bahwa batas bawah atau minimal, kuartil 1, median, kuartil 3, dan batas atas.

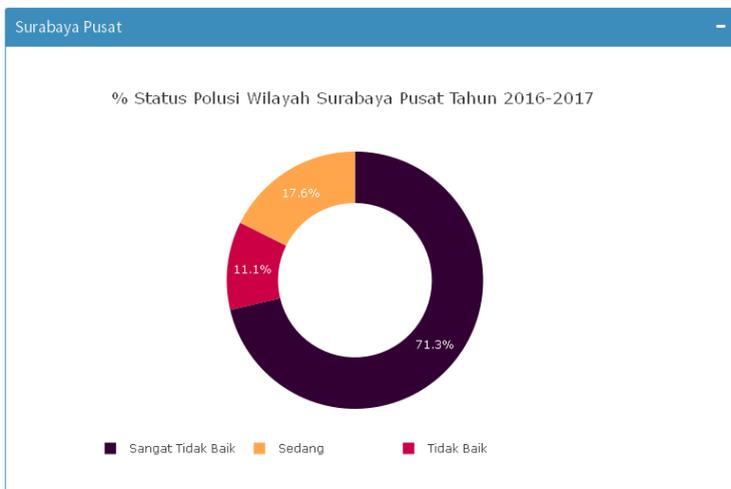


Gambar 6.31 *Box Plot* Rentang Indeks Unsur Polutan SO2

6.8.4 Doughnut Chart Persentase Status Polusi

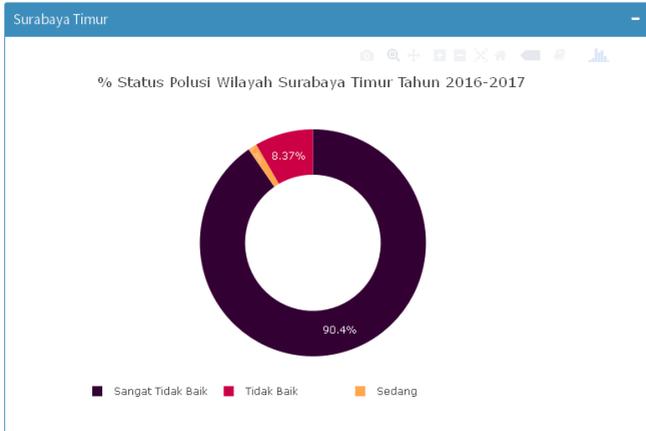
Doughnut chart digunakan untuk merepresentasikan persentase status polusi pada masing-masing Wilayah Surabaya yakni Surabaya Pusat, Surabaya Timur, dan Suraba Selatan pada tahun 2016 dan tahun 2017.

Berdasarkan hasil Gambar 6.32, analisis visualisasi menunjukkan bahwa pada Wilayah Surabaya Pusat memiliki status polusi sangat tidak baik 71.3%, status polusi tidak baik sebesar 11.1%, dan status polusi sedang sebesar 17,6% pada tahun 2016-2017.



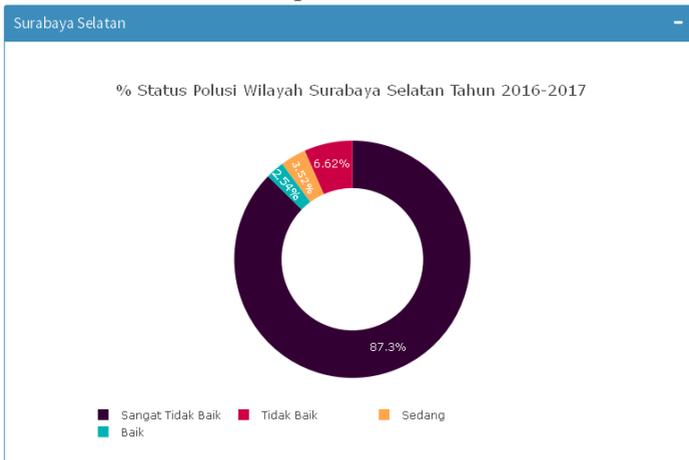
Gambar 6.32 *Doughnut chart* persentase status polusi Wilayah Surabaya Pusat

Berdasarkan hasil Gambar 6.33, analisis visualisasi menunjukkan bahwa pada Wilayah Surabaya Timur memiliki status polusi sangat tidak baik 90.4%, status polusi tidak baik sebesar 8.37%, dan status polusi sedang sebesar 1,27% pada tahun 2016-2017.



Gambar 6.33 Doughnut chart persentase status polusi Wilayah Surabaya Timur

Berdasarkan hasil Gambar 6.34, analisis visualisasi menunjukkan bahwa pada Wilayah Surabaya Timur memiliki status polusi sangat tidak baik 87.3%, status polusi tidak baik sebesar 6.62%, status polusi sedang sebesar 3.52%, dan status polusi baik sebesar 2.54% pada tahun 2016-2017.

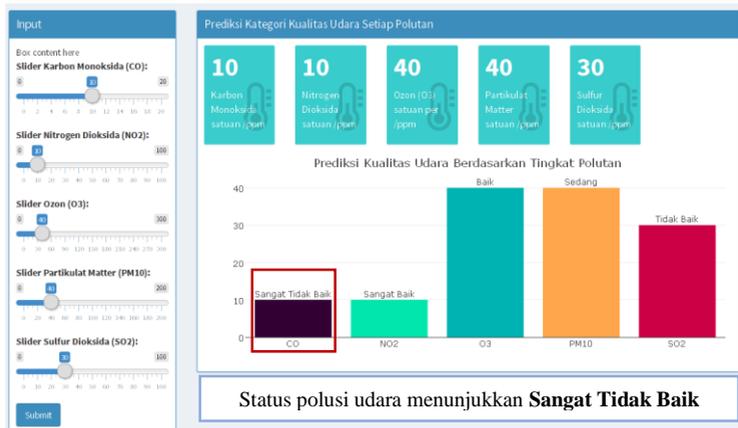


Gambar 6.34 Doughnut chart persentase status polusi Wilayah Surabaya Selatan

6.8.5 Bar Chart Prediksi Klasifikasi Status Polusi

Bar chart digunakan untuk merepresentasikan hasil status polusi sesuai dengan *input*-an pengguna yang ingin mengetahui beberapa nilai kadar polutan udara akan masuk ke dalam kategori status polusi seperti apa.

Pada Gambar 6.35 menunjukkan cara penarikan kesimpulan interpretasi hasil dari prediksi klasifikasi status polusi harian.



Kesimpulan status polusi diambil berdasarkan **urutan status polusi dari yang terburuk hingga terbaik**. Jika ada salah satu unsur polutan yang memiliki status polusi yang paling buruk, maka kesimpulan status polusi udara hari itu adalah status polusi udara terburuk tersebut.

Gambar 6.35 Interpretasi Hasil Visual *Bar Chart* Prediksi Klasifikasi Status Polusi Udara

6.8.6 Line Chart Peramalan

Line chart digunakan untuk merepresentasikan plot grafik hasil peramalan untuk masing-masing lima unsur polutan udara di setiap bagian wilayah Surabaya yakni Surabaya Pusat, Surabaya Timur dan Surabaya Selatan.

Pada Gambar 6.36 menunjukkan grafik yang merepresentasikan sumbu x sebagai waktu *time series* per harian sedangkan sumbu y merepresentasikan kadar polutan per satuan ppm pada lima unsur polutan udara yakni CO, NO₂, O₃, PM₁₀, SO₂ di Wilayah Surabaya Pusat.



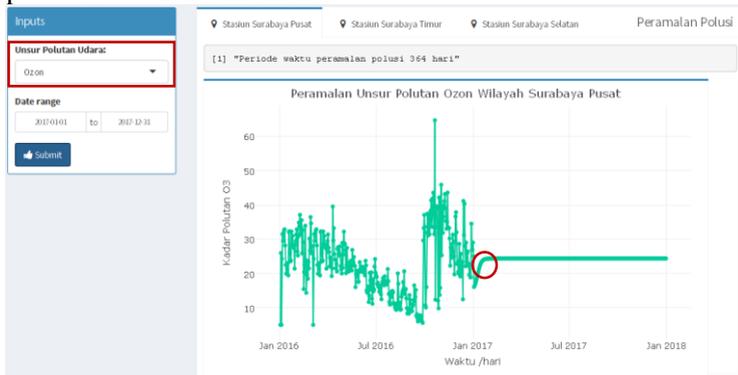
Gambar 6.36 Interpretasi *Line Chart* Peramalan Polusi Udara Surabaya Pusat

Pada Gambar 6.37 menunjukkan salah satu contoh penggunaan *filter* unsur polutan udara dalam *dropdown* menu yang memungkinkan melihat masing-masing unsur kadar polutan udara yakni sebagai contoh unsur polutan karbon monoksida.



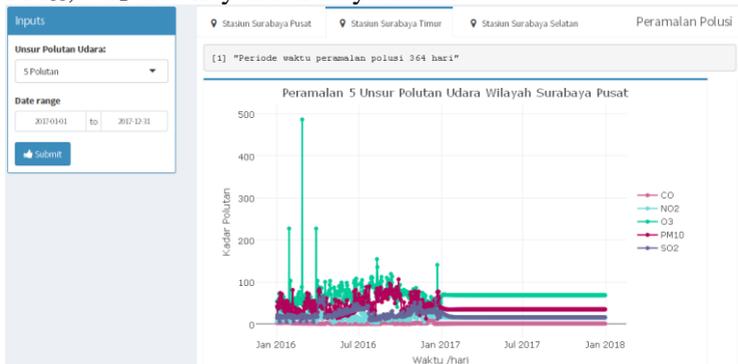
Gambar 6.37 *Line Chart* Unsur Polutan Udara Karbon Monoksida Wilayah Surabaya Pusat

Pada Gambar 6.38 menunjukkan unsur polutan udara ozon di Surabaya Pusat dimana hasil peramalan mengalami kenaikan pada awal bulan Januari 2017.



Gambar 6.38 Line Chart Unsur Polutan Udara Ozon Wilayah Surabaya Pusat

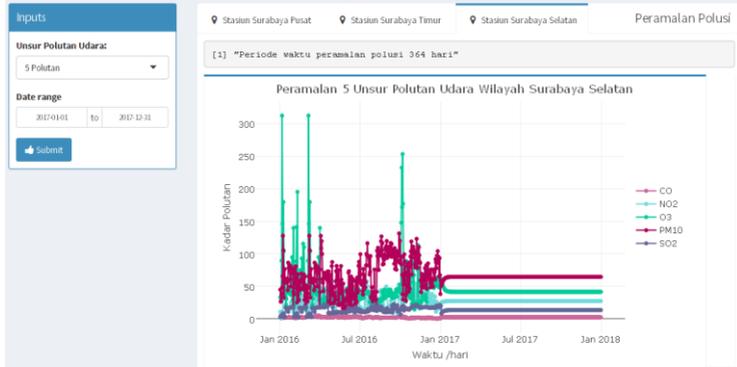
Pada Gambar 6.39 menunjukkan grafik yang merepresentasikan sumbu x sebagai waktu *time series* per harian sedangkan sumbu y merepresentasikan kadar polutan per satuan ppm pada lima unsur polutan udara yakni CO, NO₂, O₃, PM₁₀, SO₂ di Wilayah Surabaya Timur.



Gambar 6.39 Interpretasi *Line Chart* Peramalan Polusi Udara Surabaya Timur

Pada Gambar 6.40 menunjukkan grafik yang merepresentasikan sumbu x sebagai waktu *time series* per harian sedangkan sumbu y merepresentasikan kadar polutan per

satuan ppm pada lima unsur polutan udara yakni CO, NO₂, O₃, PM₁₀, SO₂ di Wilayah Surabaya Selatan.



Gambar 6.40 Interpretasi *Line Chart* Peramalan Polusi Udara Surabaya Selatan

6.9 Kesimpulan Hasil Percobaan

Pada tahap ini dilakukan penarikan kesimpulan dari keseluruhan percobaan yang dilakukan mulai dari proses *clustering*, proses peramalan dan proses klasifikasi. Berikut ini adalah kesimpulan dari percobaan penelitian.

6.9.1 Kesimpulan Hasil Percobaan *Clustering*

1. Model terbaik untuk klasterisasi atau pengelompokan rentang nilai kadar polutan yang cocok di Surabaya adalah dengan melakukan pengelompokan pada setiap unsur polutan udara di seluruh bagian wilayah Surabaya.
2. Pada tahun 2016, titik rawan polusi yang paling banyak adalah daerah wilayah Surabaya Selatan dimana unsur polutan yang paling tercemar adalah Karbon Monoksida, Nitrogen Dioksida dan Partikulat Matter atau debu. Sedangkan titik rawan polusi kedua adalah Surabaya Timur dimana memiliki unsur yang paling tercemar dibandingkan daerah lain yakni Ozon dan Sulfur Dioksida.

6.9.2 Kesimpulan Hasil Percobaan Peramalan

Berikut ini adalah kesimpulan dari percobaan peramalan polusi udara dengan metode ANN.

1. Model terbaik yang dapat digunakan untuk peramalan pada stasiun pemantau udara Wilayah Surabaya Pusat dan Surabaya Timur adalah dengan menggunakan data satu periode sehari sebelumnya. Sedangkan untuk stasiun pemantau udara wilayah Surabaya Selatan menggunakan data dua periode sebelumnya.
2. Peramalan udara di wilayah Surabaya Pusat menunjukkan pola sebagai berikut.
 - Unsur polutan udara karbon monoksida, nitrogen dioksida dan ozon mengalami kenaikan secara perlahan mulai dari Januari 2017 hingga bulan Maret 2017.
 - Sedangkan partikulat matter atau debu dan sulfur dioksida cenderung menurun sejak Januari 2017 hingga Bulan Maret 2017. Kemudian sejak Bulan April 2017 kadar 5 unsur polutan cenderung stationer.
3. Peramalan udara di wilayah Surabaya Timur menunjukkan pola sebagai berikut.
 - Unsur polutan udara karbon monoksida mengalami kenaikan secara perlahan mulai dari Januari 2017 hingga bulan Maret 2017.
 - Unsur polutan udara nitrogen dioksida, ozon, dan Sulfur Dioksida cenderung menurun sedikit dan kemudian relatif stationer sejak akhir Bulan Januari 2017.
 - Unsur polutan Partikulat Matter di wilayah Surabaya Timur yang cenderung mengalami kenaikan secara perlahan pada awal Bulan Januari 2017 hingga 6 Januari 2017 dan mengalami sedikit penurunan hingga 18 Januari 2017 dimana selanjutnya kadar polutan menjadi relatif stabil.
4. Peramalan udara di wilayah Surabaya Pusat menunjukkan pola sebagai berikut.

- Unsur polutan udara Karbon monoksida, nitrogen dioksida, ozon dan partikulat matter cenderung naik pada awal bulan Januari 2017 dan kemudian sedikit menurun lalu pola data relatif stationer.
- Sedangkan sulfur dioksida cenderung menurun pada awal bulan Januari 2017 dan pada akhir bulan naik secara perlahan hingga bulan Februari 2017 pola data relatif stationer.

6.9.3 Kesimpulan Hasil Percobaan Klasifikasi

Hasil klasifikasi dari peramalan menunjukkan kesimpulan status polusi udara untuk 1 tahun kedepan mulai periode 1 Januari 2017 sampai dengan akhir Desember 2017 yakni sebagai berikut.

1. Status polusi untuk wilayah Surabaya Pusat memiliki 80% status polusi udara sangat tidak baik, 19% status polusi udara sedang dan 1% status polusi udara tidak baik.
2. Status polusi udara untuk wilayah Surabaya Timur menunjukkan bahwa 100% status polusi udara sangat tidak baik.
3. Status polusi untuk wilayah Surabaya Selatan juga menunjukkan bahwa status polusi udara 100% sangat tidak baik.

BAB VII

KESIMPULAN DAN SARAN

Pada bab ini disampaikan mengenai kesimpulan dari semua proses yang telah dilakukan pada penelitian tugas akhir ini dan saran yang dapat digunakan untuk pengembangan penelitian selanjutnya.

7.1 Kesimpulan

Berdasarkan hasil uji coba yang telah dilakukan dalam penelitian tugas akhir ini, maka kesimpulan yang dapat diambil adalah :

1. Model *clustering* pada masing-masing unsur polutan udara CO, NO₂, O₃, PM₁₀, SO₂ dapat diterapkan dan terpartisi secara baik menggunakan metode K-Means dengan jumlah *cluster* 5.
2. Model *clustering* memiliki uji performa dari model terbaik dengan *clustering* pada setiap unsur polutan di seluruh Surabaya menunjukkan nilai performa SSE senilai 0.17, nilai performa *dunn index* senilai 0.044 dan nilai performa *silhouette* 0.602
3. Model peramalan pada ketiga stasiun pemantau udara dikatakan cukup karena nilai MAPE berkisar antara 20% sampai dengan 34%, yakni nilai MAPE pengujian pada model wilayah Surabaya Pusat senilai 24.6%, nilai MAPE pada model wilayah Surabaya Timur senilai 34,7% dan nilai MAPE pada model wilayah Surabaya Selatan senilai 27,4%.
4. Model prediksi klasifikasi pada lima model di setiap unsur polutan sudah sangat baik karena nilai akurasi di atas 80% dimana akurasi pada klasifikasi model unsur polutan CO bernilai 100%, akurasi pada model unsur NO₂ bernilai 99.4%, akurasi pada model unsur O₃ bernilai 100% dan akurasi pada model unsur PM10 & model unsur SO₂ bernilai sama yakni 99.1%.

5. Sistem dashboard dapat menampilkan dan menggabungkan hasil model peramalan dan klasifikasi serta hasil *clustering* melalui beberapa komponen visual dashboard yang terangkum sehingga dapat lebih mudah dipahami dan membantu mempermudah pembacaan hasil analisis untuk pengambilan keputusan.

7.2 Saran

Berdasarkan kesimpulan dari penelitian tugas akhir ini, diberikan rekomendasi berupa saran. Saran yang diberikan oleh penulis bagi penelitian selanjutnya adalah sebagai berikut.

1. Pembuatan model peramalan *Artificial Neural Network* dapat dilakukan dengan menggunakan *tools analytic* lain seperti MATLAB maupun Rapid Miner.
2. Variabel masukan untuk pembuatan model ANN dapat menggunakan variabel lain seperti suhu udara, tekanan udara, curah hujan dimana datanya sesuai dengan stasiun pemantau udara di masing-masing wilayah bagian Surabaya atau menggunakan data lain seperti jumlah kendaraan bermotor maupun jumlah pabrik.
3. Pembuatan model klasifikasi dapat menggunakan metode lainnya seperti *Support Vector Machine* (SVM) atau *Artificial Neural Network* (ANN).
4. Pembuatan model klasifikasi dapat menggunakan K-Fold Cross Validation untuk melakukan pengontrolan data *train*, sehingga membantu memperoleh performa akurasi yang lebih baik.

DAFTAR PUSTAKA

- [1] KABAPEDAL, “Laporan Pemeliharaan Stasiun Monitoring Udara Ambient, Badan Pengendalian Lingkungan Hidup,” 2008.
- [2] A. Budiyo, “Pencemaran Udara Dampak Pencemaran Udara Pada Lingkungan,” 2001.
- [3] A. T. Tugaswati, “Review of Air Pollution and Its Health Impact in Indonesia,” *Environmental Research*, pp. 95-100, 1991.
- [4] WHO, “WHO releases country estimates on air pollution exposure and health impact,” 2016. [Online]. Available: <http://www.who.int/mediacentre/news/releases/2016/air-pollution-estimates/en/>. [Diakses 10 Oktober 2016].
- [5] Kementerian Lingkungan Hidup, “Data Harian Kualitas Udara (ISPU) dari Stasiun Pemantauan Kualitas Udara di 10 Kota di Indonesia,” [Online]. Available: <http://www.menlh.go.id/data-harian-kualitas-udara-ispudari-stasiun-pemantauan-kualitas-udara-di-10-kota-di-indonesia/>. [Diakses 28 Desember 2016].
- [6] Hajek, “Air Quality Indices and their Modelling by Hierarchical Fuzzy Inference,” *WSEAS Transactions on Environment and Development*, 2009.
- [7] Y. Bai, Y. Li, X. Wang, J. Xie dan C. Li, “Air Pollutans Concentrations Forecasting Using Back Propagation Neural Network Based on Wavelet Decomposition with Meteorological Conditions,” *Elsevier*, pp. 557-566, 2016.
- [8] S. Russel dan P. Novig, *Artificial Intelligence : A Modern Approach*, 2013.
- [9] K. Grace, Manimegalai, G. Devasena, Rajathi dan R. Baseria, “Air Pollution Analysis Using Enhanced K-Means Clustering Algorithm for Real Time Sensor Data,” *IEEE*, pp. 1945-1948, 2016.

- [10] G. Xiaojie, C. Liang, Z. Hang dan H. Jun, "An Improved K-means Algorithm and Its Application in the Evaluation of Air Quality Level," *IEEE*, p. 3324, 2015.
- [11] S.-T. Li dan L.-Y. Shue, "Data Mining to Aid Policy Making in Air Pollution Management," *Elsevier*, pp. 331-340, 2004.
- [12] W. Tamas, G. Notton, C. Paoli, M.-L. Nivet dan C. Voyant, "Hybridization of Air Quality Forecasting Models Using Machine Learning and Clustering : An Original Approach to Detect Pollutant Peaks," *Taiwan Association for Aerosol Research*, pp. 406-416, 2016.
- [13] J. Reyes dan A. Sanchez, "Analysis of Air Quality Data in Mexico City with Clustering Techniques on Genetic Algorithm," *IEEE*, pp. 27-31, 2013.
- [14] T. P.-N, M. Steinbach dan V. Kumar, *Introduction to Data Mining*, Boston: Addison-Wesley Longman Publishing Co, 2005.
- [15] D. . A. Agunbiade dan P. . I. Ogunyinka, "Effect of Correlation Level on the Use of Auxiliary Variable in Double Sampling for Regression Estimation," *Scientific Research Publishing (SCIRP)*, 2013.
- [16] Leard Statistic, "Pearson Product-Moment Correlation," Leard Statistic, [Online]. Available: <https://statistics.laerd.com/statistical-guides/pearson-correlation-coefficient-statistical-guide.php>. [Diakses 26 Mei 2017].
- [17] S. M. Mugi Wahidin, "Uji Korelasi Spearman Rank dan Uji Korelasi Kendal Tau," 7 Juni 2014. [Online]. Available: <http://slideplayer.info/slide/3040351/>. [Diakses 26 Mei 2017].
- [18] R. Newson, "Parameters behind "non-parametric" statistics: Kendall ,Somers and median differences," *The Stata Journal*, pp. 1 - 20, 2001.
- [19] J. S. Armstrong, *Principles of Forecasting: A Handbook for Researchers and Practitioners*, United States: Springer, 2001.

- [20] W. Anggraeni, “Aplikasi Jaringan Syaraf Tiruan Untuk Peramalan Permintaan Barang,” *Jurusan Sistem Informasi ITS*, vol. V, pp. 99-105, 2006.
- [21] D. Anderson dan G. McNeill, *ARTIFICIAL NEURAL NETWORK TECHNOLOGY*, New York: Kaman Sciences Corporation, 1992, pp. 8-9.
- [22] S. Thawornwong dan D. Enke, “Neurocomputing,” dalam *The adaptive selection of financial and economic variables for use with artificial neural networks*, 2004, pp. 205-232.
- [23] J. Bidanghan, I. Purnamasari dan M. Nor Hayati, “Perbandinga Peramalan Metode Double Exponential Smoothing Satu Parameter Brown dan Metode Double Exponential Smoothing Dua Parameter Holt,” *Statistika*, vol. vol.4, no. No.1, 2016.
- [24] S. Makridakis, S. Wheelwright dan V. McGee, *Metode dan Aplikasi Peramalan*, Jilid 1 Edisi Revisi (ter), Jakarta: Binarupa Aksara, 2003.
- [25] N. Zainun dan Z. Majid, *Low Cost House Demand Perdictor*, Malaysia: Universitas Teknologi Malaysia, 2003.
- [26] P.-C. Chang, Y.-W. Wang dan C.-H. Liu, *The development of a weighted evolving fuzzy neural network for PCB sales forecasting*, Taoyuan, Taiwan: Elsevier, 2005.
- [27] S. Chawla dan A. Gionis, “k-means--: A unified approach to clustering and outlier detection,” 2013.
- [28] S. Seo, “A Review and Comparison of Methods for Detecting Outliers in Univariate Datasets,” 2002.
- [29] Badan Pengendalian Dampak Lingkungan, “PEDOMAN TEKNIS PERHITUNGAN DAN PELAPORAN SERTA INFORMASI INDEKS STANDAR PENCEMAR UDARA,” 1997.
- [30] *statitistical-research.com*, “Kendall's tau,” 05 September 2012. [Online]. Available: <https://www.google.co.id/url?sa=t&rct=j&q=&src=s&s>

source=web&cd=16&cad=rja&uact=8&ved=0ahUKEwi
v-
rKbi7_UAhXFro8KHfQpDP8QFgh1MA8&url=https%
3A%2F%2Fstatistical-research.com%2Fwp-
content%2Fuploads%2F2012%2F09%2Fkendall-
tau1.pdf&usg=AFQjCNEt8M-MFnUE_LLjeC9wzGw.
[Diakses Juni 2017].

- [31] K. Z. ., S. A. ., S. Mahboubeh Khajvand, “Estimating Customer Lifetime Value Based o RFM Analysis of Customer Purchase Behavior : Case Study,” *Procedia Computer Science* , vol. 3, pp. 57-63, 2011.

BIODATA PENULIS



Penulis, Ervi Ritya Zulvima, lahir di Madiun, 29 September 1994, merupakan anak terakhir dari ketiga bersaudara. Penulis telah menempuh pendidikan formal di SDN Klegen 1 Madiun, SMPN 1 Madiun, SMAN 3 Madiun, Jawa Timur. Pada tahun 2013 penulis diterima pada Jurusan Sistem Informasi FTIf – Institut Teknologi Sepuluh Nopember (ITS) Surabaya.

Penulis mengikuti organisasi mahasiswa yakni staff Himpunan Mahasiswa Informasi tahun 2014/2015, staff *External Affairs* Badan Eksekutif Mahasiswa FTIF tahun 2014/2015 dan Bendahara Umum 1 Himpunan Mahasiswa Sistem Informasi tahun 2015/2016. Penulis pernah menjadi asisten dosen mata kuliah Perencanaan Sumber Daya Perusahaan tahun 2016. Pada tahun 2016, penulis mendapatkan kesempatan untuk magang di PT. Telekomunikasi Indonesia Kota Bandung – Jawa Barat selama 1,5 bulan. Penulis mengambil bidang minat Rekayasa Data dan Inteligensi Bisnis (RDIB) di Jurusan Sistem Informasi ITS. Untuk keperluan penelitian, penulis dapat dihubungi melalui email erviritya@gmail.com.

(Halaman ini sengaja dikosongkan)

LAMPIRAN A

Data Aktual Kualitas Udara Stasiun Pemantau Wilayah Surabaya Pusat, Timur dan Selatan

Pada lampiran A berisi tentang data yang digunakan pada penelitian tugas akhir ini yaitu data rata-rata harian kadar polutan udara, Kota Surabaya, Jawa Timur periode Januari 2016 – Desember 2016.

Data aktual stasiun pemantau udara suf1 yakni wilayah Surabaya Pusat.

date	suf1_co	suf1_no2	suf1_o3	suf1_pm10	suf1_so2
01/01/2016	0.47	13.67	4.99	11.5	4.52
02/01/2016	0.38	2.81	25.94	8.05	4.5
03/01/2016	0.4	6.91	4.99	4.93	2.8
04/01/2016	0.6	2.66	24.24	17.77	3.64
05/01/2016	0.63	3.92	31.45	3.69	2.56
06/01/2016	0.52	5.58	29.45	11.25	1.74
07/01/2016	0.34	1.17	31.8	8.55	4.85
08/01/2016	0.36	14.44	32.61	6.29	4.09
09/01/2016	0.36	10.38	32.86	7.86	3.35
10/01/2016	0.37	8.25	28.14	23.43	4.21
11/01/2016	0.54	9.76	22.47	23.44	3.16
12/01/2016	0.43	10.25	19.9	24.21	3.73
13/01/2016	0.37	8.92	22.74	28.88	2.34
14/01/2016	0.44	4.45	21.26	17.21	2.65
15/01/2016	0.25	3.34	23	11.32	2.4
16/01/2016	0.38	9.25	19.41	23.1	6.31
17/01/2016	0.38	4.92	32.08	22.55	2.68
18/01/2016	0.41	5.31	32.28	16.61	2.87
19/01/2016	0.35	3.41	25.9	17.4	3.72
20/01/2016	0.41	2.46	23.51	37.27	3.73
21/01/2016	0.41	2.95	23.74	10.79	2.02
22/01/2016	0.36	2.41	32.21	24.05	2.32
23/01/2016	0.52	3.9	28.57	30.19	3.33
24/01/2016	0.39	1.4	30.91	11.94	4.44
25/01/2016	0.39	2.89	27.98	8.81	5.78
26/01/2016	0.46	2.27	28.35	10.05	5.86
27/01/2016	0.35	2.14	27.29	7.51	3.87
28/01/2016	0.31	3.61	21.39	6.75	2.27
29/01/2016	0.32	4.19	28.26	6.47	3.79
30/01/2016	0.29	4.75	29.45	6.26	4.57
31/01/2016	0.24	13.67	31.35	16.6	5.1
01/02/2016	0.33	1.19	32.84	27.98	4.49
02/02/2016	0.37	6.92	26.38	26.85	4.5
03/02/2016	0.34	4.94	25.21	23.91	2.8
04/02/2016	0.41	2.56	30.78	31.26	3.64

date	suf1_co	suf1_no2	suf1_o3	suf1_pm10	suf1_so2
05/02/2016	0.39	2.3	34.82	80.7	2.56
06/02/2016	0.32	2.01	33.78	28.55	1.74
07/02/2016	0.37	2.29	37.07	29.68	4.85
08/02/2016	0.29	2.84	31.35	35.22	4.09
09/02/2016	0.33	1.07	33.41	31	3.35
10/02/2016	0.41	1.65	35.52	31.49	4.21
11/02/2016	0.26	2.32	25.83	20.39	3.16
12/02/2016	0.27	4.78	32.67	50.56	3.73
13/02/2016	0.36	3.24	29.06	30.21	2.34
14/02/2016	0.51	3.64	15.44	40.16	2.65
15/02/2016	0.64	4.99	20.4	44.63	2.4
16/02/2016	0.68	4.91	22.42	40.5	6.31
17/02/2016	0.3	4.34	33.91	33.83	2.68
18/02/2016	0.3	4.48	22.95	35.61	2.87
19/02/2016	0.34	3.9	14.33	40.35	3.72
20/02/2016	0.32	3.42	19.55	34.61	3.73
21/02/2016	0.4	5.75	23.74	25.4	2.02
22/02/2016	0.45	2.41	18.45	34.35	2.32
23/02/2016	0.31	5.7	23.33	11.01	3.33
24/02/2016	0.28	5.13	21.42	39.38	4.44
25/02/2016	0.23	4.92	30.16	33.43	5.78
26/02/2016	0.28	5.56	26.58	34.57	5.86
27/02/2016	0.27	4.39	36.42	12.43	3.87
28/02/2016	0.22	5.18	34.59	21.02	2.27
29/02/2016	0.23	4.96	25.83	23.51	3.79
01/03/2016	0.2	8.7	27.98	11.5	4.52
02/03/2016	0.28	8.96	25.94	8.05	4.5
03/03/2016	0.47	10.3	4.99	4.93	2.8
04/03/2016	0.41	9.39	24.24	17.77	3.64
05/03/2016	0.47	15.49	31.45	3.69	2.56
06/03/2016	0.61	14.25	29.45	11.25	1.74
07/03/2016	0.57	13.61	31.8	8.55	4.85
08/03/2016	0.62	8.99	32.61	6.29	4.09
09/03/2016	0.37	10.66	32.86	7.86	3.35
10/03/2016	0.49	10.23	28.14	23.43	4.21
.....
.....
31/12/2016					

Data aktual stasiun pemantau udara suf6 yakni wilayah Surabaya Timur.

date	suf6_co	suf6_no2	suf6_o3	suf6_pm10	suf6_so2
01/01/2016	1.8	6.13	53.56	41.46	14.32
02/01/2016	1.81	10.04	37.1	19.26	21.41
03/01/2016	2.23	23.37	53.56	51.33	14.14
04/01/2016	1.94	24.31	40.17	36.44	15.25
05/01/2016	2.18	18.72	58.46	36.86	14.85
06/01/2016	2.32	30.92	71.53	42.74	14.75
07/01/2016	2.19	30.73	56.74	60.57	5.28
08/01/2016	2.06	24.36	50.36	73.47	19.45
09/01/2016	2.05	17.43	41.24	51.02	15.05
10/01/2016	1.95	30.27	59.69	68.86	15.01
11/01/2016	1.92	23.59	60.87	61.32	18.43
12/01/2016	1.94	34.18	57.3	71.01	15.23
13/01/2016	2.36	22.38	31.52	46.8	15.22
14/01/2016	2.2	14.07	40.97	37.64	14.6
15/01/2016	1.99	8.21	43.23	53.64	16.04
16/01/2016	2.33	9.41	63.9	49.33	15.59
17/01/2016	2.26	14.67	38.33	30.51	15.51
18/01/2016	2.44	8.34	37.11	41.28	15.16
19/01/2016	2.13	6.11	45.71	33.21	18.96
20/01/2016	2.3	7.32	51.05	24.16	15.39
21/01/2016	2.5	10.63	53.56	54.57	15.51
22/01/2016	2.25	11.77	36.88	49.36	4.8
23/01/2016	2.45	13.67	35.9	54.96	14.8
24/01/2016	2.26	14.06	33.46	30.75	18.26
25/01/2016	2.18	19.96	30.5	52.94	22.39
26/01/2016	1.98	20.55	41.23	46.28	21.94
27/01/2016	2.08	13.73	45.57	34.84	16.13
28/01/2016	2.22	18.51	226.91	40.15	21.25
29/01/2016	2.41	12.29	35.7	37.47	17.9
30/01/2016	2.29	10.24	37.34	25.08	17.72
31/01/2016	2.56	6.13	102.59	27.76	16.8
01/02/2016	2.31	5.26	41.96	22.07	14.41
02/02/2016	2.26	43.3	53.57	35.27	21.41
03/02/2016	1.05	14.42	42.58	28.66	14.14
04/02/2016	1.22	23.5	49.16	46.72	15.25
05/02/2016	1.03	22.29	53.39	80.72	14.85
06/02/2016	0.86	13.49	46.66	22.34	14.75
07/02/2016	0.74	21.5	52.71	13.56	5.28
08/02/2016	1.01	23.95	48.98	25.55	19.45
09/02/2016	0.85	14.91	38.27	24.63	15.05

date	suf6_co	suf6_no2	suf6_o3	suf6_pm10	suf6_so2
10/02/2016	0.93	27.89	61.11	38.59	15.01
11/02/2016	0.86	18.83	46.83	24.88	18.43
12/02/2016	1.04	19.07	48.96	27.1	15.23
13/02/2016	1.19	19.37	36.74	31.74	15.22
14/02/2016	1.05	13.31	41.32	32.35	14.6
15/02/2016	1.01	14.62	60.1	18.3	16.04
16/02/2016	1.23	24.84	53.88	29.52	15.59
17/02/2016	1	13.42	66.39	34.12	15.51
18/02/2016	1.01	17.3	71.73	34.91	15.16
19/02/2016	0.96	18.04	48.44	27.19	18.96
20/02/2016	0.68	13	76.1	33.58	15.39
21/02/2016	0.81	9.76	53.56	21.75	15.51
22/02/2016	0.99	11.77	56.58	23.55	4.8
23/02/2016	1.24	18.93	60.65	28.45	14.8
24/02/2016	1.19	16.36	48.33	26.79	18.26
25/02/2016	1.17	8.65	87.5	23.58	22.39
26/02/2016	0.97	13.73	486.52	24.43	21.94
27/02/2016	2.66	12.15	44.73	12.99	16.13
28/02/2016	0.46	13.08	62.13	30.16	21.25
29/02/2016	0.39	10.33	67.46	31.71	17.9
01/03/2016	0.33	11.45	60.82	41.46	14.32
02/03/2016	0.42	16.26	37.1	19.26	21.41
03/03/2016	0.81	24.06	53.56	51.33	14.14
04/03/2016	0.67	16.64	40.17	36.44	15.25
05/03/2016	0.78	18.47	58.46	36.86	14.85
06/03/2016	0.86	21.91	71.53	42.74	14.75
07/03/2016	0.57	15.15	56.74	60.57	5.28
08/03/2016	0.74	16.9	50.36	73.47	19.45
09/03/2016	0.49	23.19	41.24	51.02	15.05
....
10/03/2016	0.5	24.12	59.69	68.86	15.01
31/12/2016	0.39	19.34	36.41	33.71	28.18

Data aktual stasiun pemantau udara suf7 yakni wilayah Surabaya Selatan.

date	suf7_co	suf7_no2	suf7_o3	suf7_pm10	suf7_so2
01/01/2016	1.33	10.47	32.56	44.62	2.72
02/01/2016	1.11	0.95	34.28	26.17	4.69
03/01/2016	0.56	1.12	32.56	26.9	3.96
04/01/2016	1.9	8.45	89.32	38.57	2.77
05/01/2016	2.02	11.35	312.7	47.67	4.15
06/01/2016	2.03	7.38	146.19	65.4	4
07/01/2016	1.99	34.32	79.87	127.67	8.29
08/01/2016	1.43	39.13	179.63	105.23	2.73
09/01/2016	1.26	40.67	103.89	32.35	2.65
10/01/2016	1.46	45.98	56.75	62.05	2.54
11/01/2016	1.86	36.31	54.64	76.29	2.91
12/01/2016	1.41	29.84	53.64	60.81	2.6
13/01/2016	1.8	18.96	34.51	60.75	16.99
14/01/2016	1.93	18.04	21.82	55.89	16.79
15/01/2016	1.79	12.26	30.6	57.46	16.61
16/01/2016	1.67	13.05	45.94	61.64	16.92
17/01/2016	1.56	15.02	43.66	56.23	15.65
18/01/2016	1.63	14.33	40.84	43.71	16.39
19/01/2016	1.61	11.05	48.45	86.26	10.46
20/01/2016	1.8	13.46	44.3	78.21	16.65
21/01/2016	2.89	15.91	46.9	83.36	16.77
22/01/2016	1.82	15.03	38.51	73.21	16.28
23/01/2016	1.74	18.71	43.03	60.46	16.65
24/01/2016	1.71	17.32	38.07	49.52	17.06
25/01/2016	1.45	25.08	36.29	80.2	17.33
26/01/2016	1.43	21.21	45.82	76.6	17.97
27/01/2016	1.53	16.41	52.64	72.54	18.03
28/01/2016	1.7	18.63	94.65	70.59	17.71
29/01/2016	1.77	17.24	29.08	74.72	17.4
30/01/2016	1.66	14.91	57.17	18.28	17.09
31/01/2016	1.93	10.47	139.67	41.07	16.99
01/02/2016	1.59	8.89	80.39	37.47	2.62
02/02/2016	1.88	12.78	42.94	74.03	4.69
03/02/2016	0.63	22.24	22.18	53.25	3.96
04/02/2016	1.85	23.01	46.77	78.74	2.77
05/02/2016	1.56	19.96	53.39	80.7	4.15
06/02/2016	1.26	16.48	88.12	65.35	4
07/02/2016	1.41	16.61	141.09	47.19	8.29
08/02/2016	1.42	17.9	54.23	25.02	2.73
09/02/2016	1.11	14.35	195.17	55.96	2.65

date	suf7_co	suf7_no2	suf7_o3	suf7_pm10	suf7_so2
10/02/2016	1.58	20.51	56.36	68.78	2.54
11/02/2016	1.55	18.83	65.22	50.66	2.91
12/02/2016	1.47	20.34	28.86	28.19	2.6
13/02/2016	1.7	25.24	30.3	56.81	16.99
14/02/2016	1.79	23.68	39.46	44.59	16.79
15/02/2016	1.91	28.35	39.15	44.51	16.61
16/02/2016	1.96	26.56	74.64	58.08	16.92
17/02/2016	2.02	19.26	54.21	59.96	15.65
18/02/2016	2.4	36.35	64.41	69.5	16.39
19/02/2016	1.45	27.97	92.73	60.71	10.46
20/02/2016	2.5	15.37	44.3	56.8	16.65
21/02/2016	1.83	21.05	46.9	47.82	16.77
22/02/2016	1.44	15.03	115.48	45.75	16.28
23/02/2016	1.17	16.15	49.84	47	16.65
24/02/2016	1.7	24.85	109.95	67.9	17.06
25/02/2016	1.99	23.9	53.54	28.84	17.33
26/02/2016	1.57	17.88	33.62	64.83	17.97
27/02/2016	2.21	18.1	14.42	19.82	18.03
28/02/2016	2.43	19.39	23.15	37.36	17.71
29/02/2016	2.26	20.99	33.17	50.89	17.4
01/03/2016	3.01	12.54	28.72	44.62	2.72
02/03/2016	3.34	24.59	34.28	26.17	4.69
03/03/2016	3.76	24.66	32.56	26.9	3.96
04/03/2016	4.36	19.17	89.32	38.57	2.77
05/03/2016	5.82	22.87	312.7	47.67	4.15
06/03/2016	3.96	14.38	146.19	65.4	4
07/03/2016	5.39	19.42	79.87	127.67	8.29
08/03/2016	5.66	25.49	179.63	105.23	2.73
09/03/2016	3.47	17.05	103.89	32.35	2.65
10/03/2016	5.14	21.81	56.75	62.05	2.54
....
31/12/2016	0.59	15.9	52.34	58.59	19.66

LAMPIRAN B

Potongan Hasil Percobaan Model ANN untuk Model Wilayah Surabaya Pusat, Surabaya Timur, dan Surabaya Selatan

Pada lampiran B berisi hasil percobaan model *Artificial Neural Network* yang ada pada tiga stasiun pemantau udara yakni model ANN wilayah Surabaya Pusat, model ANN wilayah Surabaya Timur, model ANN wilayah Surabaya Selatan.

Model ANN Wilayah Surabaya Pusat

1. Model ANN 1 Periode 5 Nodes Input Surabaya Pusat

Hidden1	Stepmax/ epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
6	100000	logistic	0.1	29.70%	24.60%
6	200000	logistic	0.1	29.70%	24.60%
6	300000	logistic	0.1	29.70%	24.60%
6	100000	logistic	0.2	29.70%	24.60%
6	200000	logistic	0.2	29.70%	24.60%
6	300000	logistic	0.2	29.70%	24.60%
6	100000	logistic	0.3	29.70%	24.60%
6	200000	logistic	0.3	29.70%	24.60%
6	300000	logistic	0.3	29.70%	24.60%
6	100000	logistic	0.4	29.70%	24.60%
6	200000	logistic	0.4	29.70%	24.60%
6	300000	logistic	0.4	29.70%	24.60%
6	100000	logistic	0.5	29.70%	24.60%
6	200000	logistic	0.5	29.70%	24.60%
6	300000	logistic	0.5	29.70%	24.60%
6	100000	logistic	0.6	29.70%	24.60%
6	200000	logistic	0.6	29.70%	24.60%
6	300000	logistic	0.6	29.70%	24.60%
6	100000	logistic	0.7	29.70%	24.60%
6	200000	logistic	0.7	29.70%	24.60%
6	300000	logistic	0.7	29.70%	24.60%
6	100000	logistic	0.8	29.70%	24.60%
6	200000	logistic	0.8	29.70%	24.60%
6	300000	logistic	0.8	29.70%	24.60%
6	100000	logistic	0.9	29.70%	24.60%
6	200000	logistic	0.9	29.70%	24.60%
6	300000	logistic	0.9	29.70%	24.60%
5	100000	logistic	0.1	29.90%	28.80%
5	200000	logistic	0.1	29.90%	28.80%
5	300000	logistic	0.1	29.90%	28.80%
5	100000	logistic	0.2	29.90%	28.80%

Hidden1	Stepmax/ epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
5	200000	logistic	0.2	29.90%	28.80%
5	300000	logistic	0.2	29.90%	28.80%
5	100000	logistic	0.3	29.90%	28.80%
5	200000	logistic	0.3	29.90%	28.80%
5	300000	logistic	0.3	29.90%	28.80%
5	100000	logistic	0.4	29.90%	28.80%
5	200000	logistic	0.4	29.90%	28.80%
5	300000	logistic	0.4	29.90%	28.80%
5	100000	logistic	0.5	29.90%	28.80%
...
6	200000	tanh	0.9	29.40%	59.80%
6	300000	tanh	0.9	29.40%	59.80%

2. Model ANN 2 Periode 10 Nodes *Input* Surabaya Pusat

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
6	100000	logistic	0.1	28.30%	27.40%
6	200000	logistic	0.1	28.30%	27.40%
6	300000	logistic	0.1	28.30%	27.40%
6	100000	logistic	0.2	28.30%	27.40%
6	200000	logistic	0.2	28.30%	27.40%
6	300000	logistic	0.2	28.30%	27.40%
6	100000	logistic	0.3	28.30%	27.40%
6	200000	logistic	0.3	28.30%	27.40%
6	300000	logistic	0.3	28.30%	27.40%
6	100000	logistic	0.4	28.30%	27.40%
6	200000	logistic	0.4	28.30%	27.40%
6	300000	logistic	0.4	28.30%	27.40%
6	100000	logistic	0.5	28.30%	27.40%
6	200000	logistic	0.5	28.30%	27.40%
6	300000	logistic	0.5	28.30%	27.40%
6	100000	logistic	0.6	28.30%	27.40%
6	200000	logistic	0.6	28.30%	27.40%
6	300000	logistic	0.6	28.30%	27.40%
6	100000	logistic	0.7	28.30%	27.40%
6	200000	logistic	0.7	28.30%	27.40%
6	300000	logistic	0.7	28.30%	27.40%
6	100000	logistic	0.8	28.30%	27.40%
6	200000	logistic	0.8	28.30%	27.40%
6	300000	logistic	0.8	28.30%	27.40%
6	100000	logistic	0.9	28.30%	27.40%
6	200000	logistic	0.9	28.30%	27.40%

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
6	300000	logistic	0.9	28.30%	27.40%
5	100000	tanh	0.1	29%	27.60%
5	200000	tanh	0.1	29%	27.60%
5	300000	tanh	0.1	29%	27.60%
5	100000	tanh	0.2	29%	27.60%
5	200000	tanh	0.2	29%	27.60%
5	300000	tanh	0.2	29%	27.60%
5	100000	tanh	0.3	29%	27.60%
5	200000	tanh	0.3	29%	27.60%
....
1	100000	tanh	0.8	41.90%	34.50%
1	200000	tanh	0.8	41.90%	34.50%
1	300000	tanh	0.8	41.90%	34.50%
1	100000	tanh	0.9	41.90%	34.50%
1	200000	tanh	0.9	41.90%	34.50%
1	300000	tanh	0.9	41.90%	34.50%

3. Model ANN 3 Periode 15 Nodes *Input* Surabaya Pusat

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
4	100000	tanh	0.1	29.30%	29.50%
4	200000	tanh	0.1	29.30%	29.50%
4	300000	tanh	0.1	29.30%	29.50%
4	100000	tanh	0.2	29.30%	29.50%
4	200000	tanh	0.2	29.30%	29.50%
4	300000	tanh	0.2	29.30%	29.50%
4	100000	tanh	0.3	29.30%	29.50%
4	200000	tanh	0.3	29.30%	29.50%
4	300000	tanh	0.3	29.30%	29.50%
4	100000	tanh	0.4	29.30%	29.50%
4	200000	tanh	0.4	29.30%	29.50%
4	300000	tanh	0.4	29.30%	29.50%
4	100000	tanh	0.5	29.30%	29.50%
4	200000	tanh	0.5	29.30%	29.50%
4	300000	tanh	0.5	29.30%	29.50%
4	100000	tanh	0.6	29.30%	29.50%
4	200000	tanh	0.6	29.30%	29.50%
4	300000	tanh	0.6	29.30%	29.50%
4	100000	tanh	0.7	29.30%	29.50%
4	200000	tanh	0.7	29.30%	29.50%

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
4	300000	tanh	0.7	29.30%	29.50%
4	100000	tanh	0.8	29.30%	29.50%
4	200000	tanh	0.8	29.30%	29.50%
4	300000	tanh	0.8	29.30%	29.50%
4	100000	tanh	0.9	29.30%	29.50%
4	200000	tanh	0.9	29.30%	29.50%
4	300000	tanh	0.9	29.30%	29.50%
6	100000	tanh	0.1	27.50%	31.20%
6	200000	tanh	0.1	27.50%	31.20%
6	300000	tanh	0.1	27.50%	31.20%
6	100000	tanh	0.2	27.50%	31.20%
....
5	200000	logistic	0.8	28.60%	42.80%
5	300000	logistic	0.8	28.60%	42.80%
5	100000	logistic	0.9	28.60%	42.80%
5	200000	logistic	0.9	28.60%	42.80%
5	300000	logistic	0.9	28.60%	42.80%

4. Model ANN 4 Periode 20 *Nodes Input* Surabaya Pusat

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
1	100000	logistic	0.1	41.40%	34.60%
1	200000	logistic	0.1	41.40%	34.60%
1	300000	logistic	0.1	41.40%	34.60%
1	100000	logistic	0.2	41.40%	34.60%
1	200000	logistic	0.2	41.40%	34.60%
1	300000	logistic	0.2	41.40%	34.60%
1	100000	logistic	0.3	41.40%	34.60%
1	200000	logistic	0.3	41.40%	34.60%
1	300000	logistic	0.3	41.40%	34.60%
1	100000	logistic	0.4	41.40%	34.60%
....
1	100000	tanh	0.8	57.20%	43.10%
1	200000	tanh	0.8	57.20%	43.10%
1	300000	tanh	0.8	57.20%	43.10%
1	100000	tanh	0.9	57.20%	43.10%
1	200000	tanh	0.9	57.20%	43.10%
1	300000	tanh	0.9	57.20%	43.10%

5. Model ANN 5 Periode 25 *Nodes Input* Surabaya Pusat

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
6	100000	logistic	0.1	26.40%	30.40%
6	200000	logistic	0.1	26.40%	30.40%
6	300000	logistic	0.1	26.40%	30.40%
6	100000	logistic	0.2	26.40%	30.40%
6	200000	logistic	0.2	26.40%	30.40%
6	300000	logistic	0.2	26.40%	30.40%
6	100000	logistic	0.3	26.40%	30.40%
6	200000	logistic	0.3	26.40%	30.40%
6	300000	logistic	0.3	26.40%	30.40%
6	100000	logistic	0.4	26.40%	30.40%
6	200000	logistic	0.4	26.40%	30.40%
6	300000	logistic	0.4	26.40%	30.40%
....
6	200000	tanh	0.7	28%	60.40%
6	300000	tanh	0.7	28%	60.40%
6	100000	tanh	0.8	28%	60.40%
6	200000	tanh	0.8	28%	60.40%
6	300000	tanh	0.8	28%	60.40%
6	100000	tanh	0.9	28%	60.40%
6	200000	tanh	0.9	28%	60.40%
6	300000	tanh	0.9	28%	60.40%

6. Model ANN 6 Periode 30 *Nodes Input* Surabaya Pusat

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
2	100000	tanh	0.1	32.20%	34.40%
2	200000	tanh	0.1	32.20%	34.40%
2	300000	tanh	0.1	32.20%	34.40%
2	100000	tanh	0.2	32.20%	34.40%
2	200000	tanh	0.2	32.20%	34.40%
2	300000	tanh	0.2	32.20%	34.40%
2	100000	tanh	0.3	32.20%	34.40%
2	200000	tanh	0.3	32.20%	34.40%
2	300000	tanh	0.3	32.20%	34.40%
2	100000	tanh	0.4	32.20%	34.40%
2	200000	tanh	0.4	32.20%	34.40%
2	300000	tanh	0.4	32.20%	34.40%
2	100000	tanh	0.5	32.20%	34.40%

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
2	200000	tanh	0.5	32.20%	34.40%
2	300000	tanh	0.5	32.20%	34.40%
2	100000	tanh	0.6	32.20%	34.40%
2	200000	tanh	0.6	32.20%	34.40%
2	300000	tanh	0.6	32.20%	34.40%
2	100000	tanh	0.7	32.20%	34.40%
2	200000	tanh	0.7	32.20%	34.40%
2	300000	tanh	0.7	32.20%	34.40%
2	100000	tanh	0.8	32.20%	34.40%
2	200000	tanh	0.8	32.20%	34.40%
2	300000	tanh	0.8	32.20%	34.40%
2	100000	tanh	0.9	32.20%	34.40%
2	200000	tanh	0.9	32.20%	34.40%
2	300000	tanh	0.9	32.20%	34.40%
1	100000	logistic	0.1	40.50%	34.50%
2	100000	logistic	0.1	31.90%	34.50%
1	200000	logistic	0.1	40.50%	34.50%
....
1	300000	tanh	0.7	56.50%	42.80%
1	100000	tanh	0.8	56.50%	42.80%
1	200000	tanh	0.8	56.50%	42.80%
1	300000	tanh	0.8	56.50%	42.80%
1	100000	tanh	0.9	56.50%	42.80%
1	200000	tanh	0.9	56.50%	42.80%
1	300000	tanh	0.9	56.50%	42.80%

7. Model ANN 7 Periode 35 Nodes Input Surabaya Pusat

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
2	100000	tanh	0.1	32.20%	34.40%
2	200000	tanh	0.1	32.20%	34.40%
2	300000	tanh	0.1	32.20%	34.40%
2	100000	tanh	0.2	32.20%	34.40%
2	200000	tanh	0.2	32.20%	34.40%
2	300000	tanh	0.2	32.20%	34.40%
2	100000	tanh	0.3	32.20%	34.40%
2	200000	tanh	0.3	32.20%	34.40%
2	300000	tanh	0.3	32.20%	34.40%
2	100000	tanh	0.4	32.20%	34.40%
2	200000	tanh	0.4	32.20%	34.40%
2	300000	tanh	0.4	32.20%	34.40%
2	100000	tanh	0.5	32.20%	34.40%

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
2	200000	tanh	0.5	32.20%	34.40%
2	300000	tanh	0.5	32.20%	34.40%
2	100000	tanh	0.6	32.20%	34.40%
2	200000	tanh	0.6	32.20%	34.40%
2	300000	tanh	0.6	32.20%	34.40%
2	100000	tanh	0.7	32.20%	34.40%
2	200000	tanh	0.7	32.20%	34.40%
2	300000	tanh	0.7	32.20%	34.40%
2	100000	tanh	0.8	32.20%	34.40%
2	200000	tanh	0.8	32.20%	34.40%
2	300000	tanh	0.8	32.20%	34.40%
2	100000	tanh	0.9	32.20%	34.40%
2	200000	tanh	0.9	32.20%	34.40%
2	300000	tanh	0.9	32.20%	34.40%
1	100000	logistic	0.1	40.50%	34.50%
2	100000	logistic	0.1	31.90%	34.50%
1	200000	logistic	0.1	40.50%	34.50%
2	200000	logistic	0.1	31.90%	34.50%
1	300000	logistic	0.1	40.50%	34.50%
....
1	300000	tanh	0.7	56.50%	42.80%
1	100000	tanh	0.8	56.50%	42.80%
1	200000	tanh	0.8	56.50%	42.80%
1	300000	tanh	0.8	56.50%	42.80%
1	100000	tanh	0.9	56.50%	42.80%
1	200000	tanh	0.9	56.50%	42.80%
1	300000	tanh	0.9	56.50%	42.80%

8. Model ANN 8 Periode 40 Nodes Input Surabaya Pusat

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
1	100000	tanh	0.1	40.20%	33.90%
1	200000	tanh	0.1	40.20%	33.90%
1	300000	tanh	0.1	40.20%	33.90%
1	100000	tanh	0.2	40.20%	33.90%
1	200000	tanh	0.2	40.20%	33.90%
1	300000	tanh	0.2	40.20%	33.90%
1	100000	tanh	0.3	40.20%	33.90%
1	200000	tanh	0.3	40.20%	33.90%

B-8

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
1	300000	tanh	0.3	40.20%	33.90%
1	100000	tanh	0.4	40.20%	33.90%
1	200000	tanh	0.4	40.20%	33.90%
1	300000	tanh	0.4	40.20%	33.90%
1	100000	tanh	0.5	40.20%	33.90%
1	200000	tanh	0.5	40.20%	33.90%
1	300000	tanh	0.5	40.20%	33.90%
1	100000	tanh	0.6	40.20%	33.90%
1	200000	tanh	0.6	40.20%	33.90%
1	300000	tanh	0.6	40.20%	33.90%
1	100000	tanh	0.7	40.20%	33.90%
1	200000	tanh	0.7	40.20%	33.90%
1	300000	tanh	0.7	40.20%	33.90%
1	100000	tanh	0.8	40.20%	33.90%
1	200000	tanh	0.8	40.20%	33.90%
1	300000	tanh	0.8	40.20%	33.90%
1	100000	tanh	0.9	40.20%	33.90%
1	200000	tanh	0.9	40.20%	33.90%
1	300000	tanh	0.9	40.20%	33.90%
1	100000	logistic	0.1	40.40%	34.10%
1	200000	logistic	0.1	40.40%	34.10%
1	300000	logistic	0.1	40.40%	34.10%
2	100000	tanh	0.1	40.30%	34.10%
2	200000	tanh	0.1	40.30%	34.10%
2	300000	tanh	0.1	40.30%	34.10%
....
6	300000	tanh	0.5	23.70%	68.90%
6	100000	tanh	0.6	23.70%	68.90%
6	200000	tanh	0.6	23.70%	68.90%
6	300000	tanh	0.6	23.70%	68.90%
6	100000	tanh	0.7	23.70%	68.90%
6	200000	tanh	0.7	23.70%	68.90%
6	300000	tanh	0.7	23.70%	68.90%
6	100000	tanh	0.8	23.70%	68.90%
6	200000	tanh	0.8	23.70%	68.90%
6	300000	tanh	0.8	23.70%	68.90%
6	100000	tanh	0.9	23.70%	68.90%
6	200000	tanh	0.9	23.70%	68.90%
6	300000	tanh	0.9	23.70%	68.90%

9. Model ANN 9 Periode 45 *Nodes Input* Surabaya Pusat

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
2	100000	logistic	0.1	32%	34%
2	200000	logistic	0.1	32%	34%
2	300000	logistic	0.1	32%	34%
1	100000	logistic	0.1	40.30%	34.10%
1	200000	logistic	0.1	40.30%	34.10%
1	300000	logistic	0.1	40.30%	34.10%
1	100000	tanh	0.1	40.40%	34.20%
2	100000	tanh	0.1	31.90%	34.60%
5	100000	logistic	0.1	24.70%	37%
5	200000	logistic	0.1	24.70%	37%
5	300000	logistic	0.1	24.70%	37%
3	100000	tanh	0.1	31%	39.10%
....
3	100000	logistic	0.1	28.10%	42%
3	200000	logistic	0.1	28.10%	42%
3	300000	logistic	0.1	28.10%	42%
6	100000	logistic	0.1	22.10%	50.70%
6	200000	logistic	0.1	22.10%	50.70%
6	300000	logistic	0.1	22.10%	50.70%
4	100000	logistic	0.1	26.90%	56.90%
4	200000	logistic	0.1	26.90%	56.90%
4	300000	logistic	0.1	26.90%	56.90%

10. Model ANN 10 Periode 50 *Nodes Input* Surabaya Pusat

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
1	100000	logistic	0.1	40.20%	34%
1	200000	logistic	0.1	40.20%	34%
1	300000	logistic	0.1	40.20%	34%
1	100000	logistic	0.2	40.20%	34%
1	200000	logistic	0.2	40.20%	34%
1	300000	logistic	0.2	40.20%	34%
1	100000	logistic	0.3	40.20%	34%
1	200000	logistic	0.3	40.20%	34%
1	300000	logistic	0.3	40.20%	34%
1	100000	logistic	0.4	40.20%	34%
1	200000	logistic	0.4	40.20%	34%
1	300000	logistic	0.4	40.20%	34%

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
1	100000	logistic	0.5	40.20%	34%
1	200000	logistic	0.5	40.20%	34%
1	300000	logistic	0.5	40.20%	34%
1	100000	logistic	0.6	40.20%	34%
1	200000	logistic	0.6	40.20%	34%
1	300000	logistic	0.6	40.20%	34%
1	100000	logistic	0.7	40.20%	34%
1	200000	logistic	0.7	40.20%	34%
1	300000	logistic	0.7	40.20%	34%
1	100000	logistic	0.8	40.20%	34%
1	200000	logistic	0.8	40.20%	34%
1	300000	logistic	0.8	40.20%	34%
1	100000	logistic	0.9	40.20%	34%
1	200000	logistic	0.9	40.20%	34%
1	300000	logistic	0.9	40.20%	34%
1	100000	tanh	0.1	40.20%	34.30%
1	200000	tanh	0.1	40.20%	34.30%
....
3	200000	tanh	0.7	28%	52.70%
3	300000	tanh	0.7	28%	52.70%
3	100000	tanh	0.8	28%	52.70%
3	200000	tanh	0.8	28%	52.70%
3	300000	tanh	0.8	28%	52.70%
3	100000	tanh	0.9	28%	52.70%
3	200000	tanh	0.9	28%	52.70%
3	300000	tanh	0.9	28%	52.70%

Model ANN Wilayah Surabaya Timur

1. Model ANN 1 Periode 5 *Nodes Input* Surabaya Timur

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
4	100000	tanh	0.1	33.90%	34.20%
4	200000	tanh	0.1	33.90%	34.20%
4	300000	tanh	0.1	33.90%	34.20%
4	100000	tanh	0.2	33.90%	34.20%
4	200000	tanh	0.2	33.90%	34.20%
4	300000	tanh	0.2	33.90%	34.20%
4	100000	tanh	0.3	33.90%	34.20%
4	200000	tanh	0.3	33.90%	34.20%
4	300000	tanh	0.3	33.90%	34.20%
4	100000	tanh	0.4	33.90%	34.20%

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
4	200000	tanh	0.4	33.90%	34.20%
4	300000	tanh	0.4	33.90%	34.20%
4	100000	tanh	0.5	33.90%	34.20%
4	200000	tanh	0.5	33.90%	34.20%
4	300000	tanh	0.5	33.90%	34.20%
4	100000	tanh	0.6	33.90%	34.20%
4	200000	tanh	0.6	33.90%	34.20%
4	300000	tanh	0.6	33.90%	34.20%
4	100000	tanh	0.7	33.90%	34.20%
4	200000	tanh	0.7	33.90%	34.20%
4	300000	tanh	0.7	33.90%	34.20%
4	100000	tanh	0.8	33.90%	34.20%
4	200000	tanh	0.8	33.90%	34.20%
4	300000	tanh	0.8	33.90%	34.20%
4	100000	tanh	0.9	33.90%	34.20%
4	200000	tanh	0.9	33.90%	34.20%
4	300000	tanh	0.9	33.90%	34.20%
5	100000	tanh	0.1	35.20%	36.80%
5	200000	tanh	0.1	35.20%	36.80%
....
2	100000	logistic	0.8	57.70%	63.30%
2	200000	logistic	0.8	57.70%	63.30%
2	300000	logistic	0.8	57.70%	63.30%
2	100000	logistic	0.9	57.70%	63.30%
2	200000	logistic	0.9	57.70%	63.30%
2	300000	logistic	0.9	57.70%	63.30%

2. Model ANN 2 Periode 10 Nodes Input Surabaya Timur

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
1	100000	tanh	0.1	66.50%	61.20%
1	200000	tanh	0.1	66.50%	61.20%
1	300000	tanh	0.1	66.50%	61.20%
1	100000	tanh	0.2	66.50%	61.20%
1	200000	tanh	0.2	66.50%	61.20%
1	300000	tanh	0.2	66.50%	61.20%
1	100000	tanh	0.3	66.50%	61.20%
1	200000	tanh	0.3	66.50%	61.20%
1	300000	tanh	0.3	66.50%	61.20%

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
1	100000	tanh	0.4	66.50%	61.20%
1	200000	tanh	0.4	66.50%	61.20%
1	300000	tanh	0.4	66.50%	61.20%
1	100000	tanh	0.5	66.50%	61.20%
....
2	300000	tanh	0.6	57.60%	65.80%
2	100000	tanh	0.7	57.60%	65.80%
2	200000	tanh	0.7	57.60%	65.80%
2	300000	tanh	0.7	57.60%	65.80%
2	100000	tanh	0.8	57.60%	65.80%
2	200000	tanh	0.8	57.60%	65.80%
2	300000	tanh	0.8	57.60%	65.80%
2	100000	tanh	0.9	57.60%	65.80%
2	200000	tanh	0.9	57.60%	65.80%
2	300000	tanh	0.9	57.60%	65.80%

3. Model ANN 3 Periode 15 *Nodes Input* Surabaya Timur

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
1	100000	tanh	0.1	66.50%	61.20%
1	200000	tanh	0.1	66.50%	61.20%
1	300000	tanh	0.1	66.50%	61.20%
1	100000	tanh	0.2	66.50%	61.20%
1	200000	tanh	0.2	66.50%	61.20%
1	300000	tanh	0.2	66.50%	61.20%
1	100000	tanh	0.3	66.50%	61.20%
1	200000	tanh	0.3	66.50%	61.20%
1	300000	tanh	0.3	66.50%	61.20%
1	100000	tanh	0.4	66.50%	61.20%
1	200000	tanh	0.4	66.50%	61.20%
1	300000	tanh	0.4	66.50%	61.20%
1	100000	tanh	0.5	66.50%	61.20%
1	200000	tanh	0.5	66.50%	61.20%
1	300000	tanh	0.5	66.50%	61.20%
1	100000	tanh	0.6	66.50%	61.20%
1	200000	tanh	0.6	66.50%	61.20%
1	300000	tanh	0.6	66.50%	61.20%
1	100000	tanh	0.7	66.50%	61.20%
....
2	200000	tanh	0.8	57.60%	65.80%
2	300000	tanh	0.8	57.60%	65.80%
2	100000	tanh	0.9	57.60%	65.80%
2	200000	tanh	0.9	57.60%	65.80%

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
2	300000	tanh	0.9	57.60%	65.80%

4. Model ANN 4 Periode 20 *Nodes Input* Surabaya Timur

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
1	100000	logistic	0.1	67.80%	62.50%
1	200000	logistic	0.1	67.80%	62.50%
1	300000	logistic	0.1	67.80%	62.50%
1	100000	logistic	0.2	67.80%	62.50%
1	200000	logistic	0.2	67.80%	62.50%
1	300000	logistic	0.2	67.80%	62.50%
1	100000	logistic	0.3	67.80%	62.50%
1	200000	logistic	0.3	67.80%	62.50%
1	300000	logistic	0.3	67.80%	62.50%
1	100000	logistic	0.4	67.80%	62.50%
1	200000	logistic	0.4	67.80%	62.50%
1	300000	logistic	0.4	67.80%	62.50%
1	100000	logistic	0.5	67.80%	62.50%
1	200000	logistic	0.5	67.80%	62.50%
1	300000	logistic	0.5	67.80%	62.50%
1	100000	logistic	0.6	67.80%	62.50%
....
2	300000	logistic	0.7	56.30%	65.80%
2	100000	logistic	0.8	56.30%	65.80%
2	200000	logistic	0.8	56.30%	65.80%
2	300000	logistic	0.8	56.30%	65.80%
2	100000	logistic	0.9	56.30%	65.80%
2	200000	logistic	0.9	56.30%	65.80%
2	300000	logistic	0.9	56.30%	65.80%

5. Model ANN 5 Periode 25 *Nodes Input* Surabaya Timur

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
1	100000	tanh	0.1	67%	61.50%
1	200000	tanh	0.1	67%	61.50%
1	300000	tanh	0.1	67%	61.50%
1	100000	tanh	0.2	67%	61.50%
1	200000	tanh	0.2	67%	61.50%

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
1	300000	tanh	0.2	67%	61.50%
1	100000	tanh	0.3	67%	61.50%
1	200000	tanh	0.3	67%	61.50%
1	300000	tanh	0.3	67%	61.50%
1	100000	tanh	0.4	67%	61.50%
1	200000	tanh	0.4	67%	61.50%
1	300000	tanh	0.4	67%	61.50%
1	100000	tanh	0.5	67%	61.50%
1	200000	tanh	0.5	67%	61.50%
1	300000	tanh	0.5	67%	61.50%
1	100000	tanh	0.6	67%	61.50%
....
2	100000	tanh	0.7	56.50%	68.30%
2	200000	tanh	0.7	56.50%	68.30%
2	300000	tanh	0.7	56.50%	68.30%
2	100000	tanh	0.8	56.50%	68.30%
2	200000	tanh	0.8	56.50%	68.30%
2	300000	tanh	0.8	56.50%	68.30%
2	100000	tanh	0.9	56.50%	68.30%
2	200000	tanh	0.9	56.50%	68.30%
2	300000	tanh	0.9	56.50%	68.30%

6. Model ANN 6 Periode 30 Nodes *Input* Surabaya Timur

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
3	100000	tanh	0.1	41.80%	57%
3	200000	tanh	0.1	41.80%	57%
3	300000	tanh	0.1	41.80%	57%
3	100000	tanh	0.2	41.80%	57%
3	200000	tanh	0.2	41.80%	57%
3	300000	tanh	0.2	41.80%	57%
3	100000	tanh	0.3	41.80%	57%
3	200000	tanh	0.3	41.80%	57%
....
2	200000	logistic	0.7	56.70%	67.50%
2	300000	logistic	0.7	56.70%	67.50%
2	100000	logistic	0.8	56.70%	67.50%
2	200000	logistic	0.8	56.70%	67.50%
2	300000	logistic	0.8	56.70%	67.50%
2	100000	logistic	0.9	56.70%	67.50%
2	200000	logistic	0.9	56.70%	67.50%
2	300000	logistic	0.9	56.70%	67.50%

7. Model ANN 7 Periode 35 *Nodes Input* Surabaya Timur

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
3	100000	logistic	0.1	43.40%	59.20%
3	200000	logistic	0.1	43.40%	59.20%
3	300000	logistic	0.1	43.40%	59.20%
3	100000	logistic	0.2	43.40%	59.20%
3	200000	logistic	0.2	43.40%	59.20%
3	300000	logistic	0.2	43.40%	59.20%
3	100000	logistic	0.3	43.40%	59.20%
3	200000	logistic	0.3	43.40%	59.20%
3	300000	logistic	0.3	43.40%	59.20%
3	100000	logistic	0.4	43.40%	59.20%
3	200000	logistic	0.4	43.40%	59.20%
3	300000	logistic	0.4	43.40%	59.20%
3	100000	logistic	0.5	43.40%	59.20%
3	200000	logistic	0.5	43.40%	59.20%
3	300000	logistic	0.5	43.40%	59.20%
3	100000	logistic	0.6	43.40%	59.20%
3	200000	logistic	0.6	43.40%	59.20%
3	300000	logistic	0.6	43.40%	59.20%
....
2	300000	logistic	0.6	58.70%	73.10%
2	100000	logistic	0.7	58.70%	73.10%
2	200000	logistic	0.7	58.70%	73.10%
2	300000	logistic	0.7	58.70%	73.10%
2	100000	logistic	0.8	58.70%	73.10%
2	200000	logistic	0.8	58.70%	73.10%
2	300000	logistic	0.8	58.70%	73.10%
2	100000	logistic	0.9	58.70%	73.10%
2	200000	logistic	0.9	58.70%	73.10%
2	300000	logistic	0.9	58.70%	73.10%

8. Model ANN 8 Periode 40 *Nodes Input* Surabaya Timur

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
3	100000	logistic	0.1	39.30%	55.30%
3	200000	logistic	0.1	39.30%	55.30%
3	300000	logistic	0.1	39.30%	55.30%
3	100000	logistic	0.2	39.30%	55.30%
3	200000	logistic	0.2	39.30%	55.30%

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
3	300000	logistic	0.2	39.30%	55.30%
3	100000	logistic	0.3	39.30%	55.30%
3	200000	logistic	0.3	39.30%	55.30%
3	300000	logistic	0.3	39.30%	55.30%
3	100000	logistic	0.4	39.30%	55.30%
3	200000	logistic	0.4	39.30%	55.30%
3	300000	logistic	0.4	39.30%	55.30%
3	100000	logistic	0.5	39.30%	55.30%
3	200000	logistic	0.5	39.30%	55.30%
....
6	100000	tanh	0.7	43.30%	101%
6	200000	tanh	0.7	43.30%	101%
6	300000	tanh	0.7	43.30%	101%
6	100000	tanh	0.8	43.30%	101%
6	200000	tanh	0.8	43.30%	101%
6	300000	tanh	0.8	43.30%	101%
6	100000	tanh	0.9	43.30%	101%
6	200000	tanh	0.9	43.30%	101%
6	300000	tanh	0.9	43.30%	101%

9. Model ANN 9 Periode 45 *Nodes Input* Surabaya Timur

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
5	100000	logistic	0.1	33.50%	55.40%
5	200000	logistic	0.1	33.50%	55.40%
5	300000	logistic	0.1	33.50%	55.40%
5	100000	logistic	0.2	33.50%	55.40%
5	200000	logistic	0.2	33.50%	55.40%
5	300000	logistic	0.2	33.50%	55.40%
5	100000	logistic	0.3	33.50%	55.40%
5	200000	logistic	0.3	33.50%	55.40%
5	300000	logistic	0.3	33.50%	55.40%
5	100000	logistic	0.4	33.50%	55.40%
5	200000	logistic	0.4	33.50%	55.40%
5	300000	logistic	0.4	33.50%	55.40%
5	100000	logistic	0.5	33.50%	55.40%
5	200000	logistic	0.5	33.50%	55.40%
5	300000	logistic	0.5	33.50%	55.40%
5	100000	logistic	0.6	33.50%	55.40%
5	200000	logistic	0.6	33.50%	55.40%
5	300000	logistic	0.6	33.50%	55.40%
5	100000	logistic	0.7	33.50%	55.40%

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
5	200000	logistic	0.7	33.50%	55.40%
5	300000	logistic	0.7	33.50%	55.40%
5	100000	logistic	0.8	33.50%	55.40%
5	200000	logistic	0.8	33.50%	55.40%
5	300000	logistic	0.8	33.50%	55.40%
5	100000	logistic	0.9	33.50%	55.40%
5	200000	logistic	0.9	33.50%	55.40%
5	300000	logistic	0.9	33.50%	55.40%
3	100000	logistic	0.1	44.10%	56%
3	200000	logistic	0.1	44.10%	56%
3	300000	logistic	0.1	44.10%	56%
3	100000	logistic	0.2	44.10%	56%
3	200000	logistic	0.2	44.10%	56%
....

10. Model ANN 10 Periode 50 *Nodes Input* Surabaya Timur

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
4	100000	tanh	0.1	34.90%	58.10%
4	200000	tanh	0.1	34.90%	58.10%
4	300000	tanh	0.1	34.90%	58.10%
4	100000	tanh	0.2	34.90%	58.10%
4	200000	tanh	0.2	34.90%	58.10%
4	300000	tanh	0.2	34.90%	58.10%
4	100000	tanh	0.3	34.90%	58.10%
4	200000	tanh	0.3	34.90%	58.10%
4	300000	tanh	0.3	34.90%	58.10%
4	100000	tanh	0.4	34.90%	58.10%
4	200000	tanh	0.4	34.90%	58.10%
4	300000	tanh	0.4	34.90%	58.10%
4	100000	tanh	0.5	34.90%	58.10%
4	200000	tanh	0.5	34.90%	58.10%
4	300000	tanh	0.5	34.90%	58.10%
4	100000	tanh	0.6	34.90%	58.10%
4	200000	tanh	0.6	34.90%	58.10%
4	300000	tanh	0.6	34.90%	58.10%
4	100000	tanh	0.7	34.90%	58.10%
4	200000	tanh	0.7	34.90%	58.10%
4	300000	tanh	0.7	34.90%	58.10%

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
1	200000	tanh	0.4	67.80%	63.20%
1	300000	tanh	0.4	67.80%	63.20%
1	100000	tanh	0.5	67.80%	63.20%
1	200000	tanh	0.5	67.80%	63.20%
1	300000	tanh	0.5	67.80%	63.20%
1	100000	tanh	0.6	67.80%	63.20%
1	200000	tanh	0.6	67.80%	63.20%
1	300000	tanh	0.6	67.80%	63.20%
1	100000	tanh	0.7	67.80%	63.20%
1	200000	tanh	0.7	67.80%	63.20%
1	300000	tanh	0.7	67.80%	63.20%
1	100000	tanh	0.8	67.80%	63.20%
1	200000	tanh	0.8	67.80%	63.20%
1	300000	tanh	0.8	67.80%	63.20%
1	100000	tanh	0.9	67.80%	63.20%
1	200000	tanh	0.9	67.80%	63.20%
1	300000	tanh	0.9	67.80%	63.20%
4	100000	logistic	0.1	37.20%	64.20%
4	200000	logistic	0.1	37.20%	64.20%
4	300000	logistic	0.1	37.20%	64.20%
4	100000	logistic	0.2	37.20%	64.20%
4	200000	logistic	0.2	37.20%	64.20%
4	300000	logistic	0.2	37.20%	64.20%
4	100000	logistic	0.3	37.20%	64.20%
4	200000	logistic	0.3	37.20%	64.20%
4	300000	logistic	0.3	37.20%	64.20%
4	100000	logistic	0.4	37.20%	64.20%
4	200000	logistic	0.4	37.20%	64.20%
4	300000	logistic	0.4	37.20%	64.20%
4	100000	logistic	0.5	37.20%	64.20%
4	200000	logistic	0.5	37.20%	64.20%
4	300000	logistic	0.5	37.20%	64.20%
4	100000	logistic	0.6	37.20%	64.20%
4	200000	logistic	0.6	37.20%	64.20%
4	300000	logistic	0.6	37.20%	64.20%
4	100000	logistic	0.7	37.20%	64.20%
4	200000	logistic	0.7	37.20%	64.20%
4	300000	logistic	0.7	37.20%	64.20%
4	100000	logistic	0.8	37.20%	64.20%
4	200000	logistic	0.8	37.20%	64.20%
4	300000	logistic	0.8	37.20%	64.20%
4	100000	logistic	0.9	37.20%	64.20%

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
4	200000	logistic	0.9	37.20%	64.20%
4	300000	logistic	0.9	37.20%	64.20%
2	100000	tanh	0.1	60.90%	68.20%
....
6	100000	logistic	0.8	36.70%	171%
6	200000	logistic	0.8	36.70%	171%
6	300000	logistic	0.8	36.70%	171%
6	100000	logistic	0.9	36.70%	171%
6	200000	logistic	0.9	36.70%	171%
6	300000	logistic	0.9	36.70%	171%

Model ANN Wilayah Surabaya Selatan

1. Model ANN 1 Periode 5 *Nodes Input* Surabaya Selatan

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
6	100000	logistic	0.1	30.40%	34%
6	200000	logistic	0.1	30.40%	34%
6	300000	logistic	0.1	30.40%	34%
6	100000	logistic	0.2	30.40%	34%
6	200000	logistic	0.2	30.40%	34%
6	300000	logistic	0.2	30.40%	34%
6	100000	logistic	0.3	30.40%	34%
6	200000	logistic	0.3	30.40%	34%
6	300000	logistic	0.3	30.40%	34%
6	100000	logistic	0.4	30.40%	34%
6	200000	logistic	0.4	30.40%	34%
6	300000	logistic	0.4	30.40%	34%
6	100000	logistic	0.5	30.40%	34%
6	200000	logistic	0.5	30.40%	34%
6	300000	logistic	0.5	30.40%	34%
6	100000	logistic	0.6	30.40%	34%
6	200000	logistic	0.6	30.40%	34%
6	300000	logistic	0.6	30.40%	34%
6	100000	logistic	0.7	30.40%	34%
6	200000	logistic	0.7	30.40%	34%
6	300000	logistic	0.7	30.40%	34%
6	100000	logistic	0.8	30.40%	34%
6	200000	logistic	0.8	30.40%	34%

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
6	300000	logistic	0.8	30.40%	34%
6	100000	logistic	0.9	30.40%	34%
6	200000	logistic	0.9	30.40%	34%
6	300000	logistic	0.9	30.40%	34%
4	100000	logistic	0.1	32.10%	35.20%
4	200000	logistic	0.1	32.10%	35.20%
4	300000	logistic	0.1	32.10%	35.20%
4	100000	logistic	0.2	32.10%	35.20%
4	200000	logistic	0.2	32.10%	35.20%
4	300000	logistic	0.2	32.10%	35.20%
....
1	100000	logistic	0.8	44.60%	58.50%
1	200000	logistic	0.8	44.60%	58.50%
1	300000	logistic	0.8	44.60%	58.50%
1	100000	tanh	0.8	44.60%	58.50%
1	200000	tanh	0.8	44.60%	58.50%
1	300000	tanh	0.8	44.60%	58.50%
1	100000	logistic	0.9	44.60%	58.50%
1	200000	logistic	0.9	44.60%	58.50%
1	300000	logistic	0.9	44.60%	58.50%
1	100000	tanh	0.9	44.60%	58.50%
1	200000	tanh	0.9	44.60%	58.50%
1	300000	tanh	0.9	44.60%	58.50%

2. Model ANN 2 Periode 10 *Nodes Input* Surabaya Selatan

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
5	100000	logistic	0.1	29.30%	36.10%
5	200000	logistic	0.1	29.30%	36.10%
5	300000	logistic	0.1	29.30%	36.10%
5	100000	logistic	0.2	29.30%	36.10%
5	200000	logistic	0.2	29.30%	36.10%
5	300000	logistic	0.2	29.30%	36.10%
5	100000	logistic	0.3	29.30%	36.10%
5	200000	logistic	0.3	29.30%	36.10%
5	300000	logistic	0.3	29.30%	36.10%
5	100000	logistic	0.4	29.30%	36.10%
5	200000	logistic	0.4	29.30%	36.10%
5	300000	logistic	0.4	29.30%	36.10%
5	100000	logistic	0.5	29.30%	36.10%
5	200000	logistic	0.5	29.30%	36.10%

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
5	300000	logistic	0.5	29.30%	36.10%
5	100000	logistic	0.6	29.30%	36.10%
5	200000	logistic	0.6	29.30%	36.10%
5	300000	logistic	0.6	29.30%	36.10%
5	100000	logistic	0.7	29.30%	36.10%
5	200000	logistic	0.7	29.30%	36.10%
5	300000	logistic	0.7	29.30%	36.10%
5	100000	logistic	0.8	29.30%	36.10%
5	200000	logistic	0.8	29.30%	36.10%
5	300000	logistic	0.8	29.30%	36.10%
5	100000	logistic	0.9	29.30%	36.10%
5	200000	logistic	0.9	29.30%	36.10%
5	300000	logistic	0.9	29.30%	36.10%
6	100000	logistic	0.1	28.70%	36.90%
6	200000	logistic	0.1	28.70%	36.90%
6	300000	logistic	0.1	28.70%	36.90%
6	100000	logistic	0.2	28.70%	36.90%
6	200000	logistic	0.2	28.70%	36.90%
1	100000	tanh	0.7	43.10%	58.10%
1	200000	tanh	0.7	43.10%	58.10%
1	300000	tanh	0.7	43.10%	58.10%
1	100000	tanh	0.8	43.10%	58.10%
1	200000	tanh	0.8	43.10%	58.10%
1	300000	tanh	0.8	43.10%	58.10%
1	100000	tanh	0.9	43.10%	58.10%
1	200000	tanh	0.9	43.10%	58.10%
1	300000	tanh	0.9	43.10%	58.10%

3. Model ANN 3 Periode 15 *Nodes Input* Surabaya Selatan

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
5	100000	tanh	0.1	27.60%	31.30%
5	200000	tanh	0.1	27.60%	31.30%
5	300000	tanh	0.1	27.60%	31.30%
5	100000	tanh	0.2	27.60%	31.30%
5	200000	tanh	0.2	27.60%	31.30%
5	300000	tanh	0.2	27.60%	31.30%
5	100000	tanh	0.3	27.60%	31.30%
5	200000	tanh	0.3	27.60%	31.30%

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
5	300000	tanh	0.3	27.60%	31.30%
5	100000	tanh	0.4	27.60%	31.30%
5	200000	tanh	0.4	27.60%	31.30%
5	300000	tanh	0.4	27.60%	31.30%
5	100000	tanh	0.5	27.60%	31.30%
5	200000	tanh	0.5	27.60%	31.30%
5	300000	tanh	0.5	27.60%	31.30%
5	100000	tanh	0.6	27.60%	31.30%
5	200000	tanh	0.6	27.60%	31.30%
5	300000	tanh	0.6	27.60%	31.30%
5	100000	tanh	0.7	27.60%	31.30%
5	200000	tanh	0.7	27.60%	31.30%
5	300000	tanh	0.7	27.60%	31.30%
5	100000	tanh	0.8	27.60%	31.30%
5	200000	tanh	0.8	27.60%	31.30%
5	300000	tanh	0.8	27.60%	31.30%
5	100000	tanh	0.9	27.60%	31.30%
5	200000	tanh	0.9	27.60%	31.30%
5	300000	tanh	0.9	27.60%	31.30%
....
4	100000	logistic	0.1	29.30%	36.60%
4	200000	logistic	0.1	29.30%	36.60%
4	300000	logistic	0.1	29.30%	36.60%
4	100000	logistic	0.2	29.30%	36.60%
4	200000	logistic	0.2	29.30%	36.60%
4	300000	logistic	0.2	29.30%	36.60%
4	100000	logistic	0.3	29.30%	36.60%
4	200000	logistic	0.3	29.30%	36.60%
4	300000	logistic	0.3	29.30%	36.60%
4	100000	logistic	0.4	29.30%	36.60%
4	200000	logistic	0.4	29.30%	36.60%
4	300000	logistic	0.4	29.30%	36.60%
4	100000	logistic	0.5	29.30%	36.60%
4	200000	logistic	0.5	29.30%	36.60%
4	300000	logistic	0.5	29.30%	36.60%
4	100000	logistic	0.6	29.30%	36.60%
4	200000	logistic	0.6	29.30%	36.60%
4	300000	logistic	0.6	29.30%	36.60%
4	100000	logistic	0.7	29.30%	36.60%
4	200000	logistic	0.7	29.30%	36.60%
4	300000	logistic	0.7	29.30%	36.60%
4	100000	logistic	0.8	29.30%	36.60%

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
4	200000	logistic	0.8	29.30%	36.60%
4	300000	logistic	0.8	29.30%	36.60%
4	100000	logistic	0.9	29.30%	36.60%
4	200000	logistic	0.9	29.30%	36.60%
4	300000	logistic	0.9	29.30%	36.60%
4	100000	tanh	0.1	29.40%	38.40%
4	200000	tanh	0.1	29.40%	38.40%
....
1	300000	logistic	0.6	41%	59.90%
1	100000	logistic	0.7	41%	59.90%
1	200000	logistic	0.7	41%	59.90%
1	300000	logistic	0.7	41%	59.90%
1	100000	logistic	0.8	41%	59.90%
1	200000	logistic	0.8	41%	59.90%
1	300000	logistic	0.8	41%	59.90%
1	100000	logistic	0.9	41%	59.90%
1	200000	logistic	0.9	41%	59.90%
1	300000	logistic	0.9	41%	59.90%

4. Model ANN 4 Periode 20 Nodes Input Surabaya Selatan

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
3	100000	logistic	0.1	32%	48.40%
3	200000	logistic	0.1	32%	48.40%
3	300000	logistic	0.1	32%	48.40%
3	100000	logistic	0.2	32%	48.40%
3	200000	logistic	0.2	32%	48.40%
3	300000	logistic	0.2	32%	48.40%
3	100000	logistic	0.3	32%	48.40%
3	200000	logistic	0.3	32%	48.40%
3	300000	logistic	0.3	32%	48.40%
3	100000	logistic	0.4	32%	48.40%
3	200000	logistic	0.4	32%	48.40%
3	300000	logistic	0.4	32%	48.40%
3	100000	logistic	0.5	32%	48.40%
3	200000	logistic	0.5	32%	48.40%
3	300000	logistic	0.5	32%	48.40%
3	100000	logistic	0.6	32%	48.40%
3	200000	logistic	0.6	32%	48.40%

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
3	300000	logistic	0.6	32%	48.40%
3	100000	logistic	0.7	32%	48.40%
3	200000	logistic	0.7	32%	48.40%
3	300000	logistic	0.7	32%	48.40%
3	100000	logistic	0.8	32%	48.40%
3	200000	logistic	0.8	32%	48.40%
3	300000	logistic	0.8	32%	48.40%
3	100000	logistic	0.9	32%	48.40%
3	200000	logistic	0.9	32%	48.40%
3	300000	logistic	0.9	32%	48.40%
4	100000	tanh	0.1	30.90%	49.20%
4	200000	tanh	0.1	30.90%	49.20%
4	300000	tanh	0.1	30.90%	49.20%
....
1	200000	tanh	0.6	46.90%	69.80%
1	300000	tanh	0.6	46.90%	69.80%
1	100000	tanh	0.7	46.90%	69.80%
1	200000	tanh	0.7	46.90%	69.80%
1	300000	tanh	0.7	46.90%	69.80%
1	100000	tanh	0.8	46.90%	69.80%
1	200000	tanh	0.8	46.90%	69.80%
1	300000	tanh	0.8	46.90%	69.80%
1	100000	tanh	0.9	46.90%	69.80%
1	200000	tanh	0.9	46.90%	69.80%
1	300000	tanh	0.9	46.90%	69.80%

5. Model ANN 5 Periode 25 Nodes Input Surabaya Selatan

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
5	100000	logistic	0.1	27%	36.10%
5	200000	logistic	0.1	27%	36.10%
5	300000	logistic	0.1	27%	36.10%
5	100000	logistic	0.2	27%	36.10%
5	200000	logistic	0.2	27%	36.10%
5	300000	logistic	0.2	27%	36.10%
5	100000	logistic	0.3	27%	36.10%
5	200000	logistic	0.3	27%	36.10%
5	300000	logistic	0.3	27%	36.10%
5	100000	logistic	0.4	27%	36.10%
5	200000	logistic	0.4	27%	36.10%
5	300000	logistic	0.4	27%	36.10%
5	100000	logistic	0.5	27%	36.10%

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
5	200000	logistic	0.5	27%	36.10%
5	300000	logistic	0.5	27%	36.10%
5	100000	logistic	0.6	27%	36.10%
5	200000	logistic	0.6	27%	36.10%
5	300000	logistic	0.6	27%	36.10%
5	100000	logistic	0.7	27%	36.10%
5	200000	logistic	0.7	27%	36.10%
5	300000	logistic	0.7	27%	36.10%
5	100000	logistic	0.8	27%	36.10%
5	200000	logistic	0.8	27%	36.10%
5	300000	logistic	0.8	27%	36.10%
5	100000	logistic	0.9	27%	36.10%
5	200000	logistic	0.9	27%	36.10%
5	300000	logistic	0.9	27%	36.10%
6	100000	logistic	0.1	25.90%	39.40%
6	200000	logistic	0.1	25.90%	39.40%
6	300000	logistic	0.1	25.90%	39.40%
6	100000	logistic	0.2	25.90%	39.40%
6	200000	logistic	0.2	25.90%	39.40%
6	300000	logistic	0.2	25.90%	39.40%
6	100000	logistic	0.3	25.90%	39.40%
....
2	200000	logistic	0.7	34.90%	59.50%
2	300000	logistic	0.7	34.90%	59.50%
2	100000	logistic	0.8	34.90%	59.50%
2	200000	logistic	0.8	34.90%	59.50%
2	300000	logistic	0.8	34.90%	59.50%
2	100000	logistic	0.9	34.90%	59.50%
2	200000	logistic	0.9	34.90%	59.50%
2	300000	logistic	0.9	34.90%	59.50%

6. Model ANN 6 Periode 30 *Nodes Input* Surabaya Selatan

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
4	100000	logistic	0.1	28%	35.70%
4	200000	logistic	0.1	28%	35.70%
4	300000	logistic	0.1	28%	35.70%
4	100000	logistic	0.2	28%	35.70%
4	200000	logistic	0.2	28%	35.70%

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
4	300000	logistic	0.2	28%	35.70%
4	100000	logistic	0.3	28%	35.70%
4	200000	logistic	0.3	28%	35.70%
4	300000	logistic	0.3	28%	35.70%
4	100000	logistic	0.4	28%	35.70%
4	200000	logistic	0.4	28%	35.70%
4	300000	logistic	0.4	28%	35.70%
4	100000	logistic	0.5	28%	35.70%
4	200000	logistic	0.5	28%	35.70%
4	300000	logistic	0.5	28%	35.70%
4	100000	logistic	0.6	28%	35.70%
4	200000	logistic	0.6	28%	35.70%
4	300000	logistic	0.6	28%	35.70%
4	100000	logistic	0.7	28%	35.70%
4	200000	logistic	0.7	28%	35.70%
4	300000	logistic	0.7	28%	35.70%
4	100000	logistic	0.8	28%	35.70%
4	200000	logistic	0.8	28%	35.70%
4	300000	logistic	0.8	28%	35.70%
4	100000	logistic	0.9	28%	35.70%
4	200000	logistic	0.9	28%	35.70%
4	300000	logistic	0.9	28%	35.70%
4	100000	tanh	0.1	28.40%	51.60%
4	200000	tanh	0.1	28.40%	51.60%
4	300000	tanh	0.1	28.40%	51.60%
....
1	300000	logistic	0.6	39.90%	59.20%
1	100000	logistic	0.7	39.90%	59.20%
1	200000	logistic	0.7	39.90%	59.20%
1	300000	logistic	0.7	39.90%	59.20%
1	100000	logistic	0.8	39.90%	59.20%
1	200000	logistic	0.8	39.90%	59.20%
1	300000	logistic	0.8	39.90%	59.20%
1	100000	logistic	0.9	39.90%	59.20%
1	200000	logistic	0.9	39.90%	59.20%
1	300000	logistic	0.9	39.90%	59.20%

7. Model ANN 7 Periode 35 Nodes *Input* Surabaya Selatan

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
3	100000	tanh	0.1	29.90%	48.10%
3	100000	logistic	0.1	30.10%	52.70%

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
3	200000	logistic	0.1	30.10%	52.70%
3	300000	logistic	0.1	30.10%	52.70%
4	100000	logistic	0.1	27.50%	53.30%
4	200000	logistic	0.1	27.50%	53.30%
4	300000	logistic	0.1	27.50%	53.30%
1	100000	logistic	0.1	39.80%	58.10%
1	200000	logistic	0.1	39.80%	58.10%
1	300000	logistic	0.1	39.80%	58.10%
1	100000	tanh	0.1	39.80%	58.10%
2	100000	logistic	0.1	34.30%	59.90%
2	200000	logistic	0.1	34.30%	59.90%
2	300000	logistic	0.1	34.30%	59.90%
2	100000	tanh	0.1	35%	60.30%

8. Model ANN 8 Periode 40 *Nodes Input* Surabaya Selatan

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
3	100000	tanh	0.1	28.90%	51.90%
3	200000	tanh	0.1	28.90%	51.90%
3	300000	tanh	0.1	28.90%	51.90%
3	100000	tanh	0.2	28.90%	51.90%
3	200000	tanh	0.2	28.90%	51.90%
3	300000	tanh	0.2	28.90%	51.90%
3	100000	tanh	0.3	28.90%	51.90%
3	200000	tanh	0.3	28.90%	51.90%
3	300000	tanh	0.3	28.90%	51.90%
3	100000	tanh	0.4	28.90%	51.90%
3	200000	tanh	0.4	28.90%	51.90%
3	300000	tanh	0.4	28.90%	51.90%
3	100000	tanh	0.5	28.90%	51.90%
3	200000	tanh	0.5	28.90%	51.90%
3	300000	tanh	0.5	28.90%	51.90%
3	100000	tanh	0.6	28.90%	51.90%
3	200000	tanh	0.6	28.90%	51.90%
3	300000	tanh	0.6	28.90%	51.90%
3	100000	tanh	0.7	28.90%	51.90%
3	200000	tanh	0.7	28.90%	51.90%
3	300000	tanh	0.7	28.90%	51.90%
3	100000	tanh	0.8	28.90%	51.90%

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
3	200000	tanh	0.8	28.90%	51.90%
1	200000	tanh	0.7	39.30%	57.90%
1	300000	tanh	0.7	39.30%	57.90%
1	100000	tanh	0.8	39.30%	57.90%
1	200000	tanh	0.8	39.30%	57.90%
1	300000	tanh	0.8	39.30%	57.90%
1	100000	tanh	0.9	39.30%	57.90%
1	200000	tanh	0.9	39.30%	57.90%
1	300000	tanh	0.9	39.30%	57.90%
2	100000	logistic	0.1	34.10%	59.60%
2	200000	logistic	0.1	34.10%	59.60%
2	300000	logistic	0.1	34.10%	59.60%
2	100000	logistic	0.2	34.10%	59.60%
2	200000	logistic	0.2	34.10%	59.60%
2	300000	logistic	0.2	34.10%	59.60%
2	100000	logistic	0.3	34.10%	59.60%
2	200000	logistic	0.3	34.10%	59.60%
2	300000	logistic	0.3	34.10%	59.60%
2	100000	logistic	0.4	34.10%	59.60%
2	200000	logistic	0.4	34.10%	59.60%
2	300000	logistic	0.4	34.10%	59.60%
2	100000	logistic	0.5	34.10%	59.60%
2	200000	logistic	0.5	34.10%	59.60%
2	300000	logistic	0.5	34.10%	59.60%
2	100000	logistic	0.6	34.10%	59.60%
2	200000	logistic	0.6	34.10%	59.60%
....
2	300000	tanh	0.5	38.10%	60.50%
2	100000	tanh	0.6	38.10%	60.50%
2	200000	tanh	0.6	38.10%	60.50%
2	300000	tanh	0.6	38.10%	60.50%
2	100000	tanh	0.7	38.10%	60.50%
2	200000	tanh	0.7	38.10%	60.50%
2	300000	tanh	0.7	38.10%	60.50%
2	100000	tanh	0.8	38.10%	60.50%
2	200000	tanh	0.8	38.10%	60.50%
2	300000	tanh	0.8	38.10%	60.50%
2	100000	tanh	0.9	38.10%	60.50%
2	200000	tanh	0.9	38.10%	60.50%
2	300000	tanh	0.9	38.10%	60.50%

9. Model ANN 9 Periode 45 *Nodes Input* Surabaya Selatan

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
3	100000	logistic	0.1	28.20%	45.30%
3	200000	logistic	0.1	28.20%	45.30%
3	300000	logistic	0.1	28.20%	45.30%
3	100000	logistic	0.2	28.20%	45.30%
3	200000	logistic	0.2	28.20%	45.30%
3	300000	logistic	0.2	28.20%	45.30%
3	100000	logistic	0.3	28.20%	45.30%
3	200000	logistic	0.3	28.20%	45.30%
3	300000	logistic	0.3	28.20%	45.30%
3	100000	logistic	0.4	28.20%	45.30%
3	200000	logistic	0.4	28.20%	45.30%
3	300000	logistic	0.4	28.20%	45.30%
3	100000	logistic	0.5	28.20%	45.30%
3	200000	logistic	0.5	28.20%	45.30%
3	300000	logistic	0.5	28.20%	45.30%
3	100000	logistic	0.6	28.20%	45.30%
3	200000	logistic	0.6	28.20%	45.30%
3	300000	logistic	0.6	28.20%	45.30%
3	100000	logistic	0.7	28.20%	45.30%
3	200000	logistic	0.7	28.20%	45.30%
3	300000	logistic	0.7	28.20%	45.30%
3	100000	logistic	0.8	28.20%	45.30%
3	200000	logistic	0.8	28.20%	45.30%
3	300000	logistic	0.8	28.20%	45.30%
3	100000	logistic	0.9	28.20%	45.30%
3	200000	logistic	0.9	28.20%	45.30%
3	300000	logistic	0.9	28.20%	45.30%
3	100000	tanh	0.1	28.60%	45.60%
3	200000	tanh	0.1	28.60%	45.60%
3	300000	tanh	0.1	28.60%	45.60%
3	100000	tanh	0.2	28.60%	45.60%
3	200000	tanh	0.2	28.60%	45.60%
3	300000	tanh	0.2	28.60%	45.60%
3	100000	tanh	0.3	28.60%	45.60%
....
1	100000	logistic	0.6	38.30%	57.70%
1	200000	logistic	0.6	38.30%	57.70%
1	300000	logistic	0.6	38.30%	57.70%

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
1	100000	logistic	0.7	38.30%	57.70%
1	200000	logistic	0.7	38.30%	57.70%
1	300000	logistic	0.7	38.30%	57.70%
1	100000	logistic	0.8	38.30%	57.70%
1	200000	logistic	0.8	38.30%	57.70%
1	300000	logistic	0.8	38.30%	57.70%
1	100000	logistic	0.9	38.30%	57.70%
1	200000	logistic	0.9	38.30%	57.70%
1	300000	logistic	0.9	38.30%	57.70%

10. Model ANN 10 Periode 50 *Nodes Input* Surabaya Selatan

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
2	100000	logistic	0.1	32.80%	56.80%
2	200000	logistic	0.1	32.80%	56.80%
2	300000	logistic	0.1	32.80%	56.80%
2	100000	logistic	0.2	32.80%	56.80%
2	200000	logistic	0.2	32.80%	56.80%
2	300000	logistic	0.2	32.80%	56.80%
2	100000	logistic	0.3	32.80%	56.80%
2	200000	logistic	0.3	32.80%	56.80%
2	300000	logistic	0.3	32.80%	56.80%
2	100000	logistic	0.4	32.80%	56.80%
2	200000	logistic	0.4	32.80%	56.80%
2	300000	logistic	0.4	32.80%	56.80%
2	100000	logistic	0.5	32.80%	56.80%
2	200000	logistic	0.5	32.80%	56.80%
2	300000	logistic	0.5	32.80%	56.80%
2	100000	logistic	0.6	32.80%	56.80%
2	200000	logistic	0.6	32.80%	56.80%
2	300000	logistic	0.6	32.80%	56.80%
....
2	300000	tanh	0.5	38.40%	58.70%
2	100000	tanh	0.6	38.40%	58.70%
2	200000	tanh	0.6	38.40%	58.70%
2	300000	tanh	0.6	38.40%	58.70%
2	100000	tanh	0.7	38.40%	58.70%
2	200000	tanh	0.7	38.40%	58.70%
2	300000	tanh	0.7	38.40%	58.70%
2	100000	tanh	0.8	38.40%	58.70%
2	200000	tanh	0.8	38.40%	58.70%
2	300000	tanh	0.8	38.40%	58.70%

Hidden1	Stepmax/epoch	Fungsi Aktivasi	Lrate	MAPE.train	MAPE.test
2	100000	tanh	0.9	38.40%	58.70%
2	200000	tanh	0.9	38.40%	58.70%
2	300000	tanh	0.9	38.40%	58.70%

LAMPIRAN C

Potongan Hasil Peramalan ANN untuk Wilayah Surabaya Pusat, Surabaya Timur, dan Surabaya Selatan

Hasil Peramalan Unsur Polutan Udara Stasiun Pemantau Udara
Wilayah Surabaya Pusat

Tanggal	forecast_CO	forecast_NO ₂	forecast_O ₃	forecast_PM ₁₀	forecast_SO ₂
01/01/2017	0.29	5.87	12.17	19.73	18.50
02/01/2017	0.29	6.87	12.10	22.20	18.50
03/01/2017	0.28	7.47	12.05	23.59	18.50
04/01/2017	0.28	7.81	12.03	24.36	18.50
05/01/2017	0.28	8.01	12.01	24.78	18.49
06/01/2017	0.28	8.12	12.01	25.01	18.48
07/01/2017	0.28	8.19	12.01	25.13	18.47
08/01/2017	0.28	8.23	12.02	25.19	18.46
09/01/2017	0.28	8.25	12.03	25.21	18.44
10/01/2017	0.28	8.27	12.04	25.23	18.43
11/01/2017	0.28	8.28	12.05	25.23	18.41
12/01/2017	0.28	8.29	12.06	25.22	18.40
13/01/2017	0.28	8.30	12.07	25.22	18.38
14/01/2017	0.28	8.31	12.08	25.21	18.37
15/01/2017	0.28	8.32	12.10	25.20	18.35
16/01/2017	0.28	8.32	12.11	25.19	18.34
17/01/2017	0.28	8.33	12.12	25.18	18.32
18/01/2017	0.28	8.34	12.13	25.17	18.31
19/01/2017	0.28	8.34	12.15	25.16	18.29
20/01/2017	0.28	8.35	12.16	25.15	18.27
21/01/2017	0.29	8.36	12.17	25.14	18.26
22/01/2017	0.29	8.36	12.18	25.13	18.24
23/01/2017	0.29	8.37	12.20	25.12	18.22
24/01/2017	0.29	8.38	12.21	25.11	18.21
25/01/2017	0.29	8.39	12.22	25.09	18.19
26/01/2017	0.29	8.40	12.24	25.08	18.17
27/01/2017	0.29	8.40	12.25	25.07	18.15
28/01/2017	0.29	8.41	12.27	25.06	18.13
29/01/2017	0.29	8.42	12.28	25.05	18.11
30/01/2017	0.29	8.43	12.30	25.03	18.09
31/01/2017	0.29	8.44	12.31	25.02	18.07
01/02/2017	0.29	8.45	12.33	25.01	18.05
02/02/2017	0.29	8.46	12.35	24.99	18.03
03/02/2017	0.29	8.47	12.36	24.98	18.01
04/02/2017	0.29	8.48	12.38	24.96	17.99
05/02/2017	0.29	8.49	12.40	24.95	17.96
06/02/2017	0.29	8.50	12.42	24.93	17.94
07/02/2017	0.29	8.51	12.44	24.91	17.91
08/02/2017	0.29	8.52	12.46	24.89	17.88

Tanggal	forecast_CO	forecast_NO ₂	forecast_O ₃	forecast_PM ₁₀	forecast_SO ₂
09/02/2017	0.29	8.53	12.48	24.88	17.86
10/02/2017	0.29	8.55	12.51	24.86	17.83
11/02/2017	0.29	8.56	12.53	24.84	17.80
12/02/2017	0.29	8.57	12.55	24.81	17.76
13/02/2017	0.29	8.59	12.58	24.79	17.73
14/02/2017	0.29	8.60	12.61	24.77	17.69
15/02/2017	0.29	8.62	12.64	24.74	17.66
16/02/2017	0.29	8.64	12.67	24.71	17.62
17/02/2017	0.29	8.66	12.70	24.69	17.57
18/02/2017	0.29	8.68	12.74	24.66	17.53
19/02/2017	0.29	8.70	12.77	24.62	17.48
20/02/2017	0.29	8.72	12.81	24.59	17.43
21/02/2017	0.29	8.75	12.86	24.55	17.37
22/02/2017	0.29	8.77	12.90	24.51	17.31
23/02/2017	0.29	8.80	12.95	24.46	17.25
24/02/2017	0.29	8.83	13.01	24.42	17.18
25/02/2017	0.29	8.87	13.07	24.36	17.10
26/02/2017	0.30	8.91	13.13	24.31	17.02
27/02/2017	0.30	8.95	13.20	24.24	16.93
28/02/2017	0.30	8.99	13.28	24.17	16.83
...
...
01/11/2017	0.39	11.54	22.68	18.93	5.72
02/11/2017	0.39	11.54	22.68	18.93	5.72
03/11/2017	0.39	11.54	22.68	18.93	5.72
04/11/2017	0.39	11.54	22.68	18.93	5.72
05/11/2017	0.39	11.54	22.68	18.93	5.72
06/11/2017	0.39	11.54	22.68	18.93	5.72
07/11/2017	0.39	11.54	22.68	18.93	5.72
08/11/2017	0.39	11.54	22.68	18.93	5.72
09/11/2017	0.39	11.54	22.68	18.93	5.72
10/11/2017	0.39	11.54	22.68	18.93	5.72
11/11/2017	0.39	11.54	22.68	18.93	5.72
12/11/2017	0.39	11.54	22.68	18.93	5.72
13/11/2017	0.39	11.54	22.68	18.93	5.72
14/11/2017	0.39	11.54	22.68	18.93	5.72
15/11/2017	0.39	11.54	22.68	18.93	5.72
16/11/2017	0.39	11.54	22.68	18.93	5.72
17/11/2017	0.39	11.54	22.68	18.93	5.72
18/11/2017	0.39	11.54	22.68	18.93	5.72

C-4

Tanggal	forecast_CO	forecast_NO ₂	forecast_O ₃	forecast_PM ₁₀	forecast_SO ₂
19/11/2017	0.39	11.54	22.68	18.93	5.72
20/11/2017	0.39	11.54	22.68	18.93	5.72
21/11/2017	0.39	11.54	22.68	18.93	5.72
22/11/2017	0.39	11.54	22.68	18.93	5.72
23/11/2017	0.39	11.54	22.68	18.93	5.72
24/11/2017	0.39	11.54	22.68	18.93	5.72
25/11/2017	0.39	11.54	22.68	18.93	5.72
26/11/2017	0.39	11.54	22.68	18.93	5.72
27/11/2017	0.39	11.54	22.68	18.93	5.72
28/11/2017	0.39	11.54	22.68	18.93	5.72
29/11/2017	0.39	11.54	22.68	18.93	5.72
30/11/2017	0.39	11.54	22.68	18.93	5.72
01/12/2017	0.39	11.54	22.68	18.93	5.72
02/12/2017	0.39	11.54	22.68	18.93	5.72
03/12/2017	0.39	11.54	22.68	18.93	5.72
04/12/2017	0.39	11.54	22.68	18.93	5.72
05/12/2017	0.39	11.54	22.68	18.93	5.72
06/12/2017	0.39	11.54	22.68	18.93	5.72
07/12/2017	0.39	11.54	22.68	18.93	5.72
08/12/2017	0.39	11.54	22.68	18.93	5.72
09/12/2017	0.39	11.54	22.68	18.93	5.72
10/12/2017	0.39	11.54	22.68	18.93	5.72
11/12/2017	0.39	11.54	22.68	18.93	5.72
12/12/2017	0.39	11.54	22.68	18.93	5.72
13/12/2017	0.39	11.54	22.68	18.93	5.72
14/12/2017	0.39	11.54	22.68	18.93	5.72
15/12/2017	0.39	11.54	22.68	18.93	5.72
16/12/2017	0.39	11.54	22.68	18.93	5.72
17/12/2017	0.39	11.54	22.68	18.93	5.72
18/12/2017	0.39	11.54	22.68	18.93	5.72
19/12/2017	0.39	11.54	22.68	18.93	5.72
20/12/2017	0.39	11.54	22.68	18.93	5.72
21/12/2017	0.39	11.54	22.68	18.93	5.72
22/12/2017	0.39	11.54	22.68	18.93	5.72
23/12/2017	0.39	11.54	22.68	18.93	5.72
24/12/2017	0.39	11.54	22.68	18.93	5.72
25/12/2017	0.39	11.54	22.68	18.93	5.72
26/12/2017	0.39	11.54	22.68	18.93	5.72
27/12/2017	0.39	11.54	22.68	18.93	5.72
28/12/2017	0.39	11.54	22.68	18.93	5.72
29/12/2017	0.39	11.54	22.68	18.93	5.72
30/12/2017	0.39	11.54	22.68	18.93	5.72

Tanggal	forecast_CO	forecast_NO ₂	forecast_O ₃	forecast_PM ₁₀	forecast_SO ₂
31/12/2017	0.39	11.54	22.68	18.93	5.72

Hasil Peramalan Unsur Polutan Udara Stasiun Pemantau Udara Wilayah Surabaya Timur

Tanggal	forecast_CO	forecast_NO ₂	forecast_O ₃	forecast_PM ₁₀	forecast_SO ₂
01/01/2016	1.80	6.13	53.56	41.46	14.32
02/01/2016	1.81	10.04	37.10	19.26	21.41
03/01/2016	2.23	23.37	53.56	51.33	14.14
04/01/2016	1.94	24.31	40.17	36.44	15.25
05/01/2016	2.18	18.72	58.46	36.86	14.85
06/01/2016	2.32	30.92	71.53	42.74	14.75
07/01/2016	2.19	30.73	56.74	60.57	5.28
08/01/2016	2.06	24.36	50.36	73.47	19.45
09/01/2016	2.05	17.43	41.24	51.02	15.05
10/01/2016	1.95	30.27	59.69	68.86	15.01
11/01/2016	1.92	23.59	60.87	61.32	18.43
12/01/2016	1.94	34.18	57.30	71.01	15.23
13/01/2016	2.36	22.38	31.52	46.80	15.22
14/01/2016	2.20	14.07	40.97	37.64	14.60
15/01/2016	1.99	8.21	43.23	53.64	16.04
16/01/2016	2.33	9.41	63.90	49.33	15.59
17/01/2016	2.26	14.67	38.33	30.51	15.51
18/01/2016	2.44	8.34	37.11	41.28	15.16
19/01/2016	2.13	6.11	45.71	33.21	18.96
20/01/2016	2.30	7.32	51.05	24.16	15.39
21/01/2016	2.50	10.63	53.56	54.57	15.51
22/01/2016	2.25	11.77	36.88	49.36	4.80
23/01/2016	2.45	13.67	35.90	54.96	14.80
24/01/2016	2.26	14.06	33.46	30.75	18.26
25/01/2016	2.18	19.96	30.50	52.94	22.39
26/01/2016	1.98	20.55	41.23	46.28	21.94
27/01/2016	2.08	13.73	45.57	34.84	16.13
28/01/2016	2.22	18.51	226.91	40.15	21.25
29/01/2016	2.41	12.29	35.70	37.47	17.90
30/01/2016	2.29	10.24	37.34	25.08	17.72
31/01/2016	2.56	6.13	102.59	27.76	16.80
01/02/2016	2.31	5.26	41.96	22.07	14.41
02/02/2016	2.26	43.30	53.57	35.27	21.41

C-6

03/02/2016	1.05	14.42	42.58	28.66	14.14
04/02/2016	1.22	23.50	49.16	46.72	15.25
05/02/2016	1.03	22.29	53.39	80.72	14.85
06/02/2016	0.86	13.49	46.66	22.34	14.75
07/02/2016	0.74	21.50	52.71	13.56	5.28
08/02/2016	1.01	23.95	48.98	25.55	19.45
09/02/2016	0.85	14.91	38.27	24.63	15.05
10/02/2016	0.93	27.89	61.11	38.59	15.01
11/02/2016	0.86	18.83	46.83	24.88	18.43
12/02/2016	1.04	19.07	48.96	27.10	15.23
13/02/2016	1.19	19.37	36.74	31.74	15.22
14/02/2016	1.05	13.31	41.32	32.35	14.60
15/02/2016	1.01	14.62	60.10	18.30	16.04
16/02/2016	1.23	24.84	53.88	29.52	15.59
17/02/2016	1.00	13.42	66.39	34.12	15.51
18/02/2016	1.01	17.30	71.73	34.91	15.16
19/02/2016	0.96	18.04	48.44	27.19	18.96
20/02/2016	0.68	13.00	76.10	33.58	15.39
21/02/2016	0.81	9.76	53.56	21.75	15.51
22/02/2016	0.99	11.77	56.58	23.55	4.80
23/02/2016	1.24	18.93	60.65	28.45	14.80
24/02/2016	1.19	16.36	48.33	26.79	18.26
25/02/2016	1.17	8.65	87.50	23.58	22.39
26/02/2016	0.97	13.73	486.52	24.43	21.94
27/02/2016	2.66	12.15	44.73	12.99	16.13
28/02/2016	0.46	13.08	62.13	30.16	21.25
29/02/2016	0.39	10.33	67.46	31.71	17.90
...
01/10/2016	0.58	9.59	55.83	68.81	23.85
02/10/2016	0.45	19.15	78.09	57.34	22.56
03/10/2016	0.32	14.62	79.08	30.96	18.48
04/10/2016	0.22	13.18	72.24	28.70	17.23
05/10/2016	0.22	10.23	73.54	17.25	16.67
06/10/2016	0.25	13.72	68.16	17.15	16.76
07/10/2016	0.31	12.82	75.44	35.24	28.59
08/10/2016	0.21	24.10	69.34	19.73	17.03
09/10/2016	0.11	15.77	81.11	51.13	17.17
10/10/2016	0.12	18.83	72.31	32.51	17.29
11/10/2016	0.13	13.13	76.99	33.51	17.72
12/10/2016	0.15	9.02	78.48	24.50	18.29
13/10/2016	0.25	17.78	72.76	20.55	18.63
14/10/2016	0.39	10.92	69.98	21.41	19.08
15/10/2016	2.18	13.51	73.25	31.34	22.01

16/10/2016	0.41	15.06	76.79	40.57	25.17
17/10/2016	0.24	8.91	67.39	29.90	24.90
18/10/2016	0.35	11.62	67.49	32.26	35.77
19/10/2016	0.24	12.40	64.66	36.64	31.55
20/10/2016	0.11	11.05	61.55	26.33	20.96
21/10/2016	0.25	11.53	73.27	35.65	32.83
22/10/2016	0.31	8.72	72.55	49.45	22.61
23/10/2016	0.40	10.85	74.14	68.95	21.68
24/10/2016	0.46	22.38	68.91	75.35	27.24
25/10/2016	0.69	21.23	71.34	50.27	28.53
26/10/2016	0.53	21.37	73.96	60.27	26.65
27/10/2016	0.40	26.35	64.77	59.64	39.93
28/10/2016	0.38	21.57	74.44	65.65	37.51
29/10/2016	1.83	20.57	70.36	48.89	30.52
30/10/2016	1.73	16.26	82.58	42.81	36.34
31/10/2016	1.74	21.62	78.93	46.45	44.57
01/11/2016	1.85	14.46	68.05	77.38	41.45
02/11/2016	0.37	24.96	56.89	66.94	51.00
03/11/2016	1.95	19.14	76.99	43.65	40.19
04/11/2016	1.94	22.72	77.67	77.02	38.39
05/11/2016	1.90	17.15	85.47	41.36	32.23
06/11/2016	2.05	16.98	70.11	38.54	34.16
07/11/2016	2.02	12.06	69.09	67.22	23.99
08/11/2016	1.91	22.37	52.05	56.94	27.04
09/11/2016	2.09	28.47	35.69	74.78	37.23
10/11/2016	2.09	25.04	67.90	48.15	40.18
11/11/2016	1.95	30.66	61.15	76.92	40.18
12/11/2016	1.85	19.26	67.87	56.80	37.95
13/11/2016	2.01	19.36	50.47	20.55	44.06
14/11/2016	0.56	26.32	44.38	48.87	51.38
15/11/2016	0.56	28.52	44.38	54.45	45.60
16/11/2016	0.40	17.14	52.62	36.03	34.70
17/11/2016	1.46	15.36	40.99	30.59	27.34
18/11/2016	1.62	16.63	55.11	30.79	25.40
19/11/2016	1.55	13.87	73.94	57.04	27.35
20/11/2016	1.39	10.32	58.77	50.41	29.66
21/11/2016	1.24	12.91	57.70	36.27	24.73
22/11/2016	1.39	10.16	51.33	38.19	30.74
23/11/2016	1.29	4.57	69.62	44.67	26.29
24/11/2016	1.43	15.72	68.92	35.39	28.94
25/11/2016	1.47	30.74	48.52	27.85	27.37

26/11/2016	1.85	13.40	66.74	33.58	27.27
27/11/2016	1.43	18.98	49.75	12.24	26.13
28/11/2016	1.50	22.67	41.89	47.15	29.86
29/11/2016	1.45	16.03	49.14	45.40	29.52
30/11/2016	1.19	18.28	33.06	41.10	32.23
01/12/2016	7.60	16.60	54.26	48.38	28.29
02/12/2016	7.64	17.93	41.12	48.04	28.62
03/12/2016	7.52	17.01	28.86	49.10	27.97
04/12/2016	7.46	21.38	28.19	36.13	30.91
05/12/2016	7.94	31.54	30.47	44.89	28.93
06/12/2016	7.51	27.27	26.87	47.72	31.38
07/12/2016	7.38	20.85	28.89	48.89	33.43
08/12/2016	7.55	16.79	64.09	39.30	28.57
09/12/2016	7.40	23.25	45.79	47.29	30.83
10/12/2016	7.40	32.16	50.23	39.50	26.70
11/12/2016	7.93	21.91	45.65	30.19	27.41
12/12/2016	7.27	16.02	40.46	38.47	27.03
13/12/2016	7.31	26.08	45.45	32.49	32.22
14/12/2016	7.46	18.91	40.78	41.64	34.74
15/12/2016	0.39	19.91	51.93	56.46	31.04
16/12/2016	0.25	21.34	49.79	59.15	28.72
17/12/2016	0.20	26.43	41.51	41.15	30.27
18/12/2016	0.19	20.97	31.80	47.46	59.58
19/12/2016	0.18	32.77	31.13	49.61	26.78
20/12/2016	0.12	33.75	35.76	61.35	28.04
21/12/2016	0.10	26.43	30.96	51.84	21.41
22/12/2016	0.10	24.64	140.44	75.82	11.66
23/12/2016	0.13	26.25	50.77	54.37	29.69
24/12/2016	0.13	23.81	40.32	66.31	28.76
25/12/2016	0.13	29.28	43.09	76.72	27.86
26/12/2016	0.15	25.98	43.82	61.10	15.32
27/12/2016	0.37	23.18	38.85	42.18	29.39
28/12/2016	0.51	14.45	54.15	32.78	28.63
29/12/2016	0.38	16.46	39.66	31.64	16.41
30/12/2016	0.46	29.76	50.05	25.47	27.95
31/12/2016	0.47	17.24	66.06	30.95	24.57
01/01/2017	0.42	16.11	70.59	38.59	25.29
02/01/2017	0.40	15.59	72.56	41.66	25.08
03/01/2017	0.41	15.34	73.30	42.68	24.37
04/01/2017	0.43	15.22	73.48	42.77	23.44
05/01/2017	0.45	15.16	73.37	42.45	22.43
06/01/2017	0.48	15.12	73.14	41.99	21.41
07/01/2017	0.52	15.11	72.84	41.49	20.43

08/01/2017	0.55	15.09	72.52	41.02	19.50
09/01/2017	0.59	15.09	72.18	40.60	18.65
10/01/2017	0.63	15.08	71.85	40.27	17.89
11/01/2017	0.67	15.08	71.53	40.03	17.23
12/01/2017	0.71	15.07	71.23	39.87	16.67
13/01/2017	0.75	15.07	70.96	39.80	16.23
14/01/2017	0.78	15.07	70.71	39.80	15.88
15/01/2017	0.81	15.07	70.50	39.85	15.62
16/01/2017	0.84	15.06	70.32	39.93	15.42
17/01/2017	0.87	15.06	70.17	40.03	15.29
18/01/2017	0.89	15.06	70.05	40.13	15.19
19/01/2017	0.91	15.06	69.95	40.23	15.12
20/01/2017	0.92	15.06	69.87	40.31	15.08
21/01/2017	0.93	15.06	69.81	40.39	15.05
22/01/2017	0.94	15.05	69.76	40.45	15.02
23/01/2017	0.95	15.05	69.72	40.50	15.01
24/01/2017	0.95	15.05	69.69	40.54	15.00
25/01/2017	0.96	15.05	69.66	40.57	14.99
26/01/2017	0.96	15.05	69.65	40.60	14.99
27/01/2017	0.96	15.05	69.63	40.62	14.98
28/01/2017	0.96	15.05	69.62	40.63	14.98
29/01/2017	0.97	15.05	69.61	40.65	14.98
30/01/2017	0.97	15.05	69.61	40.66	14.97
31/01/2017	0.97	15.05	69.60	40.66	14.97
01/02/2017	0.97	15.05	69.60	40.67	14.97
02/02/2017	0.97	15.05	69.59	40.67	14.97
03/02/2017	0.97	15.05	69.59	40.68	14.97
04/02/2017	0.97	15.05	69.59	40.68	14.97
05/02/2017	0.97	15.05	69.59	40.68	14.97
06/02/2017	0.97	15.05	69.59	40.68	14.97
07/02/2017	0.97	15.05	69.59	40.68	14.97
08/02/2017	0.97	15.05	69.59	40.68	14.97
09/02/2017	0.97	15.05	69.59	40.68	14.97
10/02/2017	0.97	15.05	69.59	40.68	14.97
11/02/2017	0.97	15.05	69.59	40.68	14.97
12/02/2017	0.97	15.05	69.59	40.69	14.97
13/02/2017	0.97	15.05	69.59	40.69	14.97
14/02/2017	0.97	15.05	69.59	40.69	14.97
15/02/2017	0.97	15.05	69.59	40.69	14.97
16/02/2017	0.97	15.05	69.59	40.69	14.97
17/02/2017	0.97	15.05	69.59	40.69	14.97

C-10

18/02/2017	0.97	15.05	69.59	40.69	14.97
19/02/2017	0.97	15.05	69.59	40.69	14.97
20/02/2017	0.97	15.05	69.59	40.69	14.97
21/02/2017	0.97	15.05	69.59	40.69	14.97
22/02/2017	0.97	15.05	69.59	40.69	14.97
23/02/2017	0.97	15.05	69.59	40.69	14.97
24/02/2017	0.97	15.05	69.59	40.69	14.97
25/02/2017	0.97	15.05	69.59	40.69	14.97
26/02/2017	0.97	15.05	69.59	40.69	14.97
27/02/2017	0.97	15.05	69.59	40.69	14.97
28/02/2017	0.97	15.05	69.59	40.69	14.97
01/10/2017	0.97	15.05	69.59	40.69	14.97
02/10/2017	0.97	15.05	69.59	40.69	14.97
03/10/2017	0.97	15.05	69.59	40.69	14.97
04/10/2017	0.97	15.05	69.59	40.69	14.97
05/10/2017	0.97	15.05	69.59	40.69	14.97
06/10/2017	0.97	15.05	69.59	40.69	14.97
07/10/2017	0.97	15.05	69.59	40.69	14.97
08/10/2017	0.97	15.05	69.59	40.69	14.97
09/10/2017	0.97	15.05	69.59	40.69	14.97
10/10/2017	0.97	15.05	69.59	40.69	14.97
11/10/2017	0.97	15.05	69.59	40.69	14.97
12/10/2017	0.97	15.05	69.59	40.69	14.97
13/10/2017	0.97	15.05	69.59	40.69	14.97
14/10/2017	0.97	15.05	69.59	40.69	14.97
15/10/2017	0.97	15.05	69.59	40.69	14.97
16/10/2017	0.97	15.05	69.59	40.69	14.97
17/10/2017	0.97	15.05	69.59	40.69	14.97
18/10/2017	0.97	15.05	69.59	40.69	14.97
19/10/2017	0.97	15.05	69.59	40.69	14.97
20/10/2017	0.97	15.05	69.59	40.69	14.97
21/10/2017	0.97	15.05	69.59	40.69	14.97
22/10/2017	0.97	15.05	69.59	40.69	14.97
23/10/2017	0.97	15.05	69.59	40.69	14.97
24/10/2017	0.97	15.05	69.59	40.69	14.97
25/10/2017	0.97	15.05	69.59	40.69	14.97
26/10/2017	0.97	15.05	69.59	40.69	14.97
27/10/2017	0.97	15.05	69.59	40.69	14.97
28/10/2017	0.97	15.05	69.59	40.69	14.97
29/10/2017	0.97	15.05	69.59	40.69	14.97
30/10/2017	0.97	15.05	69.59	40.69	14.97
31/10/2017	0.97	15.05	69.59	40.69	14.97
01/11/2017	0.97	15.05	69.59	40.69	14.97

02/11/2017	0.97	15.05	69.59	40.69	14.97
03/11/2017	0.97	15.05	69.59	40.69	14.97
04/11/2017	0.97	15.05	69.59	40.69	14.97
05/11/2017	0.97	15.05	69.59	40.69	14.97
06/11/2017	0.97	15.05	69.59	40.69	14.97
07/11/2017	0.97	15.05	69.59	40.69	14.97
08/11/2017	0.97	15.05	69.59	40.69	14.97
09/11/2017	0.97	15.05	69.59	40.69	14.97
10/11/2017	0.97	15.05	69.59	40.69	14.97
11/11/2017	0.97	15.05	69.59	40.69	14.97
12/11/2017	0.97	15.05	69.59	40.69	14.97
13/11/2017	0.97	15.05	69.59	40.69	14.97
14/11/2017	0.97	15.05	69.59	40.69	14.97
15/11/2017	0.97	15.05	69.59	40.69	14.97
16/11/2017	0.97	15.05	69.59	40.69	14.97
17/11/2017	0.97	15.05	69.59	40.69	14.97
18/11/2017	0.97	15.05	69.59	40.69	14.97
19/11/2017	0.97	15.05	69.59	40.69	14.97
20/11/2017	0.97	15.05	69.59	40.69	14.97
21/11/2017	0.97	15.05	69.59	40.69	14.97
22/11/2017	0.97	15.05	69.59	40.69	14.97
23/11/2017	0.97	15.05	69.59	40.69	14.97
24/11/2017	0.97	15.05	69.59	40.69	14.97
25/11/2017	0.97	15.05	69.59	40.69	14.97
26/11/2017	0.97	15.05	69.59	40.69	14.97
27/11/2017	0.97	15.05	69.59	40.69	14.97
28/11/2017	0.97	15.05	69.59	40.69	14.97
29/11/2017	0.97	15.05	69.59	40.69	14.97
30/11/2017	0.97	15.05	69.59	40.69	14.97
01/12/2017	0.97	15.05	69.59	40.69	14.97
02/12/2017	0.97	15.05	69.59	40.69	14.97
03/12/2017	0.97	15.05	69.59	40.69	14.97
04/12/2017	0.97	15.05	69.59	40.69	14.97
05/12/2017	0.97	15.05	69.59	40.69	14.97
06/12/2017	0.97	15.05	69.59	40.69	14.97
07/12/2017	0.97	15.05	69.59	40.69	14.97
08/12/2017	0.97	15.05	69.59	40.69	14.97
09/12/2017	0.97	15.05	69.59	40.69	14.97
10/12/2017	0.97	15.05	69.59	40.69	14.97
11/12/2017	0.97	15.05	69.59	40.69	14.97
12/12/2017	0.97	15.05	69.59	40.69	14.97

C-12

13/12/2017	0.97	15.05	69.59	40.69	14.97
14/12/2017	0.97	15.05	69.59	40.69	14.97
15/12/2017	0.97	15.05	69.59	40.69	14.97
16/12/2017	0.97	15.05	69.59	40.69	14.97
17/12/2017	0.97	15.05	69.59	40.69	14.97
18/12/2017	0.97	15.05	69.59	40.69	14.97
19/12/2017	0.97	15.05	69.59	40.69	14.97
20/12/2017	0.97	15.05	69.59	40.69	14.97
21/12/2017	0.97	15.05	69.59	40.69	14.97
22/12/2017	0.97	15.05	69.59	40.69	14.97
23/12/2017	0.97	15.05	69.59	40.69	14.97
24/12/2017	0.97	15.05	69.59	40.69	14.97
25/12/2017	0.97	15.05	69.59	40.69	14.97
26/12/2017	0.97	15.05	69.59	40.69	14.97
27/12/2017	0.97	15.05	69.59	40.69	14.97
28/12/2017	0.97	15.05	69.59	40.69	14.97
29/12/2017	0.97	15.05	69.59	40.69	14.97
30/12/2017	0.97	15.05	69.59	40.69	14.97
31/12/2017	0.97	15.05	69.59	40.69	14.97

Hasil Peramalan Unsur Polutan Udara Stasiun Pemantau Udara
Wilayah Surabaya Selatan

Tanggal	forecast_CO	forecast_NO ₂	forecast_O ₃	forecast_PM ₁₀	forecast_SO ₂
01/01/2017	0.55	7.27	32.18	39.06	4.27
02/01/2017	0.51	11.04	62.34	42.29	4.36
03/01/2017	0.45	14.16	78.60	43.17	4.25
04/01/2017	0.46	17.11	86.01	43.55	3.88
05/01/2017	0.53	19.77	88.87	43.02	3.31
06/01/2017	0.61	22.01	89.93	41.51	2.59
07/01/2017	0.73	23.75	90.60	39.69	1.77
08/01/2017	0.87	24.94	91.46	38.22	0.94
09/01/2017	1.06	25.59	92.63	37.52	0.18
10/01/2017	1.29	25.78	93.87	37.73	0.44
11/01/2017	1.55	25.68	94.76	38.80	0.83
12/01/2017	1.86	25.50	94.69	40.63	0.90
13/01/2017	2.23	25.46	93.06	43.19	0.57
14/01/2017	2.67	25.75	89.38	46.37	0.20
15/01/2017	3.14	26.38	84.02	49.56	1.33
16/01/2017	3.53	27.06	78.94	51.28	2.43
17/01/2017	3.76	27.36	76.19	51.14	3.08

18/01/2017	3.87	27.20	75.63	50.66	3.31
19/01/2017	3.94	26.82	76.10	50.61	3.34
20/01/2017	3.98	26.44	76.83	50.79	3.28
21/01/2017	4.01	26.12	77.53	51.00	3.20
22/01/2017	4.04	25.87	78.12	51.19	3.11
23/01/2017	4.05	25.67	78.61	51.33	3.03
24/01/2017	4.07	25.52	79.01	51.45	2.96
25/01/2017	4.08	25.40	79.32	51.54	2.90
26/01/2017	4.09	25.31	79.58	51.62	2.85
27/01/2017	4.09	25.24	79.78	51.67	2.81
28/01/2017	4.10	25.18	79.94	51.72	2.78
29/01/2017	4.10	25.13	80.07	51.76	2.76
30/01/2017	4.11	25.09	80.17	51.79	2.74
31/01/2017	4.11	25.06	80.26	51.81	2.72
01/02/2017	4.11	25.04	80.32	51.83	2.71
02/02/2017	4.11	25.02	80.37	51.84	2.70
03/02/2017	4.11	25.01	80.41	51.86	2.69
04/02/2017	4.12	25.00	80.44	51.87	2.69
05/02/2017	4.12	24.99	80.47	51.87	2.68
06/02/2017	4.12	24.98	80.49	51.88	2.68
07/02/2017	4.12	24.97	80.50	51.88	2.68
08/02/2017	4.12	24.97	80.52	51.89	2.67
09/02/2017	4.12	24.97	80.53	51.89	2.67
10/02/2017	4.12	24.96	80.53	51.89	2.67
11/02/2017	4.12	24.96	80.54	51.89	2.67
12/02/2017	4.12	24.96	80.54	51.89	2.67
13/02/2017	4.12	24.96	80.55	51.90	2.67
14/02/2017	4.12	24.96	80.55	51.90	2.67
15/02/2017	4.12	24.96	80.55	51.90	2.67
16/02/2017	4.12	24.96	80.55	51.90	2.67
17/02/2017	4.12	24.96	80.56	51.90	2.66
18/02/2017	4.12	24.95	80.56	51.90	2.66
19/02/2017	4.12	24.95	80.56	51.90	2.66
20/02/2017	4.12	24.95	80.56	51.90	2.66
21/02/2017	4.12	24.95	80.56	51.90	2.66
22/02/2017	4.12	24.95	80.56	51.90	2.66
23/02/2017	4.12	24.95	80.56	51.90	2.66
24/02/2017	4.12	24.95	80.56	51.90	2.66
25/02/2017	4.12	24.95	80.56	51.90	2.66
26/02/2017	4.12	24.95	80.56	51.90	2.66
27/02/2017	4.12	24.95	80.56	51.90	2.66

28/02/2017	4.12	24.95	80.56	51.90	2.66
...
01/10/2017	4.12	24.95	80.56	51.90	2.66
02/10/2017	4.12	24.95	80.56	51.90	2.66
03/10/2017	4.12	24.95	80.56	51.90	2.66
04/10/2017	4.12	24.95	80.56	51.90	2.66
05/10/2017	4.12	24.95	80.56	51.90	2.66
06/10/2017	4.12	24.95	80.56	51.90	2.66
07/10/2017	4.12	24.95	80.56	51.90	2.66
08/10/2017	4.12	24.95	80.56	51.90	2.66
09/10/2017	4.12	24.95	80.56	51.90	2.66
10/10/2017	4.12	24.95	80.56	51.90	2.66
11/10/2017	4.12	24.95	80.56	51.90	2.66
12/10/2017	4.12	24.95	80.56	51.90	2.66
13/10/2017	4.12	24.95	80.56	51.90	2.66
14/10/2017	4.12	24.95	80.56	51.90	2.66
15/10/2017	4.12	24.95	80.56	51.90	2.66
16/10/2017	4.12	24.95	80.56	51.90	2.66
17/10/2017	4.12	24.95	80.56	51.90	2.66
18/10/2017	4.12	24.95	80.56	51.90	2.66
19/10/2017	4.12	24.95	80.56	51.90	2.66
20/10/2017	4.12	24.95	80.56	51.90	2.66
21/10/2017	4.12	24.95	80.56	51.90	2.66
22/10/2017	4.12	24.95	80.56	51.90	2.66
23/10/2017	4.12	24.95	80.56	51.90	2.66
24/10/2017	4.12	24.95	80.56	51.90	2.66
25/10/2017	4.12	24.95	80.56	51.90	2.66
26/10/2017	4.12	24.95	80.56	51.90	2.66
27/10/2017	4.12	24.95	80.56	51.90	2.66
28/10/2017	4.12	24.95	80.56	51.90	2.66
29/10/2017	4.12	24.95	80.56	51.90	2.66
30/10/2017	4.12	24.95	80.56	51.90	2.66
31/10/2017	4.12	24.95	80.56	51.90	2.66
01/11/2017	4.12	24.95	80.56	51.90	2.66
02/11/2017	4.12	24.95	80.56	51.90	2.66
03/11/2017	4.12	24.95	80.56	51.90	2.66
04/11/2017	4.12	24.95	80.56	51.90	2.66
05/11/2017	4.12	24.95	80.56	51.90	2.66
06/11/2017	4.12	24.95	80.56	51.90	2.66
07/11/2017	4.12	24.95	80.56	51.90	2.66
08/11/2017	4.12	24.95	80.56	51.90	2.66
09/11/2017	4.12	24.95	80.56	51.90	2.66
10/11/2017	4.12	24.95	80.56	51.90	2.66

11/11/2017	4.12	24.95	80.56	51.90	2.66
12/11/2017	4.12	24.95	80.56	51.90	2.66
13/11/2017	4.12	24.95	80.56	51.90	2.66
14/11/2017	4.12	24.95	80.56	51.90	2.66
15/11/2017	4.12	24.95	80.56	51.90	2.66
16/11/2017	4.12	24.95	80.56	51.90	2.66
17/11/2017	4.12	24.95	80.56	51.90	2.66
18/11/2017	4.12	24.95	80.56	51.90	2.66
19/11/2017	4.12	24.95	80.56	51.90	2.66
20/11/2017	4.12	24.95	80.56	51.90	2.66
21/11/2017	4.12	24.95	80.56	51.90	2.66
22/11/2017	4.12	24.95	80.56	51.90	2.66
23/11/2017	4.12	24.95	80.56	51.90	2.66
24/11/2017	4.12	24.95	80.56	51.90	2.66
25/11/2017	4.12	24.95	80.56	51.90	2.66
26/11/2017	4.12	24.95	80.56	51.90	2.66
27/11/2017	4.12	24.95	80.56	51.90	2.66
28/11/2017	4.12	24.95	80.56	51.90	2.66
29/11/2017	4.12	24.95	80.56	51.90	2.66
30/11/2017	4.12	24.95	80.56	51.90	2.66
01/12/2017	4.12	24.95	80.56	51.90	2.66
02/12/2017	4.12	24.95	80.56	51.90	2.66
03/12/2017	4.12	24.95	80.56	51.90	2.66
04/12/2017	4.12	24.95	80.56	51.90	2.66
05/12/2017	4.12	24.95	80.56	51.90	2.66
06/12/2017	4.12	24.95	80.56	51.90	2.66
07/12/2017	4.12	24.95	80.56	51.90	2.66
08/12/2017	4.12	24.95	80.56	51.90	2.66
09/12/2017	4.12	24.95	80.56	51.90	2.66
10/12/2017	4.12	24.95	80.56	51.90	2.66
11/12/2017	4.12	24.95	80.56	51.90	2.66
12/12/2017	4.12	24.95	80.56	51.90	2.66
13/12/2017	4.12	24.95	80.56	51.90	2.66
14/12/2017	4.12	24.95	80.56	51.90	2.66
15/12/2017	4.12	24.95	80.56	51.90	2.66
16/12/2017	4.12	24.95	80.56	51.90	2.66
17/12/2017	4.12	24.95	80.56	51.90	2.66
18/12/2017	4.12	24.95	80.56	51.90	2.66
19/12/2017	4.12	24.95	80.56	51.90	2.66
20/12/2017	4.12	24.95	80.56	51.90	2.66
21/12/2017	4.12	24.95	80.56	51.90	2.66

C-16

22/12/2017	4.12	24.95	80.56	51.90	2.66
23/12/2017	4.12	24.95	80.56	51.90	2.66
24/12/2017	4.12	24.95	80.56	51.90	2.66
25/12/2017	4.12	24.95	80.56	51.90	2.66
26/12/2017	4.12	24.95	80.56	51.90	2.66
27/12/2017	4.12	24.95	80.56	51.90	2.66
28/12/2017	4.12	24.95	80.56	51.90	2.66
29/12/2017	4.12	24.95	80.56	51.90	2.66
30/12/2017	4.12	24.95	80.56	51.90	2.66
31/12/2017	4.12	24.95	80.56	51.90	2.66

LAMPIRAN D

Potongan Hasil Klasifikasi dari Hasil Peramalan untuk Stasiun Pemantau Wilayah Surabaya Pusat, Surabaya Timur dan Surabaya Selatan

Hasil klasifikasi peramalan status polusi udara untuk satu tahun 2017 di wilayah Surabaya Pusat.

Tanggal	CO	prediksi_ i_co	NO2	prediksi_ no2	O3	prediksi_ o3	PM10	prediksi_ pm10	SO2	prediksi_ so2	status_ polusi
01/01/2017	0.2893 37	Baik	5.867383	Sedang	12.174 01	Sedang	19.726 65044	Sangat Baik	18.496 41	Sangat Baik	Sedang
02/01/2017	0.2865 28	Baik	6.874905	Sedang	12.102 17	Sedang	22.196 26656	Sangat Baik	18.496 64	Sangat Baik	Sedang
03/01/2017	0.2849 36	Baik	7.466932	Sedang	12.054 07	Sedang	23.590 33431	Sedang	18.498 52	Sangat Baik	Sedang
04/01/2017	0.2840 83	Baik	7.810088	Sedang	12.026 58	Sedang	24.361 74837	Sedang	18.496 3	Sangat Baik	Sedang
05/01/2017	0.2836 6	Baik	8.007785	Sedang	12.013 83	Sedang	24.782 15486	Sedang	18.489 82	Sangat Baik	Sedang
06/01/2017	0.2834 81	Baik	8.121917	Sedang	12.010 74	Sedang	25.007 77248	Sedang	18.480 17	Sangat Baik	Sedang
07/01/2017	0.2834 38	Baik	8.188613	Sedang	12.013 68	Sedang	25.126 30548	Sedang	18.468 44	Sangat Baik	Sedang
08/01/2017	0.2834 7	Baik	8.228611	Sedang	12.020 25	Sedang	25.186 3085	Sedang	18.455 4	Sangat Baik	Sedang
09/01/2017	0.2835 44	Baik	8.253681	Sedang	12.028 99	Sedang	25.214 43629	Sedang	18.441 56	Sangat Baik	Sedang
10/01/2017	0.2836 41	Baik	8.270448	Sedang	12.039	Sedang	25.225 24237	Sedang	18.427 22	Sangat Baik	Sedang
11/01/2017	0.2837 51	Baik	8.282623	Sedang	12.049 77	Sedang	25.226 6425	Sedang	18.412 58	Sangat Baik	Sedang

Tanggal	CO	prediksi i_co	NO2	prediksi_ no2	O3	prediksi_ o3	PM10	prediksi_ pm10	SO2	prediksi_ so2	status_ polusi
12/01/2017	0.2838 68	Baik	8.292274	Sedang	12.061	Sedang	25.222 92858	Sedang	18.397 72	Sangat Baik	Sedang
13/01/2017	0.2839 89	Baik	8.300554	Sedang	12.072 52	Sedang	25.216 42036	Sedang	18.382 71	Sangat Baik	Sedang
14/01/2017	0.2841 14	Baik	8.308104	Sedang	12.084 25	Sedang	25.208 36681	Sedang	18.367 55	Sangat Baik	Sedang
15/01/2017	0.2842 4	Baik	8.31528	Sedang	12.096 13	Sedang	25.199 4366	Sedang	18.352 25	Sangat Baik	Sedang
16/01/2017	0.2843 68	Baik	8.322282	Sedang	12.108 15	Sedang	25.189 98429	Sedang	18.336 81	Sangat Baik	Sedang
17/01/2017	0.2844 97	Baik	8.329225	Sedang	12.120 31	Sedang	25.180 19457	Sedang	18.321 21	Sangat Baik	Sedang
18/01/2017	0.2846 28	Baik	8.336175	Sedang	12.132 61	Sedang	25.170 16027	Sedang	18.305 44	Sangat Baik	Sedang
19/01/2017	0.2847 61	Baik	8.343174	Sedang	12.145 06	Sedang	25.159 92444	Sedang	18.289 48	Sangat Baik	Sedang
20/01/2017	0.2848 96	Baik	8.350248	Sedang	12.157 68	Sedang	25.149 50305	Sedang	18.273 31	Sangat Baik	Sedang
21/01/2017	0.2850 32	Baik	8.357417	Sedang	12.170 49	Sedang	25.138 8971	Sedang	18.256 9	Sangat Baik	Sedang
22/01/2017	0.2851 71	Baik	8.364696	Sedang	12.183 49	Sedang	25.128 09916	Sedang	18.240 23	Sangat Baik	Sedang
23/01/2017	0.2853 12	Baik	8.372101	Sedang	12.196 72	Sedang	25.117 09684	Sedang	18.223 28	Sangat Baik	Sedang

Tanggal	CO	prediksi i_co	NO2	prediksi_ no2	O3	prediksi_ o3	PM10	prediksi_ pm10	SO2	prediksi_ so2	status_ polusi
24/01/2017	0.2854 56	Baik	8.379644	Sedang	12.210 18	Sedang	25.105 87451	Sedang	18.206 01	Sangat Baik	Sedang
25/01/2017	0.2856 02	Baik	8.387338	Sedang	12.223 91	Sedang	25.094 41425	Sedang	18.188 41	Sangat Baik	Sedang
26/01/2017	0.2857 52	Baik	8.395198	Sedang	12.237 93	Sedang	25.082 69626	Sedang	18.170 44	Sangat Baik	Sedang
27/01/2017	0.2859 05	Baik	8.403239	Sedang	12.252 26	Sedang	25.070 69896	Sedang	18.152 06	Sangat Baik	Sedang
28/01/2017	0.2860 62	Baik	8.411475	Sedang	12.266 92	Sedang	25.058 39904	Sedang	18.133 25	Sangat Baik	Sedang
29/01/2017	0.2862 22	Baik	8.419924	Sedang	12.281 95	Sedang	25.045 77132	Sedang	18.113 96	Sangat Baik	Sedang
30/01/2017	0.2863 87	Baik	8.428604	Sedang	12.297 38	Sedang	25.032 78857	Sedang	18.094 16	Sangat Baik	Sedang
31/01/2017	0.2865 57	Baik	8.437532	Sedang	12.313 24	Sedang	25.019 42136	Sedang	18.073 8	Sangat Baik	Sedang
01/02/2017	0.2867 32	Baik	8.446732	Sedang	12.329 57	Sedang	25.005 63776	Sedang	18.052 84	Sangat Baik	Sedang
02/02/2017	0.2869 12	Baik	8.456224	Sedang	12.346 4	Sedang	24.991 40303	Sedang	18.031 23	Sangat Baik	Sedang
03/02/2017	0.2870 98	Baik	8.466034	Sedang	12.363 79	Sedang	24.976 67936	Sedang	18.008 9	Sangat Baik	Sedang

Tanggal	CO	prediksi i_co	NO2	prediksi_ no2	O3	prediksi_ o3	PM10	prediksi_ pm10	SO2	prediksi_ so2	status_ polusi
04/02/2017	0.2872 91	Baik	8.476188	Sedang	12.381 76	Sedang	24.961 42539	Sedang	17.985 81	Sangat Baik	Sedang
05/02/2017	0.2874 9	Baik	8.486717	Sedang	12.400 39	Sedang	24.945 59583	Sedang	17.961 88	Sangat Baik	Sedang
06/02/2017	0.2876 98	Baik	8.497651	Sedang	12.419 71	Sedang	24.929 14093	Sedang	17.937 05	Sangat Baik	Sedang
07/02/2017	0.2879 13	Baik	8.509027	Sedang	12.439 8	Sedang	24.912 00589	Sedang	17.911 23	Sangat Baik	Sedang
08/02/2017	0.2881 37	Baik	8.520883	Sedang	12.460 72	Sedang	24.894 13019	Sedang	17.884 34	Sangat Baik	Sedang
09/02/2017	0.2883 71	Baik	8.533263	Sedang	12.482 54	Sedang	24.875 44677	Sedang	17.856 29	Sangat Baik	Sedang
10/02/2017	0.2886 16	Baik	8.546215	Sedang	12.505 34	Sedang	24.855 88117	Sedang	17.826 96	Sangat Baik	Sedang
11/02/2017	0.2888 73	Baik	8.559792	Sedang	12.529 22	Sedang	24.835 35044	Sedang	17.796 24	Sangat Baik	Sedang
12/02/2017	0.2891 42	Baik	8.574055	Sedang	12.554 28	Sedang	24.813 76186	Sedang	17.763 99	Sangat Baik	Sedang
13/02/2017	0.2894 25	Baik	8.589069	Sedang	12.580 64	Sedang	24.791 01152	Sedang	17.730 07	Sangat Baik	Sedang
14/02/2017	0.2897 24	Baik	8.604909	Sedang	12.608 41	Sedang	24.766 98254	Sedang	17.694 32	Sangat Baik	Sedang
15/02/2017	0.2900 4	Baik	8.621661	Sedang	12.637 75	Sedang	24.741 54305	Sedang	17.656 54	Sangat Baik	Sedang

Tanggal	CO	prediksi i_co	NO2	prediksi_ no2	O3	prediksi_ o3	PM10	prediksi_ pm10	SO2	prediksi_ so2	status_ polusi
16/02/2017	0.2903 74	Baik	8.639419	Sedang	12.668 82	Sedang	24.714 54373	Sedang	17.616 53	Sangat Baik	Sedang
17/02/2017	0.2907 29	Baik	8.658292	Sedang	12.701 8	Sedang	24.685 8149	Sedang	17.574 04	Sangat Baik	Sedang
18/02/2017	0.2911 08	Baik	8.678404	Sedang	12.736 89	Sedang	24.655 163	Sedang	17.528 81	Sangat Baik	Sedang
19/02/2017	0.2915 12	Baik	8.699895	Sedang	12.774 35	Sedang	24.622 36638	Sedang	17.480 53	Sangat Baik	Sedang
20/02/2017	0.2919 44	Baik	8.722929	Sedang	12.814 45	Sedang	24.587 17019	Sedang	17.428 83	Sangat Baik	Sedang
21/02/2017	0.2924 09	Baik	8.747691	Sedang	12.857 49	Sedang	24.549 28014	Sedang	17.373 31	Sangat Baik	Sedang
22/02/2017	0.2929 09	Baik	8.774398	Sedang	12.903 85	Sedang	24.508 35493	Sedang	17.313 49	Sangat Baik	Sedang
23/02/2017	0.2934 51	Baik	8.803303	Sedang	12.953 95	Sedang	24.463 99688	Sedang	17.248 83	Sangat Baik	Sedang
24/02/2017	0.2940 38	Baik	8.834698	Sedang	13.008 29	Sedang	24.415 74044	Sedang	17.178 67	Sangat Baik	Sedang
25/02/2017	0.2946 79	Baik	8.86893	Sedang	13.067 45	Sedang	24.363 03787	Sedang	17.102 26	Sangat Baik	Sedang
26/02/2017	0.2953 79	Baik	8.906406	Sedang	13.132 11	Sedang	24.305 24149	Sedang	17.018 71	Sangat Baik	Sedang

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
27/02/2017	0.296148	Baik	8.94761	Sedang	13.2031	Sedang	24.24158144	Sedang	16.92696	Sangat Baik	Sedang
28/02/2017	0.296997	Baik	8.993117	Sedang	13.28137	Sedang	24.17113777	Sedang	16.82575	Sangat Baik	Sedang
01/10/2017	0.386437	Baik	11.54027	Sangat Tidak Baik	22.67732	Sedang	18.92904244	Sangat Baik	5.718022	Sangat Tidak Baik	Sangat Tidak Baik
02/10/2017	0.386437	Baik	11.54027	Sangat Tidak Baik	22.67732	Sedang	18.92904244	Sangat Baik	5.718022	Sangat Tidak Baik	Sangat Tidak Baik
03/10/2017	0.386437	Baik	11.54027	Sangat Tidak Baik	22.67732	Sedang	18.92904244	Sangat Baik	5.718022	Sangat Tidak Baik	Sangat Tidak Baik
04/10/2017	0.386437	Baik	11.54027	Sangat Tidak Baik	22.67732	Sedang	18.92904244	Sangat Baik	5.718022	Sangat Tidak Baik	Sangat Tidak Baik
05/10/2017	0.386437	Baik	11.54027	Sangat Tidak Baik	22.67732	Sedang	18.92904244	Sangat Baik	5.718022	Sangat Tidak Baik	Sangat Tidak Baik
06/10/2017	0.386437	Baik	11.54027	Sangat Tidak Baik	22.67732	Sedang	18.92904244	Sangat Baik	5.718022	Sangat Tidak Baik	Sangat Tidak Baik
07/10/2017	0.386437	Baik	11.54027	Sangat Tidak Baik	22.67732	Sedang	18.92904244	Sangat Baik	5.718022	Sangat Tidak Baik	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
08/10/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
09/10/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
10/10/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
11/10/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
12/10/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
13/10/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
14/10/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
15/10/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
16/10/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
17/10/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
18/10/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
19/10/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
20/10/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
21/10/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
22/10/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
23/10/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
24/10/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
25/10/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
26/10/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
27/10/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
28/10/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
29/10/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
30/10/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
31/10/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
01/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
02/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
03/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
04/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
05/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
06/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
07/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
08/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
09/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
10/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
11/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
12/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
13/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
14/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
15/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
16/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
17/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
18/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
19/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
20/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
21/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
22/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
23/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
24/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
25/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
26/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
27/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
28/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
29/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
30/11/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
01/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
02/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
03/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
04/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
05/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
06/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
07/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
08/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
09/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
10/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
11/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
12/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
13/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
14/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
15/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
16/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
17/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
18/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
19/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
20/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
21/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
22/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
23/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
24/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
25/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
26/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
27/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
28/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
29/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
30/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik
31/12/2017	0.3864 37	Baik	11.54027	Sangat Tidak Baik	22.677 32	Sedang	18.929 04244	Sangat Baik	5.7180 22	Sangat Tidak Baik	Sangat Tidak Baik

Hasil Klasifikasi status polusi harian dari hasil peramalan wilayah Surabaya Timur

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
01/01/2017	0.48	Sedang	18.00	Sangat Tidak Baik	72.18	Sangat Baik	43.34	Sangat Tidak Baik	31.87	Sedang	Sangat Tidak Baik
02/01/2017	0.33	Baik	14.97	Sangat Tidak Baik	78.09	Sangat Baik	50.44	Sangat Tidak Baik	32.25	Sedang	Sangat Tidak Baik
03/01/2017	0.36	Baik	14.45	Sangat Tidak Baik	79.75	Sangat Baik	53.59	Sangat Tidak Baik	32.09	Sedang	Sangat Tidak Baik
04/01/2017	0.43	Sedang	14.30	Sangat Tidak Baik	79.92	Sangat Baik	54.61	Sangat Tidak Baik	31.43	Sedang	Sangat Tidak Baik
05/01/2017	0.50	Sedang	14.23	Sangat Tidak Baik	79.76	Sangat Baik	55.15	Sangat Tidak Baik	30.68	Sedang	Sangat Tidak Baik
06/01/2017	0.57	Sedang	14.19	Sangat Tidak Baik	79.53	Sangat Baik	55.55	Sangat Tidak Baik	29.93	Sedang	Sangat Tidak Baik
07/01/2017	0.65	Sedang	14.15	Sangat Tidak Baik	79.27	Sangat Baik	55.91	Sangat Tidak Baik	29.19	Sedang	Sangat Tidak Baik
08/01/2017	0.72	Sedang	14.12	Sangat Tidak Baik	79.01	Sangat Baik	56.24	Sangat Tidak Baik	28.46	Sedang	Sangat Tidak Baik
09/01/2017	0.79	Sedang	14.09	Sangat Tidak Baik	78.74	Sangat Baik	56.55	Sangat Tidak Baik	27.74	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
10/01/2017	0.85	Sedang	14.07	Sangat Tidak Baik	78.47	Sangat Baik	56.84	Sangat Tidak Baik	27.03	Sedang	Sangat Tidak Baik
11/01/2017	0.92	Sedang	14.04	Sangat Tidak Baik	78.20	Sangat Baik	57.12	Sangat Tidak Baik	26.34	Sedang	Sangat Tidak Baik
12/01/2017	0.98	Tidak Baik	14.02	Sangat Tidak Baik	77.93	Sangat Baik	57.38	Sangat Tidak Baik	25.67	Sedang	Sangat Tidak Baik
13/01/2017	1.04	Tidak Baik	14.00	Sangat Tidak Baik	77.68	Sangat Baik	57.62	Sangat Tidak Baik	25.03	Sedang	Sangat Tidak Baik
14/01/2017	1.10	Tidak Baik	13.98	Sangat Tidak Baik	77.43	Sangat Baik	57.84	Sangat Tidak Baik	24.42	Sedang	Sangat Tidak Baik
15/01/2017	1.15	Tidak Baik	13.96	Sangat Tidak Baik	77.21	Sangat Baik	58.04	Sangat Tidak Baik	23.87	Sedang	Sangat Tidak Baik
16/01/2017	1.20	Tidak Baik	13.94	Sangat Tidak Baik	77.00	Sangat Baik	58.21	Sangat Tidak Baik	23.36	Sedang	Sangat Tidak Baik
17/01/2017	1.24	Tidak Baik	13.93	Sangat Tidak Baik	76.82	Sangat Baik	58.35	Sangat Tidak Baik	22.91	Sedang	Sangat Tidak Baik
18/01/2017	1.27	Tidak Baik	13.91	Sangat Tidak Baik	76.66	Sangat Baik	58.48	Sangat Tidak Baik	22.52	Sedang	Sangat Tidak Baik
19/01/2017	1.30	Tidak Baik	13.90	Sangat Tidak Baik	76.52	Sangat Baik	58.58	Sangat Tidak Baik	22.18	Sedang	Sangat Tidak Baik
20/01/2017	1.33	Tidak Baik	13.89	Sangat Tidak Baik	76.41	Sangat Baik	58.66	Sangat Tidak Baik	21.90	Sedang	Sangat Tidak Baik
21/01/2017	1.35	Tidak Baik	13.88	Sangat Tidak Baik	76.31	Sangat Baik	58.73	Sangat Tidak Baik	21.66	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
22/01/2017	1.37	Tidak Baik	13.88	Sangat Tidak Baik	76.23	Sangat Baik	58.78	Sangat Tidak Baik	21.47	Sedang	Sangat Tidak Baik
23/01/2017	1.38	Tidak Baik	13.87	Sangat Tidak Baik	76.16	Sangat Baik	58.82	Sangat Tidak Baik	21.32	Sedang	Sangat Tidak Baik
24/01/2017	1.39	Tidak Baik	13.87	Sangat Tidak Baik	76.11	Sangat Baik	58.84	Sangat Tidak Baik	21.19	Sedang	Sangat Tidak Baik
25/01/2017	1.40	Tidak Baik	13.86	Sangat Tidak Baik	76.07	Sangat Baik	58.87	Sangat Tidak Baik	21.09	Sedang	Sangat Tidak Baik
26/01/2017	1.40	Tidak Baik	13.86	Sangat Tidak Baik	76.04	Sangat Baik	58.88	Sangat Tidak Baik	21.02	Sedang	Sangat Tidak Baik
27/01/2017	1.41	Tidak Baik	13.86	Sangat Tidak Baik	76.01	Sangat Baik	58.90	Sangat Tidak Baik	20.95	Sedang	Sangat Tidak Baik
28/01/2017	1.41	Tidak Baik	13.86	Sangat Tidak Baik	75.99	Sangat Baik	58.91	Sangat Tidak Baik	20.91	Sedang	Sangat Tidak Baik
29/01/2017	1.42	Tidak Baik	13.85	Sangat Tidak Baik	75.97	Sangat Baik	58.91	Sangat Tidak Baik	20.87	Sedang	Sangat Tidak Baik
30/01/2017	1.42	Tidak Baik	13.85	Sangat Tidak Baik	75.96	Sangat Baik	58.92	Sangat Tidak Baik	20.84	Sedang	Sangat Tidak Baik
31/01/2017	1.42	Tidak Baik	13.85	Sangat Tidak Baik	75.95	Sangat Baik	58.92	Sangat Tidak Baik	20.82	Sedang	Sangat Tidak Baik
01/02/2017	1.42	Tidak Baik	13.85	Sangat Tidak Baik	75.95	Sangat Baik	58.93	Sangat Tidak Baik	20.80	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
02/02/2017	1.42	Tidak Baik	13.85	Sangat Tidak Baik	75.94	Sangat Baik	58.93	Sangat Tidak Baik	20.79	Sedang	Sangat Tidak Baik
03/02/2017	1.42	Tidak Baik	13.85	Sangat Tidak Baik	75.94	Sangat Baik	58.93	Sangat Tidak Baik	20.78	Sedang	Sangat Tidak Baik
04/02/2017	1.42	Tidak Baik	13.85	Sangat Tidak Baik	75.93	Sangat Baik	58.93	Sangat Tidak Baik	20.77	Sedang	Sangat Tidak Baik
05/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.93	Sangat Baik	58.93	Sangat Tidak Baik	20.76	Sedang	Sangat Tidak Baik
06/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.93	Sangat Baik	58.94	Sangat Tidak Baik	20.76	Sedang	Sangat Tidak Baik
07/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.93	Sangat Baik	58.94	Sangat Tidak Baik	20.76	Sedang	Sangat Tidak Baik
08/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
09/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
10/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
11/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
12/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
13/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
14/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
15/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
16/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
17/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
18/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
19/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
20/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
21/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
22/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
23/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
24/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
25/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
26/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
27/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
28/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
01/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
02/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
03/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
04/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
05/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
06/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
07/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
08/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
09/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
10/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
11/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
12/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
13/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
14/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
15/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
16/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
17/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
18/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
19/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
...
01/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
02/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
03/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
04/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
05/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
06/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
07/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
08/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
09/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
10/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
11/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
12/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
13/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
14/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
15/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
16/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
17/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
18/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
19/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
20/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
21/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
22/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
23/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
24/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
25/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
26/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
27/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
28/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
29/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
30/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
31/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
01/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
02/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
03/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
04/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
05/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
06/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
07/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
08/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
09/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
10/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
11/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
12/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
13/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
14/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
15/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
16/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
17/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
18/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
19/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
20/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
21/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
22/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
23/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
24/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
25/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
26/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
27/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
28/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
29/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
30/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
01/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
02/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
03/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
04/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
05/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
06/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
07/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
08/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
09/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
10/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
11/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
12/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
13/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
14/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
15/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
16/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
17/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
18/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
19/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
20/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
21/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
22/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
23/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
24/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
25/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
26/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
27/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
28/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
29/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
30/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
31/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik

Hasil klasifikasi dari hasil peramalan wilayah Surabaya Selatan

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
01/01/2017	0.48	Sedang	18.00	Sangat Tidak Baik	72.18	Sangat Baik	43.34	Sangat Tidak Baik	31.87	Sedang	Sangat Tidak Baik
02/01/2017	0.33	Baik	14.97	Sangat Tidak Baik	78.09	Sangat Baik	50.44	Sangat Tidak Baik	32.25	Sedang	Sangat Tidak Baik
03/01/2017	0.36	Baik	14.45	Sangat Tidak Baik	79.75	Sangat Baik	53.59	Sangat Tidak Baik	32.09	Sedang	Sangat Tidak Baik
04/01/2017	0.43	Sedang	14.30	Sangat Tidak Baik	79.92	Sangat Baik	54.61	Sangat Tidak Baik	31.43	Sedang	Sangat Tidak Baik
05/01/2017	0.50	Sedang	14.23	Sangat Tidak Baik	79.76	Sangat Baik	55.15	Sangat Tidak Baik	30.68	Sedang	Sangat Tidak Baik
06/01/2017	0.57	Sedang	14.19	Sangat Tidak Baik	79.53	Sangat Baik	55.55	Sangat Tidak Baik	29.93	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
07/01/2017	0.65	Sedang	14.15	Sangat Tidak Baik	79.27	Sangat Baik	55.91	Sangat Tidak Baik	29.19	Sedang	Sangat Tidak Baik
08/01/2017	0.72	Sedang	14.12	Sangat Tidak Baik	79.01	Sangat Baik	56.24	Sangat Tidak Baik	28.46	Sedang	Sangat Tidak Baik
09/01/2017	0.79	Sedang	14.09	Sangat Tidak Baik	78.74	Sangat Baik	56.55	Sangat Tidak Baik	27.74	Sedang	Sangat Tidak Baik
10/01/2017	0.85	Sedang	14.07	Sangat Tidak Baik	78.47	Sangat Baik	56.84	Sangat Tidak Baik	27.03	Sedang	Sangat Tidak Baik
11/01/2017	0.92	Sedang	14.04	Sangat Tidak Baik	78.20	Sangat Baik	57.12	Sangat Tidak Baik	26.34	Sedang	Sangat Tidak Baik
12/01/2017	0.98	Tidak Baik	14.02	Sangat Tidak Baik	77.93	Sangat Baik	57.38	Sangat Tidak Baik	25.67	Sedang	Sangat Tidak Baik
13/01/2017	1.04	Tidak Baik	14.00	Sangat Tidak Baik	77.68	Sangat Baik	57.62	Sangat Tidak Baik	25.03	Sedang	Sangat Tidak Baik
14/01/2017	1.10	Tidak Baik	13.98	Sangat Tidak Baik	77.43	Sangat Baik	57.84	Sangat Tidak Baik	24.42	Sedang	Sangat Tidak Baik
15/01/2017	1.15	Tidak Baik	13.96	Sangat Tidak Baik	77.21	Sangat Baik	58.04	Sangat Tidak Baik	23.87	Sedang	Sangat Tidak Baik
16/01/2017	1.20	Tidak Baik	13.94	Sangat Tidak Baik	77.00	Sangat Baik	58.21	Sangat Tidak Baik	23.36	Sedang	Sangat Tidak Baik
17/01/2017	1.24	Tidak Baik	13.93	Sangat Tidak Baik	76.82	Sangat Baik	58.35	Sangat Tidak Baik	22.91	Sedang	Sangat Tidak Baik
18/01/2017	1.27	Tidak Baik	13.91	Sangat Tidak Baik	76.66	Sangat Baik	58.48	Sangat Tidak Baik	22.52	Sedang	Sangat Tidak Baik
19/01/2017	1.30	Tidak Baik	13.90	Sangat Tidak Baik	76.52	Sangat Baik	58.58	Sangat Tidak Baik	22.18	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
20/01/2017	1.33	Tidak Baik	13.89	Sangat Tidak Baik	76.41	Sangat Baik	58.66	Sangat Tidak Baik	21.90	Sedang	Sangat Tidak Baik
21/01/2017	1.35	Tidak Baik	13.88	Sangat Tidak Baik	76.31	Sangat Baik	58.73	Sangat Tidak Baik	21.66	Sedang	Sangat Tidak Baik
22/01/2017	1.37	Tidak Baik	13.88	Sangat Tidak Baik	76.23	Sangat Baik	58.78	Sangat Tidak Baik	21.47	Sedang	Sangat Tidak Baik
23/01/2017	1.38	Tidak Baik	13.87	Sangat Tidak Baik	76.16	Sangat Baik	58.82	Sangat Tidak Baik	21.32	Sedang	Sangat Tidak Baik
24/01/2017	1.39	Tidak Baik	13.87	Sangat Tidak Baik	76.11	Sangat Baik	58.84	Sangat Tidak Baik	21.19	Sedang	Sangat Tidak Baik
25/01/2017	1.40	Tidak Baik	13.86	Sangat Tidak Baik	76.07	Sangat Baik	58.87	Sangat Tidak Baik	21.09	Sedang	Sangat Tidak Baik
26/01/2017	1.40	Tidak Baik	13.86	Sangat Tidak Baik	76.04	Sangat Baik	58.88	Sangat Tidak Baik	21.02	Sedang	Sangat Tidak Baik
27/01/2017	1.41	Tidak Baik	13.86	Sangat Tidak Baik	76.01	Sangat Baik	58.90	Sangat Tidak Baik	20.95	Sedang	Sangat Tidak Baik
28/01/2017	1.41	Tidak Baik	13.86	Sangat Tidak Baik	75.99	Sangat Baik	58.91	Sangat Tidak Baik	20.91	Sedang	Sangat Tidak Baik
29/01/2017	1.42	Tidak Baik	13.85	Sangat Tidak Baik	75.97	Sangat Baik	58.91	Sangat Tidak Baik	20.87	Sedang	Sangat Tidak Baik
30/01/2017	1.42	Tidak Baik	13.85	Sangat Tidak Baik	75.96	Sangat Baik	58.92	Sangat Tidak Baik	20.84	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
31/01/2017	1.42	Tidak Baik	13.85	Sangat Tidak Baik	75.95	Sangat Baik	58.92	Sangat Tidak Baik	20.82	Sedang	Sangat Tidak Baik
01/02/2017	1.42	Tidak Baik	13.85	Sangat Tidak Baik	75.95	Sangat Baik	58.93	Sangat Tidak Baik	20.80	Sedang	Sangat Tidak Baik
02/02/2017	1.42	Tidak Baik	13.85	Sangat Tidak Baik	75.94	Sangat Baik	58.93	Sangat Tidak Baik	20.79	Sedang	Sangat Tidak Baik
03/02/2017	1.42	Tidak Baik	13.85	Sangat Tidak Baik	75.94	Sangat Baik	58.93	Sangat Tidak Baik	20.78	Sedang	Sangat Tidak Baik
04/02/2017	1.42	Tidak Baik	13.85	Sangat Tidak Baik	75.93	Sangat Baik	58.93	Sangat Tidak Baik	20.77	Sedang	Sangat Tidak Baik
05/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.93	Sangat Baik	58.93	Sangat Tidak Baik	20.76	Sedang	Sangat Tidak Baik
06/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.93	Sangat Baik	58.94	Sangat Tidak Baik	20.76	Sedang	Sangat Tidak Baik
07/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.93	Sangat Baik	58.94	Sangat Tidak Baik	20.76	Sedang	Sangat Tidak Baik
08/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
09/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
10/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
11/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
12/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
13/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
14/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
15/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
16/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
17/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
18/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
19/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
20/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
21/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
22/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik
23/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.75	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
24/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
25/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
26/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
27/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
28/02/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
01/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
02/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
03/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
04/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
05/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
06/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
07/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
08/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
09/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
10/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
11/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
12/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
13/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
14/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
15/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
16/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
17/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
18/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
19/03/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
...
01/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
02/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
03/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
04/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
05/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
06/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
07/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
08/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
09/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
10/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
11/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
12/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
13/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
14/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
15/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
16/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
17/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
18/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
19/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
20/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
21/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
22/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
23/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
24/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
25/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
26/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
27/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
28/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
29/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
30/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
31/10/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
01/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
02/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
03/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
04/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
05/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
06/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
07/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
08/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
09/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
10/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
11/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
12/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
13/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
14/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
15/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
16/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
17/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
18/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
19/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
20/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
21/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
22/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
23/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
24/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
25/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
26/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
27/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
28/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
29/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
30/11/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
01/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
02/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
03/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
04/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
05/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
06/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
07/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
08/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
09/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
10/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
11/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
12/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
13/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
14/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
15/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
16/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
17/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
18/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
19/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
20/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
21/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik

Tanggal	CO	prediksi_co	NO2	prediksi_no2	O3	prediksi_o3	PM10	prediksi_pm10	SO2	prediksi_so2	status_polusi
22/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
23/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
24/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
25/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
26/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
27/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
28/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
29/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
30/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik
31/12/2017	1.43	Tidak Baik	13.85	Sangat Tidak Baik	75.92	Sangat Baik	58.94	Sangat Tidak Baik	20.74	Sedang	Sangat Tidak Baik

D-D-1