

**PEMODELAN KANDUNGAN *PARTICULATE MATTER* 10 DAN 2.5 DALAM  
PENCEMARAN UDARA PROVINSI DKI JAKARTA MENGGUNAKAN  
METODE ARIMA**

**SKRIPSI**



**UIN SUNAN AMPEL  
S U R A B A Y A**

Disusun Oleh  
**ELOK INDANA ZULFA**  
**H02219007**

**PROGRAM STUDI MATEMATIKA  
FAKULTAS SAINS DAN TEKNOLOGI  
UNIVERSITAS ISLAM NEGERI SUNAN AMPEL  
SURABAYA**

**2023**

## PERNYATAAN KEASLIAN

Saya yang bertanda tangan di bawah ini,

Nama : ELOK INDANA ZULFA

NIM : H02219007

Program Studi : Matematika

Angkatan : 2019

Menyatakan bahwa saya tidak melakukan plagiat dalam penulisan skripsi saya yang berjudul "PEMODELAN KANDUNGAN *PARTICULATE MATTER* 10 DAN 2.5 DALAM PENCEMARAN UDARA PROVINSI DKI JAKARTA MENGGUNAKAN METODE ARIMA". Apabila suatu saat nanti terbukti saya melakukan tindakan plagiat, maka saya bersedia menerima sanksi yang telah ditetapkan.

Demikian pernyataan keaslian ini saya buat dengan sebenar-benarnya.

Surabaya, 21 Juni 2023

Yang menyatakan,



ELOK INDANA ZULFA  
NIM. H02219007

## LEMBAR PERSETUJUAN PEMBIMBING

skripsi oleh

Nama : ELOK INDANA ZULFA  
NIM : H02219007  
Judul skripsi : PEMODELAN KANDUNGAN *PARTICULATE MATTER*  
10 DAN 2.5 DALAM PENCEMARAN UDARA  
PROVINSI DKI JAKARTA MENGGUNAKAN METODE  
ARIMA

telah diperiksa dan disetujui untuk diujikan.


Pembimbing I

  
Dr. Abdulloh Hamid, M. Pd  
NIP. 198508282014031003

Pembimbing II

  
Putroue Keumala Intan, M.Si  
NIP. 198805282018012001

Mengetahui,  
Ketua Program Studi Matematika  
UIN Sunan Ampel Surabaya

  
Yuniar Farida, M.T  
NIP. 197905272014032002

## PENGESAHAN TIM PENGUJI SKRIPSI

Skripsi oleh

Nama : ELOK INDANA ZULFA  
NIM : H02219007  
Judul Skripsi : PEMODELAN KANDUNGAN *PARTICULATE MATTER*  
10 DAN 2.5 DALAM PENCEMARAN UDARA  
PROVINSI DKI JAKARTA MENGGUNAKAN  
METODE ARIMA

Telah dipertahankan di depan Tim Penguji

pada tanggal 21 Juni 2023

Mengesahkan,

Tim Penguji

Penguji I

Yuniar Farida, M. T  
NIP. 197905272014032002

Penguji II

Hani Khaulasari, M. Si  
NIP. 199102092020122011

Penguji III

Dr. Abdullloh Hamid, M. Pd  
NIP. 198508282014031003

Penguji IV

Putroue Keumala Intan, M. Si  
NIP. 198805282018012001

Mengetahui,

Dekan Fakultas Sains dan Teknologi

UIN Sunan Ampel Surabaya



Dr. A. Saepul Hamdani, M.Pd

NIP. 196507312000031002



UIN SUNAN AMPEL  
SURABAYA

KEMENTERIAN AGAMA  
UNIVERSITAS ISLAM NEGERI SUNAN AMPEL SURABAYA  
PERPUSTAKAAN

Jl. Jend. A. Yani 117 Surabaya 60237 Telp. 031-8431972 Fax.031-8413300  
E-Mail: perpus@uinsby.ac.id

LEMBAR PERNYATAAN PERSETUJUAN PUBLIKASI  
KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS

Sebagai sivitas akademika UIN Sunan Ampel Surabaya, yang bertanda tangan di bawah ini, saya:

Nama : ELOK INDANA ZULFA  
NIM : 402219007  
Fakultas/Jurusan : SAINS DAN TEKNOLOGI / MATEMATIKA  
E-mail address : elok1508@gmail.com

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Perpustakaan UIN Sunan Ampel Surabaya, Hak Bebas Royalti Non-Eksklusif atas karya ilmiah :

Skripsi  Tesis  Disertasi  Lain-lain (.....)

yang berjudul :

PEMODELAN KANDUNGAN PARTICULATE MATTER 10 DAN 2.5

DALAM PENCEMARAN UDARA PROVINSI DKI JAKARTA

MENGGUNAKAN METODE ARIMA

beserta perangkat yang diperlukan (bila ada). Dengan Hak Bebas Royalti Non-Eksklusif ini Perpustakaan UIN Sunan Ampel Surabaya berhak menyimpan, mengalih-media/format-kan, mengelolanya dalam bentuk pangkalan data (database), mendistribusikannya, dan menampilkan/mempublikasikannya di Internet atau media lain secara *fulltext* untuk kepentingan akademis tanpa perlu meminta ijin dari saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan atau penerbit yang bersangkutan.

Saya bersedia untuk menanggung secara pribadi, tanpa melibatkan pihak Perpustakaan UIN Sunan Ampel Surabaya, segala bentuk tuntutan hukum yang timbul atas pelanggaran Hak Cipta dalam karya ilmiah saya ini.

Demikian pernyataan ini yang saya buat dengan sebenarnya.

Surabaya, 21 JUNI 2023

Penulis

( ELOK INDANA ZULFA )

## ABSTRAK

### PEMODELAN KANDUNGAN *PARTICULATE MATTER* 10 DAN 2.5 DALAM PENCEMARAN UDARA PROVINSI DKI JAKARTA MENGGUNAKAN METODE ARIMA

DKI Jakarta merupakan salah satu kota besar yang dijadikan sebagai sasaran untuk merantau seperti mencari pekerjaan atau dalam hal pendidikan. Hal tersebut menjadikan DKI Jakarta semakin padat penduduk dan dapat menyebabkan pencemaran udara dari sektor transportasi maupun industri. Pencemaran udara merupakan tercampurnya zat berbahaya ke dalam udara yang sangat membahayakan makhluk hidup. Kandungan pencemaran udara yang paling berdampak pada kesehatan manusia adalah *Particulate Matter* (PM). PM dengan jumlah berlebih dapat menyebabkan kematian serta rusaknya gas rumah kaca di bumi. Penelitian ini bertujuan untuk membuat model matematis yang dapat digunakan untuk mencari nilai prediksi kandungan *Particulate Matter* pada periode mendatang. Model ARIMA terbaik yang didapatkan dari masing-masing stasiun pengamatan menghasilkan nilai MAPE yang bernilai 20% – 50%. Jika digunakan untuk memprediksi maka hasil yang didapatkan termasuk dalam kategori cukup baik.

**Kata kunci:** Pencemaran Udara, *Particulate Matter*, Pemodelan, ARIMA

UIN SUNAN AMPEL  
S U R A B A Y A

## ABSTRACT

### MODELING OF PARTICULATE MATTER CONTENT 10 AND 2.5 IN AIR POLLUTION IN DKI JAKARTA PROVINCE USING ARIMA METHOD

DKI Jakarta is one of the big cities that is used as a target for migrating, such as looking for work or in terms of education. This makes DKI Jakarta more densely populated and can cause air pollution from the transportation and industrial sectors. Air pollution is the mixing of harmful substances into the air which is very harmful to living things. The content of air pollution that has the most impact on human health is *Particulate Matter* (PM). PM with excess amounts can cause death and damage to greenhouse gases on earth. This study aims to create a mathematical model that can be used to find the predicted value of *Particulate Matter* content in the coming period. The best ARIMA model obtained from each observation station produces a MAPE value of 20% – 50%. If it is used to predict, the results obtained are included in the pretty good category.

**Keywords:** Air Pollution, *Particulate Matter*, Modeling, ARIMA

UIN SUNAN AMPEL  
S U R A B A Y A

## DAFTAR ISI

<b>HALAMAN JUDUL</b> . . . . .	<b>i</b>
<b>PENGESAHAN TIM PENGUJI SKRIPSI</b> . . . . .	<b>iii</b>
<b>HALAMAN PERNYATAAN KEASLIAN</b> . . . . .	<b>iv</b>
<b>MOTTO</b> . . . . .	<b>v</b>
<b>HALAMAN PERSEMBAHAN</b> . . . . .	<b>vi</b>
<b>KATA PENGANTAR</b> . . . . .	<b>vii</b>
<b>DAFTAR ISI</b> . . . . .	<b>ix</b>
<b>DAFTAR TABEL</b> . . . . .	<b>xii</b>
<b>DAFTAR GAMBAR</b> . . . . .	<b>xiii</b>
<b>ABSTRAK</b> . . . . .	<b>xv</b>
<b>ABSTRACT</b> . . . . .	<b>xvi</b>
<b>I PENDAHULUAN</b> . . . . .	<b>1</b>
1.1. Latar Belakang Masalah . . . . .	1
1.2. Rumusan Masalah . . . . .	9
1.3. Tujuan Penelitian . . . . .	9
1.4. Manfaat Penelitian . . . . .	9
1.5. Batasan Masalah . . . . .	10
1.6. Sistematika Penulisan . . . . .	10
<b>II TINJAUAN PUSTAKA</b> . . . . .	<b>12</b>
2.1. Pencemaran Udara . . . . .	12
2.2. <i>Particulate Matter</i> (PM) . . . . .	13
2.3. <i>Autoregressive Integrated Moving Average</i> (ARIMA) . . . . .	14
2.4. Stasioneritas . . . . .	19
2.5. <i>Autocorrelation Function</i> (ACF) . . . . .	21
2.6. <i>Partial Autocorrelation Function</i> (PACF) . . . . .	22



2.7. Identifikasi Model . . . . .	23
2.8. Estimasi Parameter . . . . .	24
2.9. Uji Asumsi Residual . . . . .	25
2.10. Deteksi <i>Outlier</i> . . . . .	27
2.11. <i>Mean Absolute Percentage Error</i> (MAPE) . . . . .	30
2.12. Integrasi Keilmuan . . . . .	32
<b>III METODE PENELITIAN . . . . .</b>	<b>38</b>
3.1. Jenis Penelitian dan Sumber Data . . . . .	38
3.2. Analisis Data . . . . .	38
3.3. Tahapan Penelitian . . . . .	39
<b>IV HASIL DAN PEMBAHASAN . . . . .</b>	<b>43</b>
4.1. Karakteristik Data . . . . .	43
4.1.1. Karakteristik Data Kandungan <i>Particulate Matter</i> 10 (PM <sub>10</sub> ) . . . . .	43
4.1.2. Karakteristik Data Kandungan <i>Particulate Matter</i> 2.5 (PM <sub>2.5</sub> ) . . . . .	46
4.2. Proses ARIMA <i>Particulate Matter</i> 10 (PM <sub>10</sub> ) . . . . .	49
4.3. Nilai Akurasi dan Model ARIMA . . . . .	53
4.3.1. Nilai Akurasi dan Model ARIMA PM <sub>10</sub> DKI1 . . . . .	53
4.3.2. Nilai Akurasi dan Model ARIMA PM <sub>10</sub> DKI2 . . . . .	55
4.3.3. Nilai Akurasi dan Model ARIMA PM <sub>10</sub> DKI3 . . . . .	56
4.3.4. Nilai Akurasi dan Model ARIMA PM <sub>10</sub> DKI4 . . . . .	58
4.3.5. Nilai Akurasi dan Model ARIMA PM <sub>10</sub> DKI5 . . . . .	59
4.4. Proses ARIMA <i>Particulate Matter</i> 2.5 (PM <sub>2.5</sub> ) . . . . .	61
4.5. Nilai Akurasi dan Model ARIMA Kandungan PM <sub>2.5</sub> . . . . .	67
4.5.1. Nilai Akurasi dan Model ARIMA PM <sub>2.5</sub> DKI1 . . . . .	67
4.5.2. Nilai Akurasi dan Model ARIMA PM <sub>2.5</sub> DKI2 . . . . .	69
4.5.3. Nilai Akurasi dan Model ARIMA PM <sub>2.5</sub> DKI3 . . . . .	71
4.5.4. Nilai Akurasi dan Model ARIMA PM <sub>2.5</sub> DKI4 . . . . .	73
4.5.5. Nilai Akurasi dan Model ARIMA PM <sub>2.5</sub> DKI5 . . . . .	74

<b>V PENUTUP</b> . . . . .	<b>79</b>
5.1. Kesimpulan . . . . .	79
5.2. Saran . . . . .	80
<b>DAFTAR PUSTAKA</b> . . . . .	<b>80</b>



UIN SUNAN AMPEL  
S U R A B A Y A

## DAFTAR TABEL

2.1	Jenis Transformasi . . . . .	20
2.2	Plot ACF dan PACF . . . . .	24
2.3	Kriteria Nilai MAPE . . . . .	31
4.1	Karakteristik Data Kandungan <i>Particulate Matter</i> 10 ( $PM_{10}$ ) . . . . .	43
4.2	Karakteristik Data Kandungan <i>Particulate Matter</i> 2.5 ( $PM_{2.5}$ ) . . . . .	46
4.3	Kombinasi Model ARIMA Kandungan $PM_{10}$ DKI1 . . . . .	51
4.4	Uji Asumsi Residual ARIMA(1,1,1) $PM_{10}$ Stasiun DKI1 . . . . .	52
4.5	Nilai akurasi Kandungan $PM_{10}$ DKI1 . . . . .	54
4.6	Nilai akurasi Kandungan $PM_{10}$ DKI2 . . . . .	55
4.7	Nilai akurasi Kandungan $PM_{10}$ DKI3 . . . . .	57
4.8	Nilai akurasi Kandungan $PM_{10}$ DKI4 . . . . .	58
4.9	Nilai akurasi Kandungan $PM_{10}$ DKI5 . . . . .	60
4.10	Kombinasi Model ARIMA Kandungan $PM_{2.5}$ DKI1 . . . . .	64
4.11	Uji Asumsi Residual ARIMA(1,1,0) $PM_{2.5}$ Stasiun DKI1 . . . . .	65
4.12	Deteksi <i>Outlier</i> ARIMA(1, 1, 0) Kandungan $PM_{2.5}$ DKI1 . . . . .	66
4.13	Uji Asumsi Residual ARIMA(1,1,0) dengan <i>outlier</i> . . . . .	67
4.14	Nilai akurasi Kandungan $PM_{2.5}$ DKI1 . . . . .	68
4.15	Nilai akurasi Kandungan $PM_{2.5}$ DKI2 . . . . .	70
4.16	Nilai akurasi Kandungan $PM_{2.5}$ DKI3 . . . . .	71
4.17	Nilai akurasi Kandungan $PM_{2.5}$ DKI4 . . . . .	73
4.18	Nilai akurasi Kandungan $PM_{2.5}$ DKI5 . . . . .	74

## DAFTAR GAMBAR

2.1	Pola ACF Belum Stasioner . . . . .	22
2.2	Pola ACF Sudah Stasioner . . . . .	22
2.3	Pola PACF Belum Stasioner . . . . .	23
2.4	Pola PACF Sudah Stasioner . . . . .	23
3.1	Tahapan Penelitian . . . . .	42
4.1	Grafik Karakteristik Data Kandungan PM <sub>10</sub> . . . . .	44
4.2	Plot <i>Time Series</i> Kandungan PM <sub>10</sub> Pada Lima Stasiun Pengamatan . . .	45
4.3	Grafik Karakteristik Data Kandungan PM <sub>2.5</sub> . . . . .	47
4.4	Plot <i>Time Series</i> Kandungan PM <sub>2.5</sub> Pada Lima Stasiun Pengamatan . . .	48
4.5	<i>Box-Cox</i> Plot PM <sub>10</sub> Stasiun DKI1 . . . . .	49
4.6	Plot ACF PM <sub>10</sub> Stasiun DKI1 . . . . .	50
4.7	<i>Time Series</i> Plot Hasil <i>Differencing</i> PM <sub>10</sub> Stasiun DKI1 . . . . .	50
4.8	Plot ACF setelah <i>Differencing</i> PM <sub>10</sub> DKI1 . . . . .	51
4.9	Plot PACF setelah <i>Differencing</i> PM <sub>10</sub> DKI1 . . . . .	51
4.10	Plot Data <i>Outsample</i> dan Hasil Prediksi Kandungan PM <sub>10</sub> Stasiun DKI1	54
4.11	Plot Data <i>Outsample</i> dan Hasil Prediksi Kandungan PM <sub>10</sub> Stasiun DKI2	56
4.12	Plot Data <i>Outsample</i> dan Hasil Prediksi Kandungan PM <sub>10</sub> Stasiun DKI3	57
4.13	Plot Data <i>Outsample</i> dan Hasil Prediksi Kandungan PM <sub>10</sub> Stasiun DKI4	59
4.14	Plot Data <i>Outsample</i> dan Hasil Prediksi Kandungan PM <sub>10</sub> Stasiun DKI5	60
4.15	<i>Box-Cox</i> Plot PM <sub>2.5</sub> Stasiun DKI1 . . . . .	61
4.16	<i>Box-Cox</i> Plot Setelah di Transformasi PM <sub>2.5</sub> Stasiun DKI1 . . . . .	62
4.17	Plot ACF PM <sub>2.5</sub> Stasiun DKI1 . . . . .	62
4.18	<i>Time Series</i> Plot Hasil <i>Differencing</i> PM <sub>2.5</sub> Stasiun DKI1 . . . . .	63

4.19	Plot ACF setelah <i>Differencing</i> $PM_{2.5}$ DKI1 . . . . .	63
4.20	Plot PACF setelah <i>Differencing</i> $PM_{2.5}$ DKI1 . . . . .	63
4.21	Boxplot Residual ARIMA(1,1,0) Kandungan $PM_{10}$ DKI1 . . . . .	66
4.22	Plot Data <i>Outsample</i> dan Hasil Prediksi Kandungan $PM_{2.5}$ Stasiun DKI1	69
4.23	Plot Data <i>Outsample</i> dan Hasil Prediksi Kandungan $PM_{2.5}$ Stasiun DKI2	71
4.24	Plot Data <i>Outsample</i> dan Hasil Prediksi Kandungan $PM_{2.5}$ Stasiun DKI3	72
4.25	Plot Data <i>Outsample</i> dan Hasil Prediksi Kandungan $PM_{2.5}$ Stasiun DKI4	74
4.26	Plot Data <i>Outsample</i> dan Hasil Prediksi Kandungan $PM_{2.5}$ Stasiun DKI5	75



UIN SUNAN AMPEL  
S U R A B A Y A

# BAB I

## PENDAHULUAN

### 1.1. Latar Belakang Masalah

Udara merupakan gabungan gas dalam lapisan yang berputar mengelilingi bumi dengan sifat fisik tak terlihat oleh mata, tidak memiliki bau, dan tidak ada rasanya (Purba and Harefa, 2020). Udara penting bagi kehidupan di bumi karena oksigen yang terkandung di dalamnya diperlukan oleh makhluk hidup untuk melakukan proses metabolisme dalam menjaga kelangsungan hidupnya (Umri et al., 2021). Udara yang bersih sangat bermanfaat bagi manusia karena dapat membersihkan paru-paru dari udara kotor dan membuat jantung lebih kuat serta lancar dalam mengalirkan darah ke seluruh tubuh manusia (Abidin and Hasibuan, 2019). Namun, udara juga dapat membahayakan makhluk hidup yang disebut udara tercemar.

Udara tercemar merupakan udara yang mengandung zat berbahaya sehingga akan berdampak negatif dan dapat menimbulkan masalah kesehatan seperti pneumonia, sesak nafas, gangguan pada paru-paru, dan penyebab munculnya kanker yang membahayakan (Li et al., 2020). Udara yang tercemar juga dapat menularkan penyakit tuberkulosis dari udara. Hal tersebut sangat membahayakan manusia karena dapat menyebabkan kematian (Muslimah, 2019). Jika kandungan udara yang kotor lebih banyak dari kandungan udara bersih, akan menimbulkan pencemaran udara.

Sebagaimana firman Allah Swt yang berbunyi:

وَمَا أَصَابَكُمْ مِّنْ مُّصِيبَةٍ فَبِمَا كَسَبَتْ أَيْدِيكُمْ وَيَعْفُوا عَنْ كَثِيرٍ

Artinya: “Dan musibah apa pun yang menimpa kamu adalah karena perbuatan tanganmu sendiri, dan Allah memaafkan banyak (dari kesalahan-kesalahanmu)” (Qs. Asy-Syura : 30)

Pada ayat di atas menjelaskan bahwa permasalahan apapun yang terjadi di lingkungan sekitar manusia karena perbuatan manusia itu sendiri. Pencemaran udara berupa zat yang berwujud kimia maupun biologi pada lapisan bumi yang berbahaya untuk makhluk hidup. Pencemaran udara muncul dikarenakan oleh aktivitas transportasi, pengoperasian pabrik industri, dan pembuangan limbah rumah tangga yang berdampak bagi kesehatan manusia hingga dapat menyebabkan kematian (Li et al., 2020). Manusia menggunakan kendaraan bermotor untuk melakukan aktivitas sehari-hari dan tanpa mereka sadari kendaraan bermotor tersebut mengeluarkan asap dari knalpot yang merupakan gas pembuangan dari kendaraan bermotor yang dapat menimbulkan polusi udara. Permasalahan lain tentang udara dapat ditimbulkan dari membakar sampah untuk mengurangi sampah plastik, hal tersebut dapat meningkatkan pencemaran udara yang terjadi. Menurut *World Health Organization* (WHO), setiap hari terdapat 8 juta kematian di seluruh dunia yang disebabkan oleh pencemaran udara. (WHO, 2012). Selain menimbulkan berbagai penyakit dan kematian, pencemaran udara yang terjadi dapat menurunkan kualitas udara (Nurwita et al., 2021).

Kualitas udara memiliki 6 parameter yang digunakan untuk menilai kondisi

udara ambien yaitu CO, NO<sub>2</sub>, O<sub>3</sub>, SO<sub>2</sub>, *Particulate Matter* 10 dan 2.5. CO adalah suatu senyawa kimia yang terbentuk ketika bahan bakar, gas alam, maupun minyak tidak terbakar secara sempurna. Sama halnya dengan CO, NO<sub>2</sub> juga terbentuk melalui reaksi antara oksigen dan nitrogen di udara selama pembakaran bahan bakar fosil pada suhu tinggi, dalam kondisi tersebut CO dan NO<sub>2</sub> dapat terbentuk bersamaan misalnya pada emisi kendaraan bermotor (Jusoh and Hamid, 2020). O<sub>3</sub> merupakan suatu molekul yang digunakan sebagai bahan pengoksidasi yang aman karena dapat melindungi bumi dari sinar UV (Murdianto and Pranoto, 2018). Tetapi pada lapisan yang paling dekat dengan bumi, O<sub>3</sub> dianggap sebuah polutan yang dipengaruhi oleh tingginya kandungan NO<sub>2</sub>. SO<sub>2</sub> merujuk pada unsur belerang yang disebabkan dari sisa pembakaran bahan bakar fosil berbau tajam (Wijiarti et al., 2016). Polutan yang berdampak besar bagi kesehatan manusia adalah *Particulate Matter* (PM) (Perdana et al., 2023).

*Particulate Matter* (PM) merupakan sebuah komponen dalam udara semacam gas, asap, maupun debu. *Particulate Matter* dibedakan berdasarkan ukurannya menjadi dua macam yaitu PM<sub>10</sub> dan PM<sub>2.5</sub>. PM<sub>10</sub> merupakan partikel kasar berdiameter <10 μm berasal dari debu yang terangkat dari permukaan jalan, sisa dari pengoperasian pabrik industri maupun pertanian, maupun melalui bioaerosol. Sementara itu, PM<sub>2.5</sub> merupakan partikel halus dengan diameter sebesar <2.5 μm yang timbul karena emisi pada proses pembakaran serta terbentuk melalui proses kimia pada atmosfer bumi (Perdana et al., 2023). *Particulate Matter* memiliki ukuran yang sangat kecil sehingga partikel tersebut sangat mudah untuk masuk ke saluran pernapasan manusia yang dapat menimbulkan penyakit hingga kematian (Arba and Mustafa, 2022).



*World Health Organization* (WHO) menetapkan bahwa batas maksimum  $PM_{10}$  dan  $PM_{2.5}$  dalam 24 jam berturut-turut sebesar  $50\mu g/m^3$  dan  $25\mu g/m^3$ . Setiap peningkatan  $10\mu g/m^3$  kandungan *Particulate Matter* 10 dan 2.5 dalam rumah berturut-turut dapat menyebabkan kematian akibat kardiovaskuler sebanyak 0.36% dan 0.63% serta akibat masalah sistem pernapasan sebanyak 0.42% dan 0.75% (Perdana et al., 2023). Selain itu, dampak dari PM dalam jangka waktu pendek dapat menyebabkan iritasi pada saluran pernapasan seperti pilek dan sesak napas, meningkatkan tekanan darah, hingga resiko terjadinya penyakit jantung koroner. Sedangkan dalam jangka waktu panjang, PM dapat menyebabkan turunnya fungsi paru-paru, asma, bronkitis kronis, jantung koroner, stroke, hingga kematian (Mursinto and Kusumawardani, 2016). Seluruh parameter yaitu CO, NO<sub>2</sub>, O<sub>3</sub>, SO<sub>2</sub>, dan PM berperan besar dalam terbentuknya emisi gas rumah kaca. Gas rumah kaca merupakan pelindung bumi dalam menyerap radiasi matahari pada atmosfer supaya suhu pada permukaan bumi tetap hangat. Namun, jika gas rumah kaca berlebihan dapat menyebabkan pemanasan global (Rahmadania, 2022). Pemanasan global berdampak pada peningkatan suhu di bumi sehingga terjadi kemarau yang lebih panjang serta berdampak pada kesehatan manusia (Haryanti et al., 2022).

DKI Jakarta merupakan salah satu provinsi yang berpenduduk padat karena menjadi ibu kota yang seringkali dijadikan tujuan untuk merantau baik dalam pekerjaan maupun pendidikan. Kepadatan penduduk yang tersebar pada lima kota di provinsi DKI Jakarta menyebabkan naiknya pencemaran udara baik dari sektor industri maupun transportasi. Dinas Lingkungan Hidup (DLH) provinsi DKI Jakarta menyatakan bahwa buruknya kualitas udara di Jakarta disebabkan oleh meningkatnya

penggunaan kendaraan bermotor. Pengamatan terhadap kualitas udara yang telah dilakukan memperlihatkan bahwa pencemaran udara di Jakarta berada dalam level di atas tingkat kesehatan serta melewati batas maksimum yang telah ditetapkan (Ruhiat et al., 2019). IQAir atau perusahaan internasional yang bergerak dalam bidang teknologi untuk memantau kualitas udara menyatakan bahwa udara di Jakarta terburuk di dunia, karena nilai konsentrasi partikel PM di udara setiap harinya melewati batas maksimum sampai meningkat 10 kali lipat dari nilai panduan kualitas udara yang ditetapkan oleh Organisasi Kesehatan Dunia atau WHO (IQAir, 2023). Kandungan PM di DKI Jakarta jika dibandingkan dengan parameter lain sangatlah berbeda, karena kandungan PM di Jakarta sangat tinggi setiap harinya yang disebabkan karena banyaknya kendaraan bermotor yang beroperasi di sepanjang jalan dan pabrik industri yang masih mengeluarkan limbah pabrik sehingga menimbulkan polusi dan pencemaran udara.

Di provinsi DKI Jakarta terdapat *Air Quality Monitoring System* (AQMS) sejak tahun 2010 untuk pemantauan terhadap kualitas udara secara langsung dan dilakukan melalui 5 stasiun pengamatan yang tersebar di wilayah kota Jakarta. Stasiun pengamatan tersebut meliputi stasiun DKI1, stasiun DKI2, stasiun DKI3, stasiun DKI4, dan stasiun DKI5 yang datanya tersedia pada situs resmi Open Data Jakarta (DLHJakarta, 2020). Pemantauan untuk periode kedepan perlu dilakukan untuk melihat seberapa banyak kandungan *Particulate Matter* 10 dan 2.5 di wilayah provinsi DKI Jakarta. Hal tersebut dilakukan untuk mengantisipasi manusia dalam mencegah pencemaran udara di provinsi DKI Jakarta. Pencegahan pencemaran udara bisa dengan bermacam cara, misalnya penghijauan pada lahan yang tandus agar pohon tersebut

dapat mengubah karbondioksida menjadi oksigen sehingga udara yang dihasilkan merupakan udara bersih. Sebagaimana hadis Nabi Muhammad SAW:

حَدَّثَنَا قُتَيْبَةُ بْنُ سَعِيدٍ حَدَّثَنَا أَبُو عَوَانَةَ وَحَدَّثَنِي عَبْدُ الرَّحْمَنِ بْنُ  
 الْمُبَارَكِ حَدَّثَنَا أَبُو عَوَانَةَ عَنْ قَتَادَةَ عَنْ أَنَسِ بْنِ مَالِكٍ رَضِيَ اللَّهُ  
 عَنْهُ قَالَ قَالَ رَسُولُ اللَّهِ صَلَّى اللَّهُ عَلَيْهِ وَسَلَّمَ مَا مِنْ مُسْلِمٍ  
 يَغْرِسُ غَرْسًا أَوْ يَزْرَعُ زَرْعًا فَيَأْكُلُ مِنْهُ طَيْرٌ أَوْ إِنْسَانٌ أَوْ بَهِيمَةٌ إِلَّا  
 كَانَ لَهُ بِهِ صَدَقَةٌ وَقَالَ لَنَا مُسْلِمٌ حَدَّثَنَا أَبَانُ حَدَّثَنَا قَتَادَةُ حَدَّثَنَا  
 أَنَسٌ عَنِ النَّبِيِّ صَلَّى اللَّهُ عَلَيْهِ وَسَلَّمَ (روه البخارى)

Artinya: Telah menceritakan kepada kami *Qutaibah bin Sa'id* telah menceritakan kepada kami *Abu 'Awanah*. Dan diriwayatkan pula telah menceritakan kepada saya *'Abdurrahman bin Al Mubarak* telah menceritakan kepada kami *Abu 'Awanah* dari *Qatadah* dari *Anas bin Malik radiallahu 'anhu* berkata; Rasulullah shallallahu 'alaihi wasallam bersabda: “Tidaklah seorang muslim pun yang bercocok tanam atau menanam satu tanaman lalu tanaman itu dimakan oleh burung atau manusia atau hewan melainkan itu menjadi shadaqah baginya”. Dan berkata, kepada kami *Muslim* telah menceritakan kepada saya *Aban* telah menceritakan kepada kami *Qatadah* telah menceritakan kepada kami *Anas* dari Nabi shallallahu 'alaihi wasallam (HR Bukhari : 2152).

Selain menghasilkan udara yang bersih, penghijauan dilakukan untuk mencegah bahaya yang akan datang. Manusia harus menjaga agar pohon yang ditanam dapat memberi manfaat untuk seluruh makhluk hidup, seperti dalam kaidah fikih disebutkan:

## حِفْظُ الْمَوْجُودِ أَوْلَى مِنْ تَخْصِصِ

Artinya: “Memelihara yang telah ada lebih utama daripada mengharap (hasil) yang belum ada”.

Kandungan pencemaran udara dapat diprediksi menggunakan analisis statistik dengan membuat model terbaik dari data *time series*. Metode pada *time series* yang dapat digunakan untuk menghitung prediksi salah satunya adalah metode ARIMA (*Box-Jenkins*) berupa model *time series* yang hanya mengikuti berdasarkan data aktual pada periode sebelumnya yang akan diprediksi atau hanya menggunakan satu variabel saja yaitu variabel dependen (Kondo Lembang, 2017). Pada penelitian sebelumnya yang membahas mengenai ARIMA telah banyak dilakukan. Penelitian yang dilakukan oleh Farida dkk membahas mengenai prediksi penduduk di Madiun menunjukkan hasil prediksi akan bertambah setiap tahunnya dengan nilai MAPE sebesar 8.42% (Farida et al., 2022). Pada kasus pencemaran udara, ARIMA dapat digunakan untuk memprediksi kandungannya pada periode mendatang, seperti penelitian yang dilakukan oleh Syaifulloh membahas mengenai prediksi gas karbon monoksida dengan mengkombinasikan ARIMA dengan model regresi linear sederhana menunjukkan hasil prediksi yang mengalami penurunan dengan nilai RMSE sebesar 0.2349 dan MAD sebesar 0.1681 (Syaifulloh, 2021). Penelitian lain oleh Desvina membahas mengenai prediksi  $PM_{10}$  menggunakan ARIMA menunjukkan hasil prediksi yang mengalami peningkatan (Desvina, 2015). Pada penelitian Desvina terdapat beberapa model yang tidak signifikan dan tidak memenuhi syarat *white-noise*. Prediksi dilakukan dengan

menggunakan model yang tidak memenuhi *white-noise* tanpa melakukan deteksi *outlier* untuk memenuhi uji asumsi residualnya sehingga hasil prediksi masih jauh dari data aktual dan syarat uji asumsi residual tidak terpenuhi.

*Outlier* merupakan nilai pengamatan yang berada jauh dari rata-rata pada data *time series*. Pada metode ARIMA, data yang dianalisis harus memenuhi syarat ARIMA diantaranya uji signifikansi dan uji asumsi residual. Akan tetapi, jika terdapat data *outlier* terkadang membuat karakteristik data berubah dan menyebabkan model tidak memenuhi uji asumsi residual (Risky Arifanti and Asrirawan, 2021). Deteksi *outlier* dilakukan untuk mengatasi uji asumsi yang tidak memenuhi syarat ARIMA. Selain itu, dengan penambahan *outlier* model ARIMA dapat menghasilkan prediksi yang lebih akurat dengan nilai error yang lebih rendah (Suhartono and Putri, 2019). Penelitian dengan menggunakan metode ARIMA untuk memprediksi harga saham dengan penambahan *outlier* tipe *Innovational Outlier* (IO) menunjukkan hasil sangat baik dan dapat memenuhi uji autokorelasi dengan nilai MAPE sebesar 7.30% (Trydini et al., 2023). Penelitian lain yang dilakukan oleh Suparti dkk untuk menganalisis data inflasi dengan penambahan *outlier* tipe *Additive Outlier* (AO) dan *Level Shift* (LS) menunjukkan hasil prediksi yang baik dan dapat memenuhi asumsi residual dengan nilai MAPE sebesar 5.22% (Suparti and Sa'adah, 2015).

Berdasarkan penelitian yang telah dilakukan dengan metode ARIMA, peneliti tertarik menggunakan metode tersebut karena ARIMA dapat mengikuti pola data dengan nilai error yang kecil, maka penelitian ini membahas tentang pemodelan kandungan *Particulate Matter* 10 dan 2.5 dalam pencemaran udara provinsi DKI Jakarta menggunakan metode ARIMA.

## 1.2. Rumusan Masalah

Berdasarkan dengan latar belakang yang telah dijabarkan di atas, maka dapat diambil rumusan masalah pada penelitian ini yaitu:

1. Bagaimana model terbaik pada prediksi kandungan *Particulate Matter* 10 dan 2.5 dalam pencemaran udara provinsi DKI Jakarta menggunakan metode ARIMA (*Box-Jenkins*)?
2. Bagaimana hasil akurasi pada prediksi kandungan *Particulate Matter* 10 dan 2.5 dalam pencemaran udara provinsi DKI Jakarta menggunakan nilai MAPE?

## 1.3. Tujuan Penelitian

Adapun tujuan dari penelitian ini yaitu:

1. Mendapatkan model terbaik pada prediksi kandungan *Particulate Matter* 10 dan 2.5 dalam pencemaran udara provinsi DKI Jakarta menggunakan metode ARIMA (*Box-Jenkins*).
2. Mendapatkan hasil akurasi pada prediksi kandungan *Particulate Matter* 10 dan 2.5 dalam pencemaran udara provinsi DKI Jakarta menggunakan nilai MAPE.

## 1.4. Manfaat Penelitian

Berdasarkan rumusan dan tujuan masalah tersebut, penulis berharap penelitian ini bermanfaat bagi pembaca, manfaat nya adalah sebagai berikut:

1. Dapat membuat model matematika kandungan *Particulate Matter* 10 dan 2.5 provinsi DKI Jakarta menggunakan metode ARIMA.

2. Dengan memodelkan kandungan *Particulate Matter* 10 dan 2.5 provinsi DKI Jakarta dapat digunakan pemerintah untuk mengambil langkah dalam mencegah atau mereduksi kandungan *Particulate Matter* 10 dan 2.5 dalam udara provinsi DKI Jakarta.

### **1.5. Batasan Masalah**

Sesuai dengan rumusan masalah yang disebutkan, untuk mempermudah pada penelitian ini menggunakan batasan masalah sebagai berikut:

1. Data yang digunakan merupakan data harian *Particulate Matter* 10 dan 2.5 yang diperoleh dari situs resmi Open Data Jakarta dan Dinas Lingkungan Hidup (DLH) tahun 2021.
2. Nilai akurasi yang digunakan adalah nilai MAPE.

### **1.6. Sistematika Penulisan**

Sistematika dalam penyusunan penelitian ini terdiri dari lima bab dengan rincian sebagai berikut:

#### **1. BAB I PENDAHULUAN**

Pendahuluan menjelaskan tentang keadaan dari permasalahan yang diangkat, membuat rumusan masalah yang akan diteliti, menetapkan tujuan penelitian, menemukan manfaat penelitian, mengatur batasan masalah, serta menyajikan sistematika penulisan.

## 2. BAB II TINJAUAN PUSTAKA

Tinjauan pustaka memaparkan dasar dan landasan teori yang relevan terhadap topik dan kasus permasalahan yang dibahas.

## 3. BAB III METODE PENELITIAN

Metode penelitian menguraikan dari mana data didapatkan, karakteristik data, serta proses dalam mengolah data.

## 4. BAB IV HASIL DAN PEMBAHASAN

Hasil dan pembahasan menjelaskan proses dalam mencari prediksi kandungan *Particulate Matter* 10 dan 2.5 serta memberikan jawaban dari poin rumusan masalah yang dibuat.

## 5. BAB V PENUTUP

Penutup menyajikan suatu ringkasan dari hasil penelitian dan memberi rekomendasi untuk penelitian selanjutnya.

UIN SUNAN AMPEL  
S U R A B A Y A



## BAB II

### TINJAUAN PUSTAKA

#### 2.1. Pencemaran Udara

Salah satu permasalahan udara yaitu proses tercampurnya partikel ke dalam udara yang dapat membahayakan makhluk hidup (Abidin and Hasibuan, 2019). Pencemaran udara dapat menjadi salah satu masalah yang selalu ada di berbagai kota dengan jumlah penduduk besar yang disebabkan oleh banyaknya aktivitas transportasi maupun industri. Naiknya aktivitas transportasi maupun industri maka akan bertambahnya udara yang tercemar di kota tersebut (Rossha et al., 2013). Dampak dari pencemaran udara dapat memunculkan masalah kesehatan yaitu menimbulkan berbagai penyakit hingga dapat menyebabkan kematian (Li et al., 2020). Kondisi tubuh terganggu karena udara yang kotor dan dapat menimbulkan beberapa penyakit seperti pneumonia, sesak nafas, serangan jantung, dan sebagainya (Schraufnagel et al., 2019). Selain itu, dampak yang disebabkan yaitu hancurnya tempat tinggal beberapa makhluk hidup pada lingkungan sekitar (Rossha et al., 2013).

Pencemaran udara dapat menurunkan kualitas udara yang ada. Kualitas udara dinilai tinggi atau rendahnya konsentrasi parameter dalam Baku Mutu Udara Ambien Nasional yang mengukur tingginya pencemaran udara ambien. Kualitas udara memiliki 6 parameter yang digunakan untuk menilai kondisi udara ambien yaitu Karbon Monoksida (CO), Nitrogen Dioksida (NO<sub>2</sub>), Ozon (O<sub>3</sub>), Sulfur-dioksida

(SO<sub>2</sub>), serta *Particulate Matter* 10 dan 2.5 (Kurniawan, 2018).

## 2.2. *Particulate Matter* (PM)

*Particulate Matter* (PM) merupakan partikel-partikel kecil yang terdapat di udara seperti debu, kotoran, jelaga, dan asap yang dapat mengendap dalam jangka waktu yang lama (Ridayanti et al., 2022). *Particulate Matter* (PM) memiliki efek paling berbahaya terhadap kesehatan manusia karena kemampuannya masuk ke dalam sistem pernapasan yang paling dalam dan menyebabkan kematian yang tinggi akibat paparan polusi udara (Rixson et al., 2016). *Particulate Matter* (PM) memiliki beberapa ukuran, seperti *Particulate Matter* 10 (PM<sub>10</sub>) dan *Particulate Matter* 2.5 (PM<sub>2.5</sub>). Batas maksimal rata-rata harian kandungan *Particulate Matter* 10 dan 2.5 berturut-turut sebesar 50µg/m<sup>3</sup> dan 25µg/m<sup>3</sup> yang dapat diukur dengan alat *High Volume Air Sampler* (HVAS) dan *Low Volume Air Sampler* (LVAS) (Sari et al., 2019).

*Particulate Matter* 10 (PM<sub>10</sub>) merupakan suatu partikular berwujud padat maupun cair berukuran diameter 10 mikron yang mempunyai peran dalam rusaknya udara ambien. PM<sub>10</sub> berasal dari penggunaan alat transportasi, hasil pembakaran, pengoperasian pabrik industri, maupun tenaga listrik. Dampak dari PM<sub>10</sub> dalam jangka waktu pendek yaitu dapat berpengaruh pada penyakit radang paru-paru, ISPA (Infeksi Saluran Pernapasan Atas), serangan jantung, hingga kematian. Sedangkan dalam jangka waktu lama, PM<sub>10</sub> dapat mempengaruhi rusaknya sistem pernapasan bawah, turunnya fungsi paru-paru anak maupun orang dewasa, naiknya peradangan paru-paru, hingga dapat menyebabkan kematian (Ciabattini et al., 2021).

*Particulate Matter* 2.5 atau PM<sub>2.5</sub> merupakan partikular udara yang memiliki

ukuran  $\leq 2.5 \mu m$ .  $PM_{2.5}$  berasal dari sumber antropogenik seperti kendaraan bermotor, pembakaran biomassa, serta pembakaran bahan bakar pada kendaraan bermotor (Ridayanti et al., 2022). Beberapa penelitian telah membuktikan adanya hubungan antara  $PM_{2.5}$  dengan gangguan fungsi pernafasan.  $PM_{2.5}$  jika terhirup oleh manusia, dapat mengendap di organ pernapasan dan dapat menyebabkan infeksi saluran pernapasan yang akut seperti asma, bronkitis, dan bahkan kanker paru-paru jika terpapar dalam jangka waktu panjang (Arba, 2019). Penelitian yang dilakukan oleh pekerja di Industri Semen Citeureup menemukan adanya hubungan signifikan antara gangguan fungsi paru dengan konsentrasi polutan  $PM_{2.5}$ , dimana 50% dari sampel mengalami restriktif dan 10,9% mengalami obstruktif (Ridayanti et al., 2022).

### **2.3. Autoregressive Integrated Moving Average (ARIMA)**

*Autoregressive Integrated Moving Average* yang dikenal dengan sebutan ARIMA sudah dipelajari hingga tuntas dan dalam oleh George Box dan Gwilym Jenkins saat tahun 1976. Proses ARIMA direalisasikan untuk menganalisis deret secara berkala, prediksi, dan pengendalian. Pada tahun 1927, Yule pertama kali memperkenalkan model *Autoregressive* (AR) lalu dikembangkan oleh Slutsky pada tahun 1937 yang memperkenalkan model *Moving Average* (MA). Selanjutnya, Wold merupakan orang pertama yang membuat kombinasi ARMA dari dasar-dasar teoritis. Wold juga mengembangkan konsep untuk menerapkan model ARMA pada time series musiman dan mengembangkan proses yang mencakup proses non-stasioner (Hartati, 2017).

ARIMA adalah sebuah metode atau pendekatan yang digunakan untuk

memprediksi nilai-nilai di masa depan dalam rentang batas yang telah ditetapkan. Kelebihan dari metode ini yaitu memiliki sifat fleksibel atau bisa mengikuti bentuk data tertentu. Selain itu, ARIMA menghasilkan tingkat akurasi prediksi yang kecil dan tepat digunakan untuk memprediksi suatu variabel dengan hasil yang akurat serta proses yang cepat, karena hanya memakai data pada masa lampau untuk prediksinya. Dalam analisis ARIMA, diasumsikan bahwa data yang digunakan adalah stasioner. Jika data belum memenuhi syarat stasioner, maka perlu dilakukan proses stasioner terlebih dahulu agar data tersebut menjadi stasioner (Hutasuhut et al., 2014).

ARIMA terdiri dari empat model yaitu:

#### 1. Model *Autoregressive* (AR)

Model *Autoregressive* didefinisikan sebagai  $AR(p)$  pada orde  $p$ . Model ini menegaskan bahwa data pada masa lampau mempengaruhi data pada periode saat ini. (Wirdyacahya and Prastuti, 2022). Fungsi pada model  $AR(p)$  dapat dilihat pada persamaan berikut:

$$A_t = \phi_1 A_{t-1} + \phi_2 A_{t-2} + \phi_3 A_{t-3} + \dots + \phi_p A_{t-p} + e_t$$

Selain itu, persamaan dapat ditulis menjadi persamaan

$$(1 - \phi_1 B - \dots - \phi_p B^p) A_t = e_t$$

Untuk  $BA_t = A_{t-1}$ , maka ditulis:

$$\phi_p(B) A_t = e_t \tag{2.1}$$

dimana

$A_t$  : data aktual

$$\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \phi_3 B^3 - \dots - \phi_p B^p$$

$p$  : orde

$\phi_p$  : koefisien regresi, dimana  $p = 1, 2, 3, \dots, p$

$e_t$  : error pada periode ke  $-t$

## 2. Model *Moving Average* (MA)

Model *Moving Average* didefinisikan sebagai MA( $q$ ) pada orde  $q$ . Model ini mencari nilai rata-rata dari data aktual pada periode lampau untuk memprediksi periode kedepan (Wirdyacahya and Prastuti, 2022). Fungsi pada model MA( $q$ ) dapat dilihat pada persamaan berikut:

$$A_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \theta_3 e_{t-3} - \dots - \theta_q e_{t-q}$$

Selain itu, persamaan dapat ditulis menjadi persamaan

$$A_t = (1 - \theta_1 B - \dots - \theta_q B^q) e_t$$

Untuk  $B e_t = e_{t-1}$ , maka ditulis:

$$A_t = \theta_q(B) e_t \quad (2.2)$$

dimana

$A_t$  : data aktual  $\theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \theta_3 B^3 - \dots - \theta_q B^q$

$e_{t-q}$  : error pada periode ke- $t - q$

$\theta_q$  : koefisien regresi, dimana  $q = 1, 2, 3, \dots, q$

$q$  : orde pada rata-rata bergerak

### 3. Model *Autoregressive Moving Average* (ARMA)

Model *Autoregressive Moving Average* didefinisikan sebagai ARMA( $p, q$ ) pada orde  $p$  dan  $q$ . Model ini gabungan dari dua model sebelumnya untuk menghitung data aktual pada masa lampau dan digunakan untuk memprediksi periode kedepan. Penggabungan kedua model tersebut akan menghasilkan nilai error yang lebih kecil (Wiridyachya and Prastuti, 2022). Fungsi pada model ARMA( $p, q$ ) dapat dilihat pada persamaan berikut:

$$A_t = \phi_1 A_{t-1} + \dots + \phi_p A_{t-p} + e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q}$$

Selain itu, persamaan dapat ditulis menjadi persamaan

$$(1 - \phi_1 B - \dots - \phi_p B^p) A_t = (1 - \theta_1 B - \dots - \theta_q B^q) e_t$$

atau

$$\phi_p(B) A_t = \theta_q(B) e_t \quad (2.3)$$

dimana

$A_t$  : data aktual  $A_{t-p}$  : data aktual periode ke- $t - p$

$\phi_p$  : parameter nilai AR periode ke- $p$

$\theta_q$  : parameter nilai MA periode ke- $q$

#### 4. Model *Autoregressive Integrated Moving Average* (ARIMA)

Model *Autoregressive Integrated Moving Average* (ARIMA) dikembangkan dengan tujuan untuk menambahkan parameter  $d$ , yang merupakan jumlah proses differencing yang didapatkan melalui percobaan dan kesalahan pada nilai  $p$  dan  $q$ . Nilai  $p$  dan  $q$  diperoleh melalui estimasi pola plot ACF dan PACF (Wirdyachya and Prastuti, 2022). Model ARIMA dirumuskan sebagai berikut:

$$ARIMA(p, d, q)$$

dimana

$p$  : orde AR

$q$  : orde MA

$d$  : banyaknya proses *differencing*

Persamaan untuk fungsi pada model ARIMA ( $p, d, q$ ) dapat dilihat sebagai berikut:

$$A_t = \phi_0 + (1 + \phi_1) A_{t-1} + (\phi_2 - \phi_1) A_{t-2} + \dots + (\phi_p - \phi_{p-1}) A_{t-p} - \phi_p A_{t-p-1} + e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q}$$

Selain itu, persamaan dapat ditulis menjadi persamaan

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) A_t = \theta_0 + (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) e_t$$

atau

$$\phi_p(B) (1 - B)^d A_t = \theta_q(B) e_t \quad (2.4)$$

dimana

$\phi_0$  : konstanta

$(1 - B)^d$  : operator *differencing*

#### 2.4. Stasioneritas

Dalam *time series*, data dapat dikatakan stasioner atau tidak stasioner. Data dikatakan stasioner apabila tidak mengalami perubahan pada waktu tertentu (Irawan and Puteri, 2020). Apabila data tidak memenuhi sifat stasioner, diperlukan langkah-langkah untuk mengubahnya menjadi stasioner sebelum melanjutkan ke tahap selanjutnya. Hal ini bertujuan untuk mengurangi kesalahan yang mungkin terjadi pada model yang akan digunakan. Proses stasioner terdiri dari dua langkah, yaitu stasioner dalam varians dan stasioner dalam rata-rata *mean*.

##### 1. Stasioner dalam varians

Data diasumsikan stasioner dalam varians jika nilai *Rounded Value* bernilai sama dengan 1 atau nilai *lower* dan *upper* bernilai lebih dari 1. Jika tidak memenuhi kriteria tersebut, maka perlu dilakukan transformasi *Box-Cox* hingga salah satu



syarat terpenuhi. Transformasi *Box-Cox* dinyatakan oleh persamaan berikut (Wei, 2006):

$$T(x_t) = \frac{A_t^\lambda - 1}{\lambda}, \text{ untuk } \lambda \neq 0 \quad (2.5)$$

dimana

$A_t$  : data aktual

$t$  : periode

$\lambda$  : parameter untuk transformasi

Pembagian jenis transformasi *Box-Cox* sesuai dengan nilai  $\lambda$  ditunjukkan pada tabel berikut.

**Tabel 2.1 Jenis Transformasi**

Nilai $\lambda$	Jenis
1	$A_t$ (tidak ada transformasi)
0.5	$\sqrt{A_t}$
0	$\ln A_t$
-0.5	$\frac{1}{\sqrt{A_t}}$
-1	$\frac{1}{A_t}$

## 2. Stasioner dalam (*mean*)

Untuk menentukan apakah data telah stasioner dalam *mean*, dapat diketahui dari plot data. Jika data yang digunakan tidak berada di sekitar nilai rata-rata, maka perlu dilakukan proses untuk mencari perbedaan antara data pada satu periode dengan data pada periode sebelumnya secara berurutan. Persamaan *differencing*

yang digunakan dalam plot non-musiman adalah sebagai berikut:

$$\Delta A_t = A_t - A_{t-1} \quad (2.6)$$

Selain itu, stasioner terhadap *mean* dapat diketahui dari operator *backward shift* yang disimbolkan  $B$  dengan persamaan yaitu:

$$BA_t = A_{t-1} \quad (2.7)$$

dimana

$A_{t-1}$  : data aktual pada periode ke- $t - 1$

$B$  : backward shift

## 2.5. Autocorrelation Function (ACF)

*Autocorrelation Function* atau ACF merupakan suatu fungsi yang dipergunakan untuk menjelaskan hubungan antara  $A_t$  dan  $A_{(t+k)}$ . Perhitungan pada ACF berdasarkan nilai varians dan kovarian yang dimana varians berkorelasi dengan data dalam waktu yang sama sedangkan kovarian berkorelasi dengan data antar waktu. Dalam *time series* terdapat koefisien autokorelasi deret beruntut yang memiliki selisih pada *lag* 0, 1, 2 periode atau lebih (Ayundari and Sutikno, 2019). Persamaan *Autocorrelation Function* yaitu:

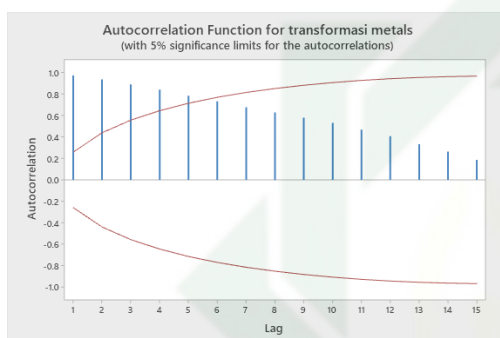
$$\rho_k = \frac{\sum_{t=1}^{n-k} (A_t - \bar{A}_t) (A_{t+k} - A_t)}{\sum_{t=1}^n (A_t - \bar{A}_t)^2} \quad (2.8)$$

dimana


$A_{t+k}$  : data aktual waktu ke- $t + k$

$\bar{A}_t$ : rata-rata pada data aktual

Pada *Autocorrelation Function* (ACF) terdapat grafik yang digunakan untuk menentukan apakah data sudah stasioner terhadap *mean* atau belum. Jika plot ACF menurun secara linier, maka menunjukkan bahwa data tersebut belum stasioner dalam *mean*. Gambar plot ACF yang belum stasioner dan sudah stasioner disajikan pada gambar di bawah ini:



Gambar 2.1 Pola ACF Belum Stasioner



Gambar 2.2 Pola ACF Sudah Stasioner

## 2.6. Partial Autocorrelation Function (PACF)

*Partial Autocorrelation Function* atau PACF digunakan untuk mengukur tingkat keterkaitan antara nilai  $A_t$  dan  $A_{t-1}$  jika dipengaruhi oleh  $lag 1, 2, 3, \dots, k - 1$  yang dianggap terpisah. Penduga untuk PACF merupakan koefisien autokorelasi untuk  $l = 1, 2, \dots, k$  (Fauzannissa et al., 2015). Persamaan *partial autocorrelation function* yaitu:

$$\hat{\phi}_{kk} = \frac{\hat{\rho}_k - \sum_{l=1}^{k-1} \hat{\phi}_{k-1,l} \hat{\rho}_{k-l}}{1 - \sum_{l=1}^{k-1} \hat{\phi}_{k-1,l} \hat{\rho}_l} \quad (2.9)$$

Dalam perhitungan pada indikator yang berbeda, persamaan PACF dapat diubah yaitu:


$$\hat{\phi}_{kl} = \hat{\phi}_{k-1,l} - \hat{\phi}_{kk}\hat{\phi}_{k-1,k-l} \quad (2.10)$$

dimana


$\hat{\phi}_{k-1,l}$  : fungsi autokorelasi parsial pada lag ke  $-k + 1$  dengan  $l$

$\hat{\phi}_k$  : fungsi autokorelasi pada lag ke  $-k + 1$

Gambar plot PACF yang belum stasioner dan sudah stasioner dapat disajikan pada gambar di bawah ini:



Gambar 2.3 Pola PACF Belum Stasioner



Gambar 2.4 Pola PACF Sudah Stasioner

## 2.7. Identifikasi Model

Pada tahap identifikasi, data sudah stasioner terhadap varians dan *mean*. Jika data belum memenuhi syarat stasioner, perlu dilakukan proses transformasi hingga data menjadi stasioner. Setelah itu, plot ACF dan PACF dapat digunakan untuk mendapatkan nilai AR (*Autoregressive*) dan MA (*Moving Average*) dalam membangun model. Selanjutnya, dilakukan uji untuk memilih model terbaik yang dapat digunakan untuk memprediksi periode di masa depan (Suryanto, 2016). Identifikasi model

ARIMA dapat dilakukan dengan melihat plot ACF dan PACF yang sesuai pada teori berikut (Wei, 2006).

**Tabel 2.2 Plot ACF dan PACF**

Model	ACF	PACF
AR(p)	Turun lambat ( <i>dies down</i> )	<i>Cut off</i> setelah lag p
MA(q)	<i>Cut off</i> setelah lag q	Turun lambat ( <i>dies down</i> )
ARMA(p,q)	Turun cepat setelah lag (q,p)	Turun cepat setelah lag (p,q)

## 2.8. Estimasi Parameter

Langkah selanjutnya akan dilakukan tahap estimasi serta uji signifikansi dari model sementara yang didapatkan dari identifikasi model. Metode yang digunakan pada tahap ini adalah metode *Conditional Least Square* (CLS) dengan cara meminimumkan nilai SSE (*Sum Square Error*) dan menjadikan nilai error sama dengan nol jika tidak diketahui nilainya (Mokorimban et al., 2021). Uji signifikansi model menggunakan hipotesis yakni:

$$H_0 : \phi_i = 0 \text{ atau } \theta_j = 0 \text{ (Parameter tidak signifikan dalam model)}$$

$$H_1 : \phi_i \neq 0 \text{ atau } \theta_j \neq 0 \text{ (Parameter signifikan dalam model)}$$

dimana  $i = 1, 2, \dots, p$  dan  $j = 1, 2, \dots, q$

Perhitungan uji yang digunakan yaitu

$$t_{hitung} = \frac{\hat{\phi}_i}{SE(\hat{\phi}_i)} \text{ atau } t_{hitung} = \frac{\hat{\theta}_j}{SE(\hat{\theta}_j)} \quad (2.11)$$

dimana

$\hat{\phi}_i$  : estimasi parameter model AR(p)

$\hat{\theta}_j$  : estimasi parameter model MA(q)

$SE(\hat{\phi}_i)$  : standard error parameter model AR(p)

$SE(\hat{\theta}_j)$  : standard error parameter model MA(q)

Hipotesis  $H_0$  ditolak apabila nilai  $|t_{hitung}| > t_{\alpha/2, (n-n_p)}$  atau jika nilai  $p - value < \alpha$  dimana  $n$  merupakan banyaknya pengamatan dan  $n_p$  merupakan jumlah parameter yang diestimasi.

## 2.9. Uji Asumsi Residual

Untuk melakukan pengecekan kecocokan model, nilai residu harus memenuhi syarat *white-noise* dan berdistribusi secara normal. Untuk mengecek varians, cara melihat residual *white-noise* dari perhitungan ACF dan PACF yang signifikan. Jika tidak ada lag yang keluar dari batas yang ditentukan, maka dapat dikatakan bahwa residual sudah memenuhi syarat sebagai *white-noise*. Selain itu, untuk memeriksa distribusi normalitas, kita dapat melihat sejauh mana residu tersebar di sekitar garis diagonal. Jika residu menyebar jauh dari garis diagonal, maka residu belum berdistribusi normal. Untuk menguji *white-noise*, dapat digunakan uji *Ljung-Box* dengan hipotesis dan persamaan berikut (Wei, 2006):

Hipotesis:

$H_0 : \rho_1 = \rho_2 = \dots = \rho_k = 0$  (Residual memenuhi asumsi *white-noise*)

$H_1 : \text{minimal ada satu } \rho_k \neq 0$  (Residual tidak memenuhi asumsi *white-noise*)

dimana  $k = 1, 2, \dots, K$

Perhitungan uji yang digunakan yaitu:

$$Q = n(n+2) \sum_{k=1}^i \frac{\hat{\rho}_k^2}{(n-k)} \quad (2.12)$$

dimana

$Q$  : uji Ljung-Box

$n$  : banyaknya parameter

$i$  : maksimum lag

$\hat{\rho}_k$  : nilai autokorelasi pada lag ke- $k$

$k$  : lag waktu

Taraf signifikansi yang ditetapkan yaitu  $\alpha = 5\%$  atau 0.05. Hipotesis  $H_0$  ditolak apabila nilai  $Q > X_{\alpha, K-m}^2$  atau nilai  $p\text{-value} < \alpha$  dimana  $K$  merupakan jumlah maksimum dari *lag* dan  $m$  merupakan jumlah dari  $p + q$ .

Selain harus memenuhi syarat sebagai *white-noise*, residu juga harus memiliki distribusi yang normal. Untuk menguji distribusi normal, digunakan uji *Kolmogorov-Smirnov* dengan hipotesis dan perhitungan sebagai berikut (Wei, 2006):

Hipotesis:

$H_0 : F(x) = F_0(x)$  Residual data berdistribusi normal

$H_1 : F(x) \neq F_0(x)$  Residual data tidak berdistribusi normal

Perhitungan uji yang digunakan yaitu:

$$D = \sup |S(x) - F_0(x)| \quad (2.13)$$

dimana

$\sup$  : nilai maksimum supremum

$F_0(x)$  : fungsi peluang kumulatif dari residual sampel

$S(x)$  : fungsi distribusi kumulatif dari residual sampel

Taraf signifikan yang digunakan yaitu  $\alpha = 5\%$  atau 0.05. Hipotesis  $H_0$  ditolak apabila nilai  $D > D_{1-\alpha, n}$  atau nilai  $p - value < \alpha$ .

## 2.10. Deteksi *Outlier*

Deteksi *outlier* adalah proses mengidentifikasi nilai pengamatan yang memiliki pola yang tidak konsisten dalam data *time series*, seperti akibat perang, krisis ekonomi, atau perubahan suhu lingkungan. Keberadaan *outlier* dapat menyebabkan data menjadi jauh dari nilai rata-ratanya dan dapat mengubah karakteristik data, sehingga hasil analisis data menjadi tidak valid. Oleh karena itu perlu dilakukan pendeteksian *outlier* agar data dapat memenuhi uji normalitas (Zulfa et al., 2022b). Terdapat empat jenis *outlier* yang umum, yaitu *Additive Outlier* (AO), *Innovational Outlier* (IO), *Level Shift*



*Outlier* (LS), dan *Temporary Change Outlier* (TC). Namun, pada penelitian hanya fokus pada dua jenis *outlier* saja yakni tipe *Additive Outlier* (AO) dan *Level Shift Outlier* (LS) (Lorensya et al., 2022). Jenis *outlier* AO merupakan sebuah *outlier* yang hanya mempengaruhi pengamatan ke  $-T$  dalam suatu *time series*. Sementara itu, jenis *outlier* IO, LS, dan TC akan berpengaruh pada pengamatan ke  $-T, T + 1, T + 2$ , dan seterusnya. Misalkan kita memiliki serangkaian data  $A_1, A_2, \dots, A_t$ , dan menggunakan model  $ARMA(p, q)$ , maka dapat ditulis sebagai berikut (Wei, 2006):

$$\phi(B)A_t = \theta(B)\alpha_t \quad (2.14)$$

#### 1. *Additive Outlier* (AO)

*Additive Outlier* (AO) adalah suatu nilai yang berbeda secara signifikan dari nilai-nilai lain dalam suatu data, namun tidak mempengaruhi nilai-nilai sebelum maupun sesudahnya dalam data tersebut. Dengan kata lain, AO adalah nilai yang jauh dari rata-rata namun tidak memiliki efek yang signifikan terhadap data sebelum dan sesudahnya. AO dapat dituliskan sebagai berikut:

$$\begin{aligned} Z(AO)_t &= A_t + \omega_{AO}I_t^{(T)} \\ &= \frac{\theta(B)}{\phi(B)}\alpha_t + \omega_{AO}I_t^{(T)} \end{aligned} \quad (2.15)$$

dimana:

$\omega_{AO}$  : nilai error dari *outlier*

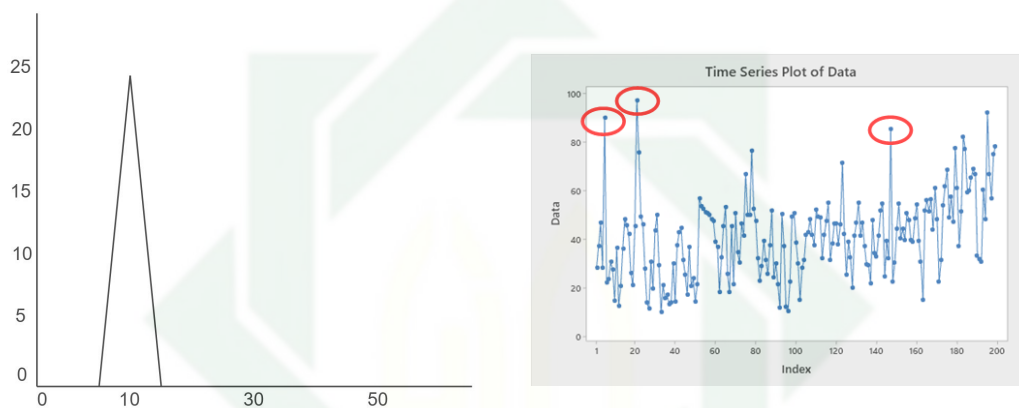
$I_t^{(T)}$  : variabel yang menunjukkan adanya *outlier* pada waktu ke  $-(T)$

Data  $A_t$  dianggap tidak mengandung *outlier* dan diasumsikan mengikuti model

ARMA, sedangkan variabel  $I$  pada waktu ke  $T$  menunjukkan ketiadaan outlier yang dirumuskan sebagai berikut:

$$I_t^{(T)} = \begin{cases} 0, & t \neq T \\ 1, & t = T \end{cases} \quad (2.16)$$

Berikut gambar yang menunjukkan *outlier* tipe *Additive*.



Berdasarkan gambar di atas, lingkaran merah menunjukkan adanya *outlier* tipe *Additive* pada satu titik tersebut tanpa mempengaruhi data lain. *Outlier* tipe *Additive* ini terlihat dari plot data karena titik data tersebut berada jauh dari titik data lainnya.

## 2. Level Shift (LS)

*Level Shift* (LS) adalah suatu jenis outlier yang mengalami perubahan signifikan dari sebuah data serta dapat mempengaruhi deret pada satu waktu tertentu, LS

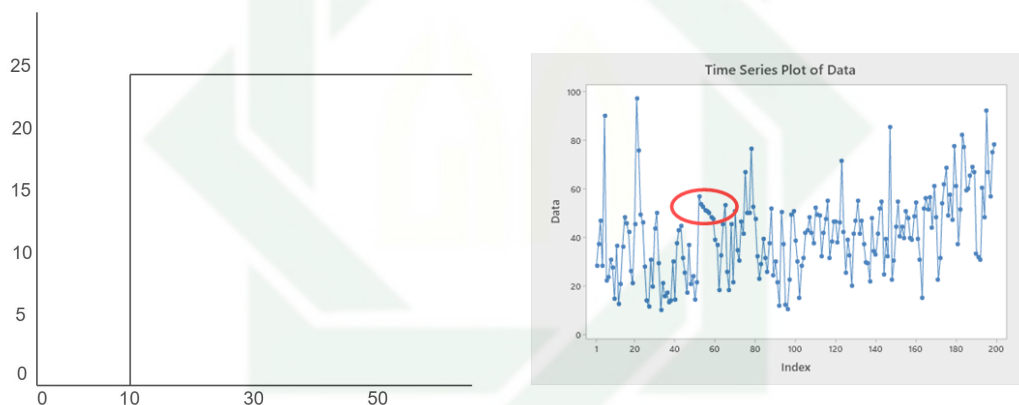
dinyatakan dalam persamaan sebagai berikut:

$$Z(LS)_t = A_t + \frac{1}{(1-B)} \omega_{LS} S_t^{(T)} \quad (2.17)$$

dengan

$$S_t^{(T)} = \begin{cases} 1, & t \geq T \\ 0, & t < T \end{cases} \quad (2.18)$$

Berikut gambar yang menunjukkan *outlier* tipe *Level Shift*.



Berdasarkan gambar di atas, lingkaran merah menunjukkan adanya *outlier* tipe *Level Shift* yang dapat mempengaruhi data lainnya secara permanen, ditandai dengan pergeseran data secara tiba-tiba yang signifikan.

### 2.11. Mean Absolute Percentage Error (MAPE)

*Mean Absolute Percentage Error* atau MAPE merupakan nilai akurasi hasil prediksi yang digunakan untuk mengukur jarak data aktual dengan hasil prediksi

(Zulfa et al., 2022a). Semakin kecil nilai akurasi maka tingkat keakuratan prediksi semakin baik, namun jika nilai akurasi semakin besar maka tingkat keakuratan prediksi semakin buruk (Krisma et al., 2020). Rumus MAPE adalah sebagai berikut:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - A_p}{A_t} \right| \times 100\% \quad (2.19)$$

dimana

$A_t$  : data aktual

$A_p$  : hasil prediksi

$n$  : banyak data

Setelah mendapat nilai MAPE, maka dilakukan analisis apakah hasil prediksi memiliki hasil yang baik atau buruk. Kriteria keakuratan nilai MAPE dapat dilihat pada tabel berikut (Puspita, 2022):

**Tabel 2.3 Kriteria Nilai MAPE**

Hasil	Kriteria
< 10%	Hasil prediksi sangat baik
10% – 20%	Hasil prediksi baik
20% – 50%	Hasil prediksi cukup baik
> 50%	Hasil prediksi buruk

## 2.12. Integrasi Keilmuan

Udara yang terkontaminasi oleh zat berbahaya dapat menyebabkan pencemaran udara. Pencemaran udara merupakan salah satu bentuk kerusakan lingkungan yang dapat terjadi di sekitar manusia. Kerusakan lingkungan dapat disebabkan karena berkembangnya sektor industri dan teknologi. Selain itu, perbuatan manusia juga dapat menyebabkan kerusakan lingkungan, termasuk masalah pencemaran udara. Seperti yang disebutkan dalam firman Allah SWT:

ظَهَرَ الْفَسَادُ فِي الْبَرِّ وَالْبَحْرِ بِمَا كَسَبَتْ أَيْدِي النَّاسِ لِيُذِيقَهُمْ  
بَعْضَ الَّذِي عَمِلُوا لَعَلَّهُمْ يَرْجِعُونَ

Artinya: “Telah tampak kerusakan di darat dan di laut disebabkan karena perbuatan tangan manusia, Allah menghendaki agar mereka merasakan sebagian dari (akibat) perbuatan mereka, agar mereka kembali (ke jalan yang benar)” (Qs. Ar-Rum : 41).

Pada ayat diatas dijelaskan bahwa kerusakan lingkungan yang terjadi di bumi ini disebabkan oleh tindakan-tindakan manusia. Misal pada permasalahan pencemaran udara, manusia membakar sampah untuk mengurangi sampah yang menggunung. Hal tersebut sebaiknya tidak dilakukan karena mengurangi sampah dapat dilakukan dengan cara lain, misalnya sampah organik seperti daun, batang pohon, dan lainnya dapat didaur ulang menjadi pupuk organik. Sementara itu, sampah anorganik seperti plastik, kaca, dan sejenisnya dapat diolah ulang menjadi kerajinan tangan yang memiliki manfaat bagi masyarakat. Contoh lain manusia memakai kendaraan bermotor sebagai

alat untuk mereka bepergian. Kendaraan bermotor tersebut mengeluarkan asap dari knalpot yang merupakan gas pembuangan dari kendaraan yang dapat membahayakan manusia. Seringkali manusia tidak sadar akan perbuatan yang telah dilakukan dan menganggap pencemaran udara terjadi karena faktor alam. Apabila manusia merasakan dampak dari pencemaran udara yang terjadi, manusia diminta untuk sadar agar mengurangi perbuatan yang merugikan mereka.

Udara yang dibuat oleh Allah Swt termasuk rahmat yang diberikan kepada seluruh makhluk hidup di bumi. Udara termasuk salah satu faktor penting dalam kehidupan karena dapat membawa manfaat yang baik untuk sebagian makhluk hidup (Ratnani, 2008). Sebagaimana hadis Nabi Saw:

حَدَّثَنَا أَحْمَدُ بْنُ مُحَمَّدٍ الْمَرْوَزِيُّ وَسَلَمَةُ يَعْنِي ابْنَ شَيْبٍ قَالَ  
 حَدَّثَنَا عَبْدُ الرَّزَّاقِ أَخْبَرَنَا مَعْمَرٌ عَنِ الزُّهْرِيِّ قَالَ حَدَّثَنِي ثَابِتُ  
 بْنُ قَيْسٍ أَنَّ أَبَا هُرَيْرَةَ قَالَ سَمِعْتُ رَسُولَ اللَّهِ صَلَّى اللَّهُ عَلَيْهِ  
 وَسَلَّمَ يَقُولُ الرِّيحُ مِنْ رَوْحِ اللَّهِ قَالَ سَلَمَةُ فَرَوْحُ اللَّهِ تَأْتِي  
 بِالرَّحْمَةِ وَتَأْتِي بِالْعَذَابِ فَإِذَا رَأَيْتُمُوهَا فَلَا تَسُبُّوهَا وَسَلُّوا اللَّهَ  
 خَيْرَهَا وَاسْتَعِيدُوا بِاللَّهِ مِنْ شَرِّهَا (روه أبو داود)

Artinya: Telah menceritakan kepada kami *Ahmad bin Muhammad Al Marwazi* dan *Salamah* –maksudnya *Salamah bin Syabib*- keduanya berkata, telah menceritakan kepada kami *Abdurrazaq* berkata, telah mengabarkan kepada kami *Ma'mar* dari *Az Zuhri* ia berkata, telah menceritakan kepadaku *Tsabit bin Qais* bahwa *Abu Hurairah* berkata; Aku mendengar Rasulullah *shallallahu 'alaihi wasallam* bersabda: “Angin itu

dari rahmat Allah.” Salamah berkata: “Terkadang angin datang bersama rahmat Allah dan terkadang datang dengan membawa siksa. Maka jika kalian melihatnya janganlah mencela, mohonlah kepada Allah akan kebaikannya, dan mintalah perlindungan kepada-Nya dari keburukannya.” (HR. Abu Daud : 5097).

Angin dapat membawa rahmat kepada makhluk hidup dan memberikan keberkahan kepada manusia. Hal ini sesuai dengan firman Allah Swt yang menyatakan:

اللَّهُ الَّذِي يُرْسِلُ الرِّيحَ فَتُثِيرُ سَحَابًا فَيَبْسُطُهُ فِي السَّمَاءِ كَيْفَ يَشَاءُ وَيَجْعَلُهُ كِسْفًا فَتَرَى الْوَدْقَ يَخْرُجُ مِنْ خِلَالِهِ ۚ فَإِذَا أَصَابَ بِهِ مَنْ يَشَاءُ مِنْ عِبَادِهِ إِذَا هُمْ يَسْتَبْشِرُونَ

Artinya: “Allahlah yang mengirim angin, lalu ia (angin) menggerakkan awan, kemudian Dia (Allah) membentangkannya di langit menurut yang dikehendaki-Nya dan Dia menjadikannya bergumpal-gumpal lalu engkau melihat hujan keluar dari celah-celahnya. Maka, apabila Dia menurunkannya kepada hamba-hamba-Nya yang dikehendaki-Nya, seketika itu pula mereka bergembira”(QS. Ar-Rum : 48).

وَهُوَ الَّذِي يُرْسِلُ الرِّيحَ بُشْرًا بَيْنَ يَدَيْ رَحْمَتِهِ ۗ قُلْ حَتَّىٰ إِذَا أَقَلَّتْ سَحَابًا ثِقَالًا سُقْنَهُ لِبَلَدٍ مَّيِّتٍ فَأَنْزَلْنَا بِهِ الْمَاءَ فَأَخْرَجْنَا بِهِ مِنْ كُلِّ الثَّمَرَاتِ ۗ قُلْ كَذَٰلِكَ نُخْرِجُ الْمَوْتَىٰ لَعَلَّكُمْ تَذَكَّرُونَ

Artinya: “Dialah yang mendatangkan angin sebagai kabar gembira yang

*mendahului kedatangan rahmat-Nya (hujan) sehingga apabila (angin itu) telah memikul awan yang berat, Kami halau ia ke suatu negeri yang mati (tandus), lalu Kami turunkan hujan di daerah itu. Kemudian Kami tumbuhkan dengan hujan itu berbagai macam buah-buahan. Seperti itulah Kami membangkitkan orang-orang mati agar kamu selalu ingat”(QS. Al-A'raf : 57).*

Kedua ayat diatas dijelaskan bahwa angin menggerakkan awan dan menurunkan hujan di tempat yang tandus agar ditempat tersebut tumbuh pohon-pohon serta tanaman yang dapat bermanfaat bagi manusia, seperti pohon menghasilkan oksigen untuk makhluk hidup sehingga manusia dan hewan dapat menghirup udara yang segar serta tumbuhan dapat mempercepat proses fotosintesis dan menghasilkan sumber makanan untuk seluruh makhluk hidup. Oleh karena itu, angin bisa datang membawa rahmat sehingga tercapailah keberkahan bagi makhluk hidup.

Selain itu, angin atau udara bisa datang membawa azab yang seringkali dapat berbahaya bagi makhluk hidup yang tercantum pada firman Allah dan Hadis Nabi Saw:

فَأَرْسَلْنَا عَلَيْهِمْ رِيحًا صَرْصَرًا فِي أَيَّامٍ نَّحِسَاتٍ لَّنُذِيقَهُمْ عَذَابَ  
الْحِزْبِ فِي الْحَيَاةِ الدُّنْيَا <sup>قُلَى</sup> وَلَعَذَابُ الْآخِرَةِ أَخْزَىٰ وَهُمْ لَا  
يُنصَرُونَ

Artinya: “Maka, Kami menghembuskan angin yang sangat dingin dan bergemuruh kepada mereka selama beberapa hari yang nahas karena Kami ingin agar mereka merasakan siksaan yang menghinakan dalam kehidupan di dunia. Sungguh, azab akhirat lebih menghinakan dan mereka tidak diberi pertolongan”(QS. Fussilat :



16)

رُويَ عَائِشَةُ رَضِيَ اللَّهُ عَنْهَا وَكَانَ إِذَا رَأَى غَيْمًا أَوْ رِيحًا عُرِفَ فِي  
 وَجْهِهِ قَلْتُ يَا رَسُولَ اللَّهِ إِنَّ النَّاسَ إِذَا رَأَوْا الْغَيْمَ فَرِحُوا رَجَاءً أَنْ  
 يَكُونَ فِيهِ الْمَطَرُ وَأَرَاكَ إِذَا رَأَيْتَهُ عُرِفَ فِي وَجْهِكَ الْكَرَاهِيَةَ فَقَالَ  
 يَا عَائِشَةُ مَا يُؤَمِّئِي أَنْ يَكُونَ فِيهِ عَذَابٌ عَذَّبَ قَوْمٌ بِالرِّيحِ (روه  
 البخاري و مسلم)

Artinya: Aisyah *radiallahu ‘anha* pernah menceritakan, jika Rasulullah shallallahu ‘alaihi wa sallam melihat mendung atau angin, maka raut wajahnya pun berbeda. Aisyah berkata “Wahai Rasulullah, jika orang-orang melihat mendung, mereka akan begitu girang. Mereka mengharap-harap agar hujan segera turun. Namun berbeda halnya dengan engkau. Jika melihat mendung, terlihat wajahmu menunjukkan tanda tidak suka.” Beliau pun bersabda, “Wahai Aisyah, apa yang bisa membuatku merasa aman? Siapa tahu ini adalah azab. Dan pernah suatu kaum diberi azab dengan datangnya angin (setelah itu). Kaum tersebut (yaitu kaum ‘Aad) ketika melihat azab, mereka mengatakan, ini adalah awan yang akan menurunkan hujan kepada kita.” (HR. Bukhari : 4829 dan Muslim : 899).

Angin atau udara yang datang membawa azab terjadi apabila manusia masih berulah yang menyebabkan udara semakin tercemar, seperti pembakaran sampah plastik. Selain itu pencemaran udara mengalami peningkatan apabila semakin banyaknya pabrik industri yang beroperasi, oleh karena itu perlu adanya prediksi mengenai jumlah kandungan *Particulate Matter* 10 (PM<sub>10</sub>) yang akan terjadi pada

periode kedepan. Hal ini penting karena dengan mengetahui prediksi jumlah kandungan *Particulate Matter* 10 (PM<sub>10</sub>) di periode kedepan pemerintah maupun masyarakat dapat menanggulangi atau mereduksi udara yang tercemar. Pada kaidah fikih disebutkan bahwa:

الضَّرَرُ يُدْفَعُ عَلَى قَدْرِ الْإِمْكَانِ

Artinya: “Bahaya dicegah semaksimal mungkin meskipun tidak seluruhnya hilang”.

Kaidah fikih di atas menjelaskan bahwa bahaya yang terjadi seharusnya bisa dicegah semaksimal mungkin meskipun hal yang berbahaya tersebut tidak seluruhnya hilang. Prediksi ini dapat digunakan sebagai acuan untuk mengantisipasi pencemaran udara yang terjadi dengan cara menanam pohon di sepanjang jalan yang sering dilewati kendaraan bermotor agar udara kotor dapat tersaring oleh udara bersih yang dihasilkan oleh pohon. Selain itu, cara yang lain adalah menghentikan pembakaran sampah dan mengubah sampah menjadi produk daur ulang yang dapat dimanfaatkan. Pencemaran udara dapat membahayakan manusia karena dapat menyebabkan timbulnya berbagai penyakit yang dapat menyebabkan kematian. Sesuai dengan kaidah fikih di atas, “bahaya yang terjadi dapat dicegah semaksimal mungkin meskipun tidak seluruhnya hilang” seluruh hal yang berbahaya dapat diantisipasi dengan menggunakan prediksi.

## BAB III

### METODE PENELITIAN

#### 3.1. Jenis Penelitian dan Sumber Data

Penelitian ini dikategorikan sebagai penelitian kuantitatif karena data yang digunakan dalam penelitian ini berupa data berbentuk angka. Jika dilihat dari manfaatnya, penelitian ini merupakan penelitian terapan dengan tujuan memberi solusi pada suatu masalah secara praktis, tidak berfokus pada pengembangan teori, maupun ide saja, tetapi berfokus pada penerapan dalam kehidupan sehari-hari (Mulyadi, 2013). Data yang digunakan dalam penelitian ini adalah data harian mengenai kandungan *Particulate Matter* 10 dan 2.5 di provinsi DKI Jakarta pada tahun 2021. Data ini diperoleh melalui situs resmi Open Data Jakarta untuk data *Particulate Matter* 10 (JakartaOpenData, 2022) dan Dinas Lingkungan Hidup (DLH) untuk data *Particulate Matter* 2.5 (DLHJakarta, 2022).

#### 3.2. Analisis Data

Pada penelitian ini, data yang digunakan adalah kandungan *Particulate Matter* 10 dan 2.5 yang diukur di lima stasiun pemantauan yang tersebar di wilayah provinsi DKI Jakarta. Stasiun DKI1 terletak di Jakarta Pusat, DKI2 terletak di Jakarta Utara, DKI3 terletak di Jakarta Selatan, DKI4 terletak di Jakarta Timur, dan DKI5 terletak di Jakarta Barat. Data tersebut kemudian dianalisis menggunakan metode ARIMA untuk

menentukan model matematis kandungan *Particulate Matter* 10 dan 2.5 di provinsi DKI Jakarta. Pada analisis data, kandungan *Particulate Matter* 10 dan 2.5 dibagi menjadi data *in-sample* dan data *out-sample*. Data *in-sample* dari tanggal 1 Januari 2021 sampai 19 Oktober 2021 sebanyak 292 data. Sementara itu, data *out-sample* mulai dari tanggal 20 Oktober 2021 sampai 31 Desember 2021 sebanyak 73 data.

### 3.3. Tahapan Penelitian

Pada penelitian ini, untuk melakukan pemodelan, dilakukan studi literatur dari penelitian sebelumnya, pengumpulan referensi dari jurnal-jurnal yang relevan, pencarian data yang sesuai dengan topik penelitian, pengolahan data menggunakan metode yang telah ditentukan, analisis data, dan akhirnya memperoleh model matematis dari data yang diolah. Berikut langkah pada pemodelan kandungan *Particulate Matter* 10 dan 2.5 di provinsi DKI Jakarta menggunakan metode ARIMA.

1. Menggunakan data kandungan *Particulate Matter* 10 dan 2.5 di Provinsi DKI Jakarta.
2. Membagi data kandungan *Particulate Matter* 10 dan 2.5 menjadi 10 bagian yaitu kandungan *Particulate Matter* 10 ( $PM_{10}$ ) di stasiun DKI1, DKI2, DKI3, DKI4, dan DKI5, serta kandungan *Particulate Matter* 2.5 ( $PM_{2.5}$ ) di stasiun DKI1, DKI2, DKI3, DKI4, dan DKI5.
3. Pembagian data menjadi 2 yaitu data *in-sample* dan data *out-sample* pada masing-masing stasiun pengamatan sebagai berikut:
  - (a) Untuk data kandungan *Particulate Matter* 10 ( $PM_{10}$ ) di lima stasiun

pengamatan.

- i. Data *in-sample* menggunakan data dari tanggal 1 Januari 2021 hingga tanggal 19 Oktober 2021 sebanyak 292 data.
- ii. Data *out-sample* menggunakan data dari tanggal 20 Oktober 2021 hingga tanggal 31 Desember 2021 sebanyak 73 data.

(b) Untuk data kandungan *Particulate Matter 2.5* ( $PM_{2.5}$ ) di lima stasiun pengamatan.

- i. Data *in-sample* menggunakan data dari tanggal 1 Januari 2021 hingga tanggal 19 Oktober 2021 sebanyak 292 data.
- ii. Data *out-sample* menggunakan data dari tanggal 20 Oktober 2021 hingga tanggal 31 Desember 2021 sebanyak 73 data.

4. Mengidentifikasi data yang digunakan sudah memenuhi stasioner dalam varians dan *mean* atau belum. Jika belum memenuhi maka harus dilakukan proses berikut:

(a) Stasioner dalam varians

Untuk menentukan apakah data sudah stasioner dalam varians, periksa apakah nilai *rounded value* bernilai sama dengan satu atau nilai *lower* dan *upper* sudah lebih dari 1. Jika salah satu dari syarat tersebut belum memenuhi, maka dilakukan transformasi hingga salah satu syarat terpenuhi.

(b) Stasioner dalam rata-rata (*mean*)

Jika data belum stasioner terhadap *mean*, perlu dilakukan proses

*differencing* untuk mencari perbedaan antara data satu periode dengan data periode sebelumnya secara berurutan. *differencing*.

5. Melakukan Plot ACF dan PACF dari data yang digunakan.
6. Menentukan model sementara melalui plot ACF dan PACF apabila data dinyatakan sudah stasioner.
7. Melakukan estimasi parameter dari beberapa model sementara yang didapat dari tahap sebelumnya.

8. Menguji asumsi residual.

Apabila model yang diuji pada tahap ini sudah memenuhi syarat *white-noise* dan berdistribusi normal maka model layak digunakan pada langkah selanjutnya, namun jika belum memenuhi syarat *white-noise* dan berdistribusi normal maka dilakukan deteksi *outlier* untuk mengatasi masalah tersebut.

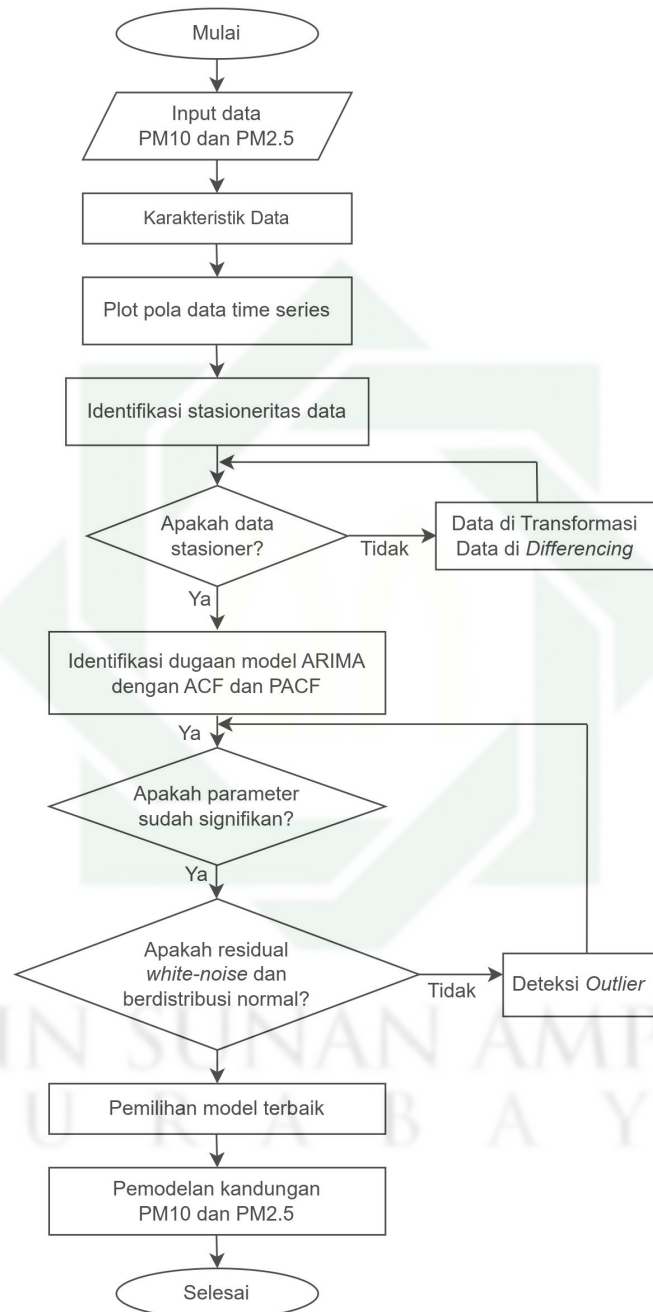
9. Melakukan Deteksi *Outlier*.

Model yang tidak memenuhi asumsi residual dilakukan deteksi *outlier* dengan cara mencari keberadaan *outlier*, memasukkan *outlier* ke dalam data, lalu menguji ulang asumsi residual. Apabila residual sudah memenuhi syarat *white-noise* dan berdistribusi normal maka model tersebut digunakan pada tahap berikutnya, namun jika asumsi residual tidak terpenuhi juga, maka yang digunakan pada tahap berikutnya adalah model tanpa deteksi *outlier*.

10. Memilih model terbaik.

Menentukan model terbaik dari metode ARIMA berdasarkan nilai MAPE pada data *out sample*.

11. Membuat model matematis kandungan *Particulate Matter* 10 dan 2.5 di masing-masing lima stasiun pengamatan provinsi DKI Jakarta.



**Gambar 3.1 Tahapan Penelitian**

## BAB IV

### HASIL DAN PEMBAHASAN

Pada bagian hasil dan pembahasan, akan diuraikan analisis dan pembahasan terkait prediksi kandungan *Particulate Matter* 10 dan 2.5 di provinsi DKI Jakarta.

#### 4.1. Karakteristik Data

Karakteristik data digunakan untuk melihat gambaran umum sebuah data.

##### 4.1.1. Karakteristik Data Kandungan *Particulate Matter* 10 (PM<sub>10</sub>)

Karakteristik data pada kandungan *Particulate Matter* 10 (PM<sub>10</sub>) di lima stasiun menggunakan statistika deskriptif yang dapat dilihat pada Tabel 4.1.


Tabel 4.1 Karakteristik Data Kandungan *Particulate Matter* 10 (PM<sub>10</sub>)

Stasiun Pengamatan	Mean	Variance	Min	Max
DKI1	49.833	154.041	19	79
DKI2	55.796	248.798	18	94
DKI3	53.421	180.888	15	89
DKI4	54.042	272.504	14	179
DKI5	48.377	181.343	15	83

Berdasarkan Tabel 4.1 rata-rata kandungan PM<sub>10</sub> di provinsi DKI Jakarta tahun



2021 tertinggi sebesar 55.796 sedangkan rata-rata terendah sebesar 48.377. Untuk lebih jelasnya ditunjukkan juga pada grafik dengan batas maksimum rata-rata harian  $PM_{10}$  menurut *World Health Organization* (WHO).



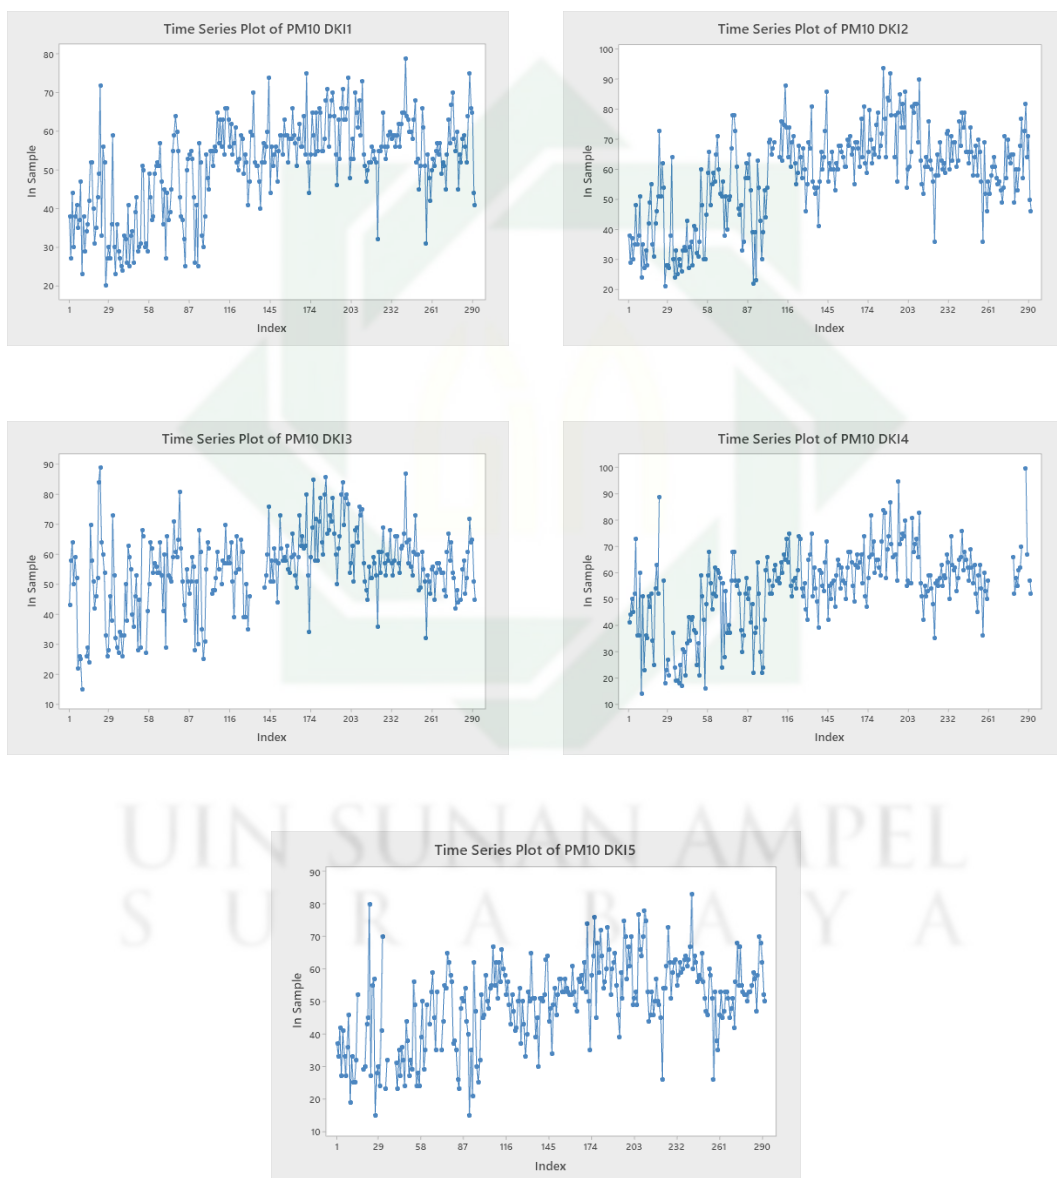
Gambar 4.1 Grafik Karakteristik Data Kandungan  $PM_{10}$

Berdasarkan grafik pada gambar 4.1 diketahui bahwa batas maksimum rata-rata harian kandungan  $PM_{10}$  yaitu  $50\mu g/m^3$  yang ditandai dengan warna abu-abu. Pada lima stasiun pengamatan, kandungan  $PM_{10}$  hampir berkisar di sekitar rata-rata. Stasiun DKI2 sampai DKI4 memiliki rata-rata melebihi batas maksimum dikarenakan banyaknya sektor industri atau kendaraan bermotor yang digunakan untuk keperluan sehari-hari.

Stasiun DKI2 yang berada di Jakarta Utara memiliki rata-rata tertinggi bernilai 55.796 dengan nilai kandungan paling tinggi senilai 94. Kandungan  $PM_{10}$  di stasiun DKI2 banyak yang bernilai hampir sama dengan rata-rata, hal tersebut ditunjukkan dengan nilai *variance* yang cukup tinggi sebesar 248.798. Kandungan  $PM_{10}$  paling tinggi dan paling rendah pada stasiun DKI4 yang berada di Jakarta Timur sebesar 179 dan 14 dengan rata-rata 54.042. Rata-rata kandungan  $PM_{10}$  yang berada di bawah batas maksimum adalah stasiun DKI1 dan DKI5 sebesar 49.833 dan 48.377. Meskipun

demikian, rata-rata pada stasiun DKI1 dan DKI5 hampir mendekati batas maksimum dan nilai kandungan tertinggi melewati batas maksimum harian yang telah ditetapkan oleh WHO.

Karakteristik lain dapat menggunakan plot *time series* untuk melihat pola data pada kandungan  $PM_{10}$ . Berikut plot *time series* pada kandungan  $PM_{10}$ .



**Gambar 4.2** Plot *Time Series* Kandungan  $PM_{10}$  Pada Lima Stasiun Pengamatan

Gambar 4.2 menunjukkan bahwa kandungan  $PM_{10}$  berpola acak karena tidak terlihat adanya musiman maupun trend yang ditandai dengan data mengalami kenaikan dan penurunan secara bebas.


#### 4.1.2. Karakteristik Data Kandungan *Particulate Matter 2.5* ( $PM_{2.5}$ )

Karakteristik data pada kandungan *Particulate Matter 2.5* ( $PM_{2.5}$ ) di lima stasiun pengamatan didapatkan dari statistika deskriptif yang dapat dilihat pada Tabel 4.2.

**Tabel 4.2 Karakteristik Data Kandungan *Particulate Matter 2.5* ( $PM_{2.5}$ )**

Stasiun Pengamatan	Mean	Variance	Min	Max
DKI1	31.044	173.617	2.94	79.87
DKI2	37.598	269.968	8.47	118.220
DKI3	38.617	238.260	7.73	97.53
DKI4	49.60	490.53	8.87	47.62
DKI5	37.90	274.281	8.35	36.64

Berdasarkan Tabel 4.2 rata-rata kandungan  $PM_{2.5}$  di provinsi DKI Jakarta tahun 2021 tertinggi sebesar 49.60 sedangkan rata-rata terendah sebesar 31.044. Untuk lebih jelasnya ditunjukkan juga pada grafik dengan batas maksimum rata-rata harian  $PM_{2.5}$  menurut *World Health Organization* (WHO).

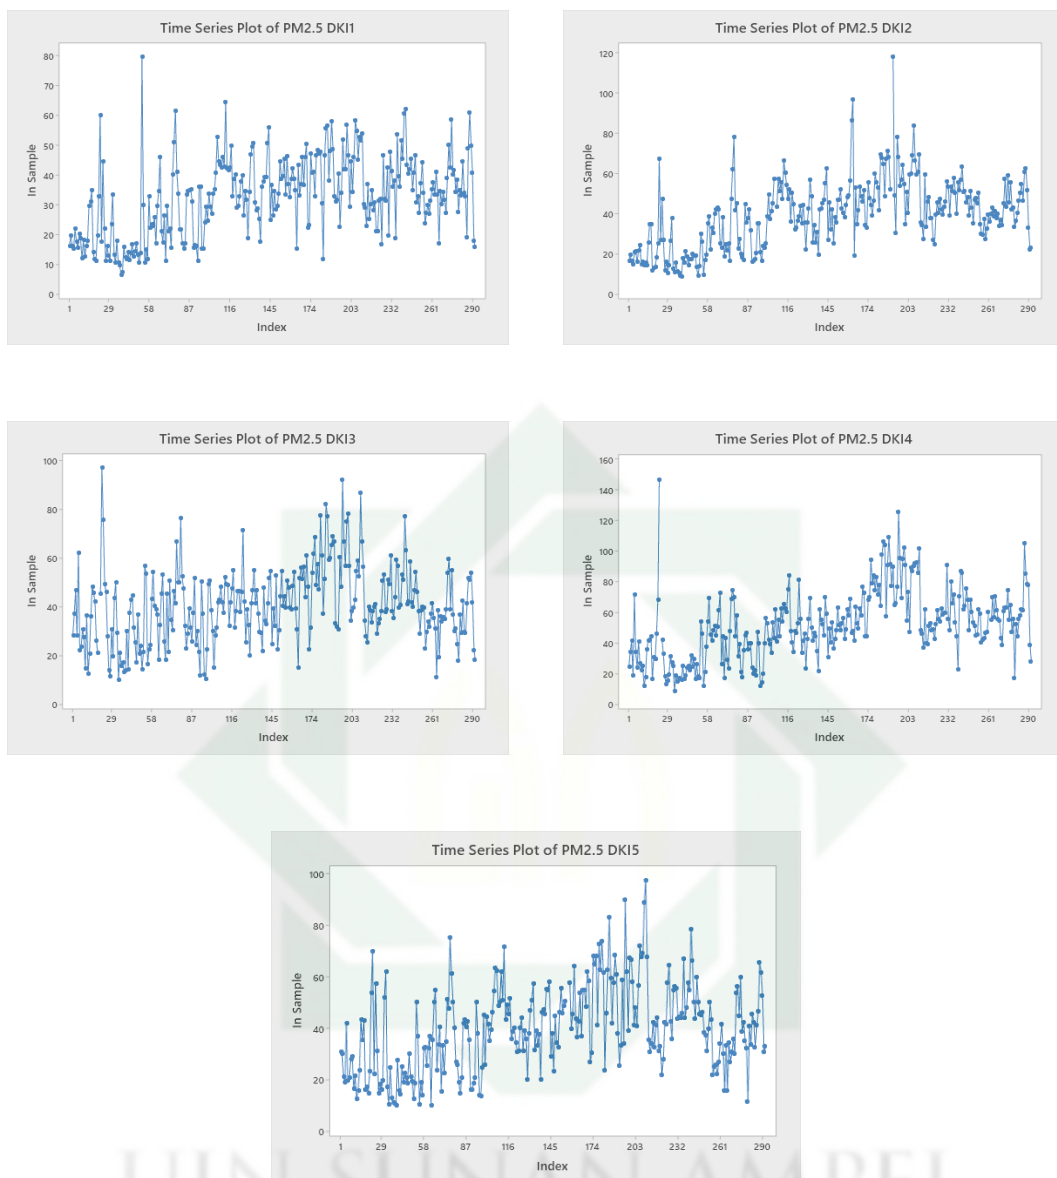


**Gambar 4.3 Grafik Karakteristik Data Kandungan PM<sub>2.5</sub>**

Berdasarkan grafik pada gambar 4.3 diketahui bahwa batas maksimum rata-rata harian kandungan PM<sub>2.5</sub> yaitu  $25\mu\text{g}/\text{m}^3$  yang ditandai dengan warna abu-abu. Pada lima stasiun pengamatan, rata-rata kandungan PM<sub>2.5</sub> seluruhnya melebihi batas maksimum rata-rata harian yang telah ditetapkan karena banyaknya sektor industri atau kendaraan bermotor yang digunakan untuk keperluan sehari-hari.

Stasiun DKI4 yang berada di Jakarta Timur memiliki rata-rata tertinggi sebesar 49.60 dengan nilai kandungan paling tinggi senilai 47.62. Kandungan PM<sub>2.5</sub> di stasiun DKI4 banyak yang bernilai hampir sama dengan rata-rata, hal tersebut ditunjukkan dengan nilai *variance* yang cukup tinggi sebesar 490.53. Kandungan PM<sub>2.5</sub> paling tinggi pada stasiun DKI2 dengan nilai 118.220 dan kandungan paling rendah pada stasiun DKI1 dengan nilai 2.94. Rata-rata kandungan PM<sub>2.5</sub> dan nilai kandungan tertinggi seluruhnya melewati batas maksimum rata-rata harian yang telah ditetapkan oleh WHO.

Karakteristik lain dapat menggunakan plot *time series* untuk melihat pola data pada kandungan PM<sub>2.5</sub>. Berikut plot *time series* pada kandungan PM<sub>2.5</sub>.

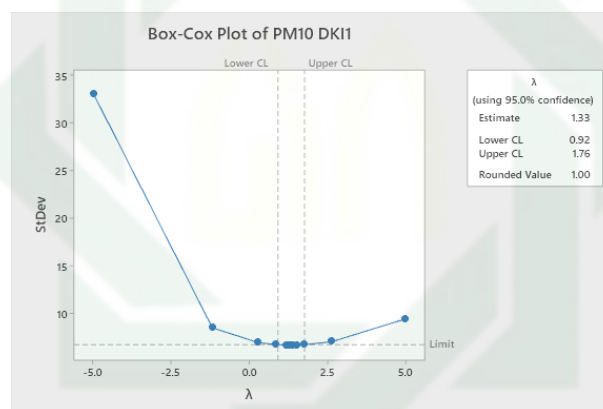


**Gambar 4.4** Plot *Time Series* Kandungan  $PM_{2.5}$  Pada Lima Stasiun Pengamatan

Gambar 4.4 menunjukkan bahwa kandungan  $PM_{2.5}$  memiliki pola yang acak karena mengalami kenaikan dan penurunan secara bebas serta tidak memiliki pola musiman atau trend yang jelas.


#### 4.2. Proses ARIMA *Particulate Matter 10* (PM<sub>10</sub>)

Sebelum dilakukan suatu prediksi menggunakan metode ARIMA, data yang digunakan harus memenuhi proses ARIMA mulai dari cek stasioneritas, membangun model sementara, menghitung nilai estimasi parameter, uji *white-noise* serta uji distribusi normal, dan mencari model terbaik berdasarkan nilai error terkecil. Pada data kandungan PM<sub>10</sub> telah diamati di lima stasiun pengamatan salah satunya pada stasiun DKI1. Dalam ARIMA, data harus memenuhi kestasioneran baik dalam varians maupun *mean*. Pengecekan stasioner dalam varians menggunakan Box-Cox dapat dilihat pada Gambar 4.5.




Gambar 4.5 *Box-Cox Plot* PM<sub>10</sub> Stasiun DKI1

Gambar 4.5 menunjukkan hasil *Box-Cox* dengan nilai *rounded value* sebesar 1.00 maka kandungan PM<sub>10</sub> stasiun DKI1 dikatakan sudah stasioner dalam varians. Selanjutnya dilakukan pengecekan stasioner dalam *mean* menggunakan uji *Augmented Dickey-Fuller* (ADF Test) atau dapat dilihat pada plot *time series* maupun plot ACF.




**Gambar 4.6 Plot ACF PM<sub>10</sub> Stasiun DK11**


Pada plot *time-series* terlihat bahwa data belum berada di sekitar rata-rata. Hasil dari ADF *Test* menunjukkan bahwa nilai *p-value* sebesar 0.01454, yang mana nilai tersebut kurang dari taraf signifikan atau  $\alpha = 5\%$  (0.05), sehingga data dapat dikatakan sudah stasioner dalam *mean*. Akan tetapi pada Gambar 4.6 terlihat bahwa *lag* pada plot ACF banyak yang keluar batas signifikan maka perlu dilakukan *differencing* satu ( $d = 1$ ) yang hasil plot nya dapat dilihat pada Gambar 4.7.



**Gambar 4.7 Time Series Plot Hasil Differencing PM<sub>10</sub> Stasiun DK11**



Gambar 4.8 Plot ACF setelah *Differencing* PM<sub>10</sub> DKI1



Gambar 4.9 Plot PACF setelah *Differencing* PM<sub>10</sub> DKI1

Berdasarkan Gambar 4.7 dapat dilihat bahwa kandungan PM<sub>10</sub> di stasiun DKI1 sudah berada di sekitar rata-rata dan hasil ADF *Test* setelah *differencing* sebesar 0.01 yang kurang dari nilai  $\alpha$ , maka dapat dikatakan bahwa data telah stasioner dalam *mean* setelah dilakukan *differencing*. Selanjutnya yaitu penduga model ARIMA yang dilihat dari plot ACF dan PACF. Dugaan model sementara yang dibentuk dapat dilihat pada Tabel berikut.

Tabel 4.3 Kombinasi Model ARIMA Kandungan PM<sub>10</sub> DKI1

Model	Parameter	<i>p-value</i>	Keputusan	Uji Residual	MAPE
ARIMA(0,1,1)	MA(1)	< 0.0001	signifikan	tidak <i>white-noise</i>	23.4838
ARIMA(1,1,0)	AR(1)	< 0.0001	signifikan	tidak <i>white-noise</i>	24.2763
ARIMA([4],1,0)	AR[4]	0.0478	signifikan	tidak <i>white-noise</i>	26.3167
ARIMA(0,1,[23])	MA[23]	0.0045	signifikan	tidak <i>white-noise</i>	24.7677
ARIMA(1,1,1)	AR(1)	< 0.0001	signifikan	<i>white-noise</i> dan berdistribusi normal	23.4977
	MA(1)	< 0.0001			



Model	Parameter	<i>p-value</i>	Keputusan	Uji Residual	MAPE
ARIMA([4],1,1)	AR[4]	0.001	signifikan	tidak <i>white-noise</i>	22.6994
	MA(1)	< 0.0001			
ARIMA(1,1,[23])	AR(1)	< 0.0001	signifikan	tidak <i>white-noise</i>	23.0089
	MA[23]	0.0253			

Pada tabel 4.3 menunjukkan model ARIMA sementara yang dibentuk dan telah memenuhi uji signifikansi parameter. Pengujian dilakukan untuk melihat apakah parameter telah signifikan serta layak untuk dilakukan proses selanjutnya. Model dikatakan signifikan apabila nilai *p-value* kurang dari  $\alpha = 0.05$  dan dalam uji statistik nilai  $|t_{hitung}| > t_{0.025,364}$  maka tolak  $H_0$  yang artinya model ARIMA telah signifikan. Model ARIMA yang memenuhi uji signifikansi dan kedua uji residual adalah ARIMA(1,1,1). Uji asumsi residual model ARIMA(1,1,1) dilakukan menggunakan Uji *Ljung-Box* dan Uji *Kolmogorov-Smirnov* dimana keputusan diambil apabila nilai *p-value* lebih besar dari  $\alpha$  maka model memenuhi syarat *white-noise* dan berdistribusi normal. Hasil uji asumsi residual dapat dilihat pada Tabel berikut.

**Tabel 4.4 Uji Asumsi Residual ARIMA(1,1,1) PM<sub>10</sub> Stasiun DKI1**

lag	Chi-square	DF	p-value uji white-noise	p-value uji distribusi normal
12	11.58	10	0.3139	> 0.1500
24	33.91	22	0.0502	

lag	Chi-square	DF	p-value uji white-noise	p-value uji distribusi normal
36	38.11	34	0.2879	> 0.1500
48	53.03	46	0.2215	

Pada Tabel 4.4 ditunjukkan bahwa seluruh *lag* menghasilkan nilai *p-value* lebih dari  $\alpha = 0.05$  atau dalam uji statistik nilai  $Q(k) < X_{0.05,46}^2$  maka  $H_0$  diterima yang berarti model ARIMA(1,1,1) dikatakan sudah memenuhi syarat *white-noise*. Untuk uji distribusi normal data dikatakan sudah berdistribusi normal jika nilai *p-value* lebih dari  $\alpha = 0.05$  atau dalam uji statistik nilai  $D < D_{1-0.05,n>40}$  maka  $H_0$  diterima yang berarti model ARIMA(1,1,1) telah berdistribusi normal.

### 4.3. Nilai Akurasi dan Model ARIMA

Setelah melalui proses ARIMA hingga uji asumsi residual, selanjutnya yaitu menghitung nilai akurasi pada model terbaik yang telah didapatkan dan menyusun persamaan dari model ARIMA tersebut.

#### 4.3.1. Nilai Akurasi dan Model ARIMA PM<sub>10</sub> DKI1

Pada stasiun DKI1 didapat model terbaik yaitu ARIMA(1,1,1) karena model tersebut telah memenuhi uji stasioneritas, uji *white-noise*, dan berdistribusi normal sehingga tidak perlu dilakukan deteksi *outlier* pada data. Nilai MAPE model ARIMA(1,1,1) tanpa *outlier* dapat dilihat pada Tabel 4.5.

**Tabel 4.5 Nilai akurasi Kandungan PM<sub>10</sub> DKI1**

ARIMA Model	MAPE
ARIMA(1,1,1) tanpa <i>outlier</i>	23.4977

Nilai MAPE yang diperoleh yaitu 23.4977, apabila digunakan untuk prediksi maka hasil prediksi yang didapatkan cukup baik. Selanjutnya, persamaan model ARIMA(1,1,1) sebagai berikut.

$$\phi_p(B)(1 - B)^d A_t = \theta_q(B)e_t$$

$$(1 - \phi_1 B)(1 - B)^1 A_t = (1 - \theta_1 B)e_t$$

$$(1 - B - \phi_1 B + \phi_1 B^2)A_t = e_t - \theta_1 e_{t-1}$$

$$A_t - A_{t-1} - \phi_1 A_{t-1} + \phi_1 A_{t-2} = e_t - \theta_1 e_{t-1}$$


$$A_t = A_{t-1} + \phi_1 A_{t-1} - \phi_1 A_{t-2} + e_t - \theta_1 e_{t-1}$$

$$A_t = (1 - \phi_1)A_{t-1} - \phi_1 A_{t-2} - \theta_1 e_{t-1} + e_t$$

$$A_t = (1 - 0.31861)A_{t-1} - 0.31861A_{t-2} - 0.91722e_{t-1} + e_t$$

$$A_t = 0.68139A_{t-1} - 0.31861A_{t-2} - 0.91722e_{t-1} + e_t$$

Berikut grafik perbandingan data *outsample* dengan prediksi kandungan PM<sub>10</sub> stasiun DKI1.

**Gambar 4.10 Plot Data *Outsample* dan Hasil Prediksi Kandungan PM<sub>10</sub> Stasiun DKI1**

Pada gambar 4.10 menunjukkan bahwa pergerakan kandungan  $PM_{10}$  mengalami kenaikan dan penurunan secara teratur dengan kandungan tertinggi dan terendah terjadi pada 23 Desember dan 30 November 2021.

#### 4.3.2. Nilai Akurasi dan Model ARIMA $PM_{10}$ DKI2

Model yang telah memenuhi syarat kestasioneritasan dan kedua uji asumsi residual pada stasiun DKI2 adalah ARIMA(1,1,1). Data tidak perlu dilakukan deteksi *outlier* karena asumsi telah terpenuhi. Proses ARIMA pada stasiun DKI2 dapat dilihat pada Lampiran 3. Selanjutnya, nilai MAPE model ARIMA(1,1,1) ditunjukkan pada Tabel 4.5.

**Tabel 4.6 Nilai akurasi Kandungan  $PM_{10}$  DKI2**

ARIMA Model	MAPE
ARIMA(1,1,1) tanpa <i>outlier</i>	25.5548

Model ARIMA(1,1,1) menghasilkan nilai MAPE sebesar 25.0917, jika digunakan untuk memprediksi maka hasil prediksi masuk dalam kategori cukup baik.

Persamaan model ARIMA(1,1,1) yaitu:

$$\phi_p(B)(1 - B)^d A_t = \theta_q(B)e_t$$

$$(1 - \phi_1 B)(1 - B)^1 A_t = (1 - \theta_1 B)e_t$$

$$(1 - B - \phi_1 B + \phi_1 B^2)A_t = e_t - \theta_1 e_{t-1}$$

$$A_t - A_{t-1} - \phi_1 A_{t-1} + \phi_1 A_{t-2} = e_t - \theta_1 e_{t-1}$$


$$A_t = A_{t-1} + \phi_1 A_{t-1} - \phi_1 A_{t-2} + e_t - \theta_1 e_{t-1}$$

$$A_t = (1 - \phi_1)A_{t-1} - \phi_1 A_{t-2} - \theta_1 e_{t-1} + e_t$$

$$A_t = (1 - 0.39673)A_{t-1} - 0.39673A_{t-2} - 0.90313e_{t-1} + e_t$$

$$A_t = 0.60327A_{t-1} - 0.39673A_{t-2} - 0.90313e_{t-1} + e_t$$

Berikut grafik perbandingan data *outsample* dengan prediksi kandungan PM<sub>10</sub> stasiun DKI2.



Gambar 4.11 Plot Data *Outsample* dan Hasil Prediksi Kandungan PM<sub>10</sub> Stasiun DKI2

Pada gambar 4.11 menunjukkan bahwa pergerakan kandungan PM<sub>10</sub> hampir mengikuti data aktualnya yang mengalami kenaikan dan penurunan secara teratur dengan kandungan tertinggi sebesar 61.2475 dan kandungan terendah sebesar 28.2128 pada 28 Oktober dan 27 November 2021.

#### 4.3.3. Nilai Akurasi dan Model ARIMA PM<sub>10</sub> DKI3

Model terbaik stasiun DKI3 adalah ARIMA(1,1,1) yang telah memenuhi syarat kestasioneritasan dan kedua uji asumsi residual. Data tidak perlu dilakukan deteksi *outlier* karena asumsi telah terpenuhi. Proses ARIMA pada stasiun DKI3 dapat dilihat pada Lampiran 4 dan nilai MAPE ARIMA(1,1,1) tanpa tambahan *outlier* pada Tabel berikut.

**Tabel 4.7 Nilai akurasi Kandungan PM<sub>10</sub> DKI3**

ARIMA Model	MAPE
ARIMA(1,1,1) tanpa <i>outlier</i>	25.2128

MAPE yang diperoleh bernilai 25.2128 yang masuk pada kategori cukup baik untuk dijadikan prediksi. Persamaan ARIMA(1,1,1) stasiun DKI3 sebagai berikut.

$$\phi_p(B)(1 - B)^d A_t = \theta_q(B)e_t$$

$$(1 - \phi_1 B)(1 - B)^1 A_t = (1 - \theta_1 B)e_t$$

$$(1 - B - \phi_1 B + \phi_1 B^2)A_t = e_t - \theta_1 e_{t-1}$$

$$A_t - A_{t-1} - \phi_1 A_{t-1} + \phi_1 A_{t-2} = e_t - \theta_1 e_{t-1}$$


$$A_t = A_{t-1} + \phi_1 A_{t-1} - \phi_1 A_{t-2} + e_t - \theta_1 e_{t-1}$$

$$A_t = (1 - \phi_1)A_{t-1} - \phi_1 A_{t-2} - \theta_1 e_{t-1} + e_t$$

$$A_t = (1 - 0.43072)A_{t-1} - 0.43072A_{t-2} - 0.95318e_{t-1} + e_t$$

$$A_t = 0.56928A_{t-1} - 0.43072A_{t-2} - 0.95318e_{t-1} + e_t$$

Berikut grafik perbandingan data *outsample* dengan prediksi kandungan PM<sub>10</sub> stasiun DKI3.

**Gambar 4.12 Plot Data *Outsample* dan Hasil Prediksi Kandungan PM<sub>10</sub> Stasiun DKI3**

Pada gambar 4.12 terlihat bahwa pergerakan  $PM_{10}$  berada di sekitar rata-rata dengan kandungan paling rendah pada 29 November 2021 sebesar 34.5511.

#### 4.3.4. Nilai Akurasi dan Model ARIMA $PM_{10}$ DKI4

Pada kandungan  $PM_{10}$  stasiun DKI4 terdapat dua model yang memenuhi uji stasioner, uji *white-noise*, dan berdistribusi normal. Model tersebut yaitu ARIMA(1,1,1) dan ARIMA(3,1,1) yang langkah-langkah nya dapat dilihat pada Lampiran 5. Deteksi *outlier* tidak dilakukan karena data sudah memenuhi asumsi *white-noise* dan berdistribusi normal. Model terbaik dipilih menggunakan nilai MAPE terkecil yang ditunjukkan pada Tabel berikut.

**Tabel 4.8 Nilai akurasi Kandungan  $PM_{10}$  DKI4**

ARIMA Model	MAPE
ARIMA(1,1,1) tanpa <i>outlier</i>	28.2749
ARIMA(3,1,1) tanpa <i>outlier</i>	28.0624

MAPE terkecil yaitu pada model ARIMA(3,1,1) sebesar 28.0624, apabila digunakan untuk melakukan prediksi maka prediksi yang didapatkan cukup baik. Model ARIMA(3,1,1) dibentuk persamaan sebagai berikut.

$$\phi_p(B)(1 - B)^d A_t = \theta_q(B)e_t$$

$$(1 - \phi_1 B)(1 - B)^1 A_t = (1 - \theta_1 B)e_t$$

$$(1 - \phi_1 B - \phi_2 B^2 - \phi_3 B^3)(1 - B)A_t = (1 - \theta_1 B)e_t$$

$$(1 - B - \phi_1 B + \phi_1 B^2 - \phi_2 B^2 + \phi_2 B^3 - \phi_3 B^3 + \phi_3 B^4)A_t = e_t - \theta_1 e_{t-1}$$

$$A_t - A_{t-1} - \phi_1 A_{t-1} + \phi_1 A_{t-2} - \phi_2 A_{t-2} + \phi_2 A_{t-3} - \phi_3 A_{t-3} + \phi_3 A_{t-4} = e_t - \theta_1 e_{t-1}$$

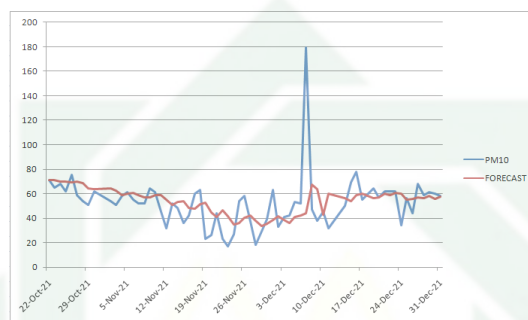
$$A_t = A_{t-1} + \phi_1 A_{t-1} - \phi_1 A_{t-2} + \phi_2 A_{t-2} - \phi_2 A_{t-3} + \phi_3 A_{t-3} - \phi_3 A_{t-4} + e_t - \theta_1 e_{t-1}$$

$$A_t = (1 - \phi_1)A_{t-1} - (\phi_1 - \phi_2)A_{t-2} - (\phi_2 - \phi_3)A_{t-3} - \phi_3A_{t-4} - \theta_1e_{t-1} + e_t$$

$$A_t = (1 - 0.33292)A_{t-1} - (0.33292 - 0.00569)A_{t-2} - (0.00569 - 0.21668)A_{t-3} - 0.21668A_{t-4} - 0.66403e_{t-1} + e_t$$

$$A_t = 0.66708A_{t-1} - 0.32723A_{t-2} + 0.21099A_{t-3} - 0.21668A_{t-4} - 0.66403e_{t-1} + e_t$$

Berikut grafik perbandingan data *outsample* dengan prediksi kandungan PM<sub>10</sub> stasiun DKI4.



Gambar 4.13 Plot Data *Outsample* dan Hasil Prediksi Kandungan PM<sub>10</sub> Stasiun DKI4

Pada gambar 4.13 pergerakan kandungan PM<sub>10</sub> berkisar di sekitar rata-rata serta tidak mengalami kenaikan maupun penurunan seperti aktualnya. Kandungan tertinggi pada 21 Oktober 2021 sebesar 71.00.

#### 4.3.5. Nilai Akurasi dan Model ARIMA PM<sub>10</sub> DKI5

Langkah-langkah ARIMA stasiun DKI5 dapat dilihat pada Lampiran 6 dan didapat model ARIMA yang memenuhi uji stasioneritas dan kedua uji asumsi residual adalah model ARIMA(1,1,1). Deteksi *outlier* tidak perlu dilakukan karena syarat ARIMA sudah terpenuhi. Nilai MAPE model ARIMA(1,1,1) ditunjukkan pada Tabel 4.9.



**Tabel 4.9 Nilai akurasi Kandungan PM<sub>10</sub> DKI5**

ARIMA Model	MAPE
ARIMA(1,1,1) tanpa <i>outlier</i>	29.164

Nilai MAPE model ARIMA(1,1,1) yaitu 29.164. Prediksi yang dilakukan mendapatkan hasil yang cukup baik karena nilai MAPE berkisar 20 - 50%. Persamaan ARIMA(1,1,1) adalah sebagai berikut.

$$\phi_p(B)(1 - B)^d A_t = \theta_q(B)e_t$$

$$(1 - \phi_1 B)(1 - B)^1 A_t = (1 - \theta_1 B)e_t$$

$$(1 - B - \phi_1 B + \phi_1 B^2)A_t = e_t - \theta_1 e_{t-1}$$

$$A_t - A_{t-1} - \phi_1 A_{t-1} + \phi_1 A_{t-2} = e_t - \theta_1 e_{t-1}$$


$$A_t = A_{t-1} + \phi_1 A_{t-1} - \phi_1 A_{t-2} + e_t - \theta_1 e_{t-1}$$

$$A_t = (1 - \phi_1)A_{t-1} - \phi_1 A_{t-2} - \theta_1 e_{t-1} + e_t$$

$$A_t = (1 - 0.28776)A_{t-1} - 0.28776A_{t-2} - 0.93118e_{t-1} + e_t$$

$$A_t = 0.71224A_{t-1} - 0.28776A_{t-2} - 0.93118e_{t-1} + e_t$$

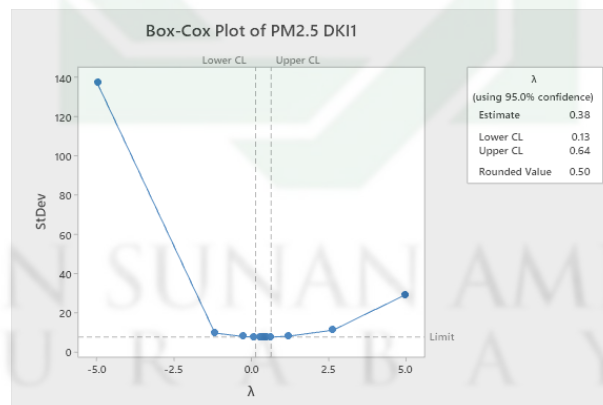
Berikut grafik perbandingan data *outsample* dengan prediksi kandungan PM<sub>10</sub> stasiun DKI5.

**Gambar 4.14 Plot Data *Outsample* dan Hasil Prediksi Kandungan PM<sub>10</sub> Stasiun DKI5**

Pada gambar 4.14 kandungan  $PM_{10}$  mengalami kenaikan dan penurunan secara teratur yang tidak jauh dari data aktualnya. Kandungan tertinggi dan terendah pada 27 Oktober dan 30 November 2021.

#### 4.4. Proses ARIMA *Particulate Matter 2.5* ( $PM_{2.5}$ )


Sebelum melakukan prediksi dengan metode ARIMA, terdapat tahapan-tahapan untuk memastikan bahwa data yang digunakan memenuhi persyaratan ARIMA. Tahapan tersebut meliputi pemeriksaan stasioneritas data, pembangunan model sementara, estimasi nilai parameter, pengujian white-noise dan distribusi normal, serta mencari model terbaik berdasarkan error terkecil. Salah satu stasiun yang diamati adalah stasiun DKI1 menggunakan metode ARIMA. Data pada metode ARIMA harus memenuhi syarat stasioner dalam varians maupun dalam *mean*. Uji stasioner dalam varians dengan Box-Cox ditunjukkan pada Gambar 4.15.



Gambar 4.15 *Box-Cox Plot*  $PM_{2.5}$  Stasiun DKI1


Pada Gambar 4.15 dapat dilihat bahwa nilai *rounded value* bernilai 0.50 serta nilai *lower upper* belum bernilai lebih dari 1, yang berarti data belum stasioner dalam

varians. Maka perlu dilakukan transformasi dan dihasilkan plot *Box-Cox* baru yang dapat dilihat pada Gambar 4.16.




**Gambar 4.16** *Box-Cox* Plot Setelah di Transformasi  $PM_{2.5}$  Stasiun DKI1

Gambar 4.16 menunjukkan hasil *Box-Cox* dengan nilai *rounded value* sebesar 1.00 maka kandungan  $PM_{2.5}$  stasiun DKI1 sudah stasioner dalam varians. Selanjutnya dilakukan uji stasioner dalam *mean* dengan uji *Augmented Dickey-Fuller (ADF Test)* serta dapat dilihat pada plot *time series* maupun plot *ACF*.




**Gambar 4.17** Plot *ACF*  $PM_{2.5}$  Stasiun DKI1


Plot *time series* menunjukkan bahwa data belum berada di sekitar rata-rata. Hasil dari ADF Test yaitu nilai *p-value* sebesar 0.01 yang berarti data dikatakan telah stasioner dalam *mean*. Akan tetapi, pada Gambar 4.17 masih terdapat *lag* yang melebihi batas signifikan maka perlu dilakukan *differencing* satu ( $d = 1$ ) yang hasil plot nya dapat dilihat pada Gambar 4.18.



Gambar 4.18 Time Series Plot Hasil Differencing  $PM_{2.5}$  Stasiun DKI1



Gambar 4.19 Plot ACF setelah Differencing  $PM_{2.5}$  DKI1



Gambar 4.20 Plot PACF setelah Differencing  $PM_{2.5}$  DKI1

Berdasarkan Gambar 4.18 dapat dilihat bahwa kandungan  $PM_{2.5}$  di stasiun DKI1 sudah stasioner dalam *mean* karena grafik sudah berada di sekitar rata-rata dan

hasil ADF *Test* sebesar 0.01 yang kurang dari  $\alpha = 0.05$  setelah dilakukan *differencing*. Kemudian dari plot ACF dan PACF dibentuk dugaan model sementara yang ditunjukkan pada Tabel berikut.

**Tabel 4.10 Kombinasi Model ARIMA Kandungan PM<sub>2.5</sub> DKI**

Model	Parameter	<i>p-value</i>	Keputusan	Uji Residual	MAPE
ARIMA(1,1,0)	AR(1)	< 0.0001	signifikan	tidak <i>white-noise</i> dan tidak berdistribusi normal	35.7804
ARIMA(0,1,1)	MA(1)	< 0.0001	signifikan	tidak <i>white-noise</i> dan tidak berdistribusi normal	36.8106
ARIMA(1,1,1)	AR(1)	< 0.0001	signifikan	tidak berdistribusi normal	37.1397
	MA(1)	< 0.0001			
ARIMA([3],1,1)	AR[3]	< 0.0001	signifikan	tidak <i>white-noise</i> dan tidak berdistribusi normal	36.1308
	MA(1)	0.0461			
ARIMA([4],1,1)	AR[4]	0.0038	signifikan	tidak <i>white-noise</i> dan tidak berdistribusi normal	36.6047
	MA(1)	< 0.0001			

Pada Tabel 4.10 ditunjukkan model ARIMA yang dibentuk dan telah memenuhi uji signifikansi parameter. Pengujian dilakukan untuk melihat apakah parameter telah signifikan serta layak untuk dilakukan proses selanjutnya. Model memenuhi uji signifikansi apabila nilai *p-value* kurang dari  $\alpha = 0.05$  dan dalam uji statistik nilai  $|t_{hitung}| > t_{0.025,364}$  maka hipotesis  $H_0$  ditolak yang artinya model ARIMA sudah signifikan. Untuk langkah selanjutnya yaitu uji asumsi residual, model yang dipilih adalah model yang memiliki nilai MAPE terkecil yaitu ARIMA(1,1,0) dengan MAPE 35.7804. Uji asumsi residual dilakukan dengan Uji *Ljung-Box* dan Uji

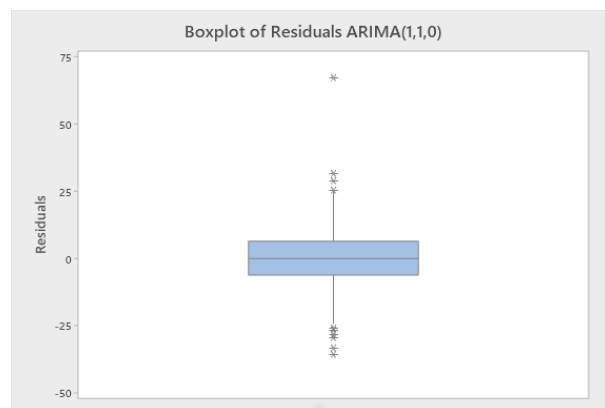
*Kolmogorov-Smirnov* dimana keputusan diambil apabila nilai *p-value* lebih dari  $\alpha = 0.05$  maka model sudah bersifat *white-noise* dan berdistribusi normal. Hasil uji asumsi residual ditunjukkan pada Tabel 4.11.

**Tabel 4.11 Uji Asumsi Residual ARIMA(1,1,0) PM<sub>2.5</sub> Stasiun DKI1**

lag	Chi-square	DF	p-value uji white-noise	p-value uji distribusi normal
12	28.52	11	0.0027	
24	42.89	23	0.0071	
36	53.67	35	0.0226	< 0.0100
48	68.12	47	0.0236	

Tabel 4.11 menunjukkan bahwa model ARIMA(1,1,0) tidak *white-noise* karena seluruh *lag* memiliki nilai *p-value* kurang dari  $\alpha$  atau dalam uji statistik nilai  $Q(k) > X_{0.05,47}^2$  maka tolak  $H_0$  yang berarti model ARIMA(1,1,0) tidak *white-noise*. Untuk uji distribusi normal terlihat bahwa nilai *p-value* kurang dari  $\alpha$  atau dalam uji statistik nilai  $D > D_{1-0.05, n > 40}$  maka tolak  $H_0$  yang berarti model ARIMA(1,1,0) belum berdistribusi normal. Hal tersebut kemungkinan disebabkan karena adanya *outlier* pada residual data kandungan PM<sub>10</sub>, sehingga dilakukan deteksi *outlier* untuk mengatasi masalah tersebut.

Deteksi *outlier* dilakukan dengan tujuan untuk mengetahui seberapa banyak residual pada data kandungan PM<sub>10</sub>. Deteksi *outlier* secara visual ditunjukkan pada Gambar 4.21 yang ditandai dengan bintang hitam.



**Gambar 4.21** Boxplot Residual ARIMA(1,1,0) Kandungan PM<sub>10</sub> DKI

Gambar 4.21 menunjukkan bahwa data *outlier* ditandai dengan bintang hitam, pada model ARIMA(1,1,0) terdapat *outlier* yang berjumlah lebih dari 50 *outlier*, tetapi untuk pendeteksian *outlier* pada model ARIMA(1,1,0) dilakukan menggunakan 20 *outlier* dengan taraf signifikansi sebesar 5%.

**Tabel 4.12** Deteksi *Outlier* ARIMA(1, 1, 0) Kandungan PM<sub>2.5</sub> DKI

Parameter	Estimasi Parameter	Tipe <i>Outlier</i>	<i>p-value</i>
$\phi_1$	-0.29131	-	< 0.0001
$\omega_{53}$	62.17487	<i>additive</i>	< 0.0001
$\omega_{183}$	-31.64286	<i>additive</i>	< 0.0001
:	:	:	:
$\omega_{174}$	22.51121	<i>shift</i>	0.0050
$\omega_{32}$	17.88014	<i>additive</i>	0.0074

Pada ARIMA(1,1,0) terdapat 12 *outlier* bertipe *additive* dan 8 *outlier* bertipe *level shift*. nilai *p-value* pada 20 *outlier* yang teridentifikasi kurang dari  $\alpha$  maka dapat

disimpulkan bahwa ada *outlier* yang mempengaruhi data. Masing-masing *outlier* ditambahkan kedalam model ARIMA(1,1,0) sehingga nilai asumsi residual dengan tambahan *outlier* ditunjukkan pada Tabel 4.13.

**Tabel 4.13 Uji Asumsi Residual ARIMA(1,1,0) dengan *outlier***

lag	Chi-square	DF	p-value uji white-noise	p-value uji distribusi normal
12	19.23	11	0.0572	
24	27.24	23	0.2458	
36	37.39	35	0.3598	> 0.1500
48	46.64	47	0.4873	

Setelah 20 *outlier* ditambahkan satu persatu ke model ARIMA(1,1,0) untuk memenuhi asumsi residual yang hasilnya dapat dilihat pada Tabel 4.13. Residual ARIMA(1,1,0) sudah memenuhi asumsi *white-noise* dan berdistribusi normal karena nilai *p-value* lebih dari  $\alpha$ .

#### 4.5. Nilai Akurasi dan Model ARIMA Kandungan PM<sub>2.5</sub>

Setelah melalui proses ARIMA hingga uji asumsi residual, selanjutnya yaitu menghitung nilai akurasi pada model terbaik yang telah didapatkan dan menyusun persamaan dari model ARIMA tersebut.

##### 4.5.1. Nilai Akurasi dan Model ARIMA PM<sub>2.5</sub> DKI1

Pada stasiun DKI1 didapat model terbaik yaitu ARIMA(1,1,0) karena telah memenuhi uji stasioneritas, uji *white-noise*, dan berdistribusi normal dengan



penambahan *outlier*. Nilai MAPE model ARIMA(1,1,0) tanpa *outlier* dan model dengan tambahan *outlier* dapat dilihat pada Tabel 4.14.

**Tabel 4.14 Nilai akurasi Kandungan PM<sub>2.5</sub> DKI**

ARIMA Model	MAPE
ARIMA(1,1,0) tanpa <i>outlier</i>	35.7804
ARIMA(1,1,0) dengan <i>outlier</i>	32.7545

Model ARIMA(1,1,0) dengan penambahan *outlier* menghasilkan nilai MAPE lebih kecil dibandingkan dengan model tanpa *outlier*. Apabila model digunakan untuk prediksi maka hasil prediksi yang didapatkan cukup baik. Selanjutnya, persamaan model ARIMA(1,1,0) sebagai berikut.

$$A_t = \frac{e_t}{(1 + 0.291B)(1 - B)} + 62.174I_t^{53} - \dots$$

$$(1 + 0.291B)(1 - B)A_t = e_t + 62.174I_t^{53} - \dots$$


$$(1 - B + 0.291B - 0.291B^2)A_t = e_t + 62.174I_t^{53} - \dots$$

$$A_t - A_{t-1} + 0.291A_{t-1} - 0.291A_{t-2} = e_t + 62.174I_t^{53} - \dots$$

$$A_t - (1 + 0.291)A_{t-1} - 0.291A_{t-2} = e_t + 62.174I_t^{53} - \dots$$

$$\begin{aligned} A_t = & 1.291A_{t-1} + 0.291A_{t-2} + e_t + 62.174I_t^{53} - 31.642I_t^{183} + 37.275I_t^{23} + 25.955I_t^{25} \\ & - 24.096I_t^{235} - 22.438I_t^{230} + 21.597I_t^{113} + 19.005I_t^{77} - 19.844I_t^{225} + 17.880I_t^{32} \\ & + \frac{29.414}{(1 - B)}S_t^{287} - 22.798I_t^{164} - \frac{26.809}{(1 - B)}S_t^{172} - \frac{26.036}{(1 - B)}S_t^{291} - \frac{26.619}{(1 - B)}S_t^{145} \\ & + \frac{25.922}{(1 - B)}S_t^{75} + 19.814I_t^{66} + \frac{23.801}{(1 - B)}S_t^{94} - \frac{23.468}{(1 - B)}S_t^{212} + \frac{22.511}{(1 - B)}S_t^{174} \end{aligned}$$

Berikut grafik perbandingan data *outsample* dengan prediksi kandungan  $PM_{2.5}$  stasiun DKI1.



**Gambar 4.22** Plot Data *Outsample* dan Hasil Prediksi Kandungan  $PM_{2.5}$  Stasiun DKI1

Pada gambar 4.22 terlihat bahwa pergerakan kandungan  $PM_{2.5}$  mengikuti data aktualnya yang mengalami kenaikan dan penurunan secara teratur. Kandungan terendah pada 1 Desember 2021 yang bernilai 4.5163.

#### 4.5.2. Nilai Akurasi dan Model ARIMA $PM_{2.5}$ DKI2

Proses ARIMA pada kandungan  $PM_{2.5}$  stasiun DKI2 dapat dilihat pada Lampiran 7 dimana seluruh model ARIMA yang dibentuk belum memenuhi syarat *white-noise* dan belum berdistribusi normal. Untuk itu, dicari model yang belum memenuhi uji asumsi residual berdasarkan nilai MAPE terkecil. Model dengan nilai MAPE terkecil adalah model ARIMA(1,1,1) yang selanjutnya dilakukan deteksi *outlier* pada model tersebut agar uji asumsi residual terpenuhi. Nilai MAPE ARIMA(1,1,1) tanpa *outlier* dan model ARIMA(1,1,1) dengan *outlier* ditunjukkan pada Tabel 4.15.

Tabel 4.15 Nilai akurasi Kandungan PM<sub>2.5</sub> DKI2

ARIMA Model	MAPE
ARIMA(1,1,1) tanpa <i>outlier</i>	31.3825
ARIMA(1,1,1) dengan <i>outlier</i>	30.3558

Model ARIMA(1,1,1) dengan tambahan *outlier* menghasilkan MAPE yang lebih kecil sebesar 30.3558. Jika model ARIMA(1,1,1) digunakan untuk memprediksi maka hasil prediksi masuk dalam kategori cukup baik. Persamaan model ARIMA(1,1,1) yaitu:

$$A_t = \frac{(1 - 1.00B)}{(1 - 0.472B)(1 - B)} + 65.074I_t^{190} - \dots$$


$$(1 - 0.472B)(1 - B)A_t = (1 - 1.00B)e_t + 65.074I_t^{190} - \dots$$

$$A_t - A_{t-1} - 0.472A_{t-1} + 0.472A_{t-2} = e_t - e_{t-1} + 65.074I_t^{190} - \dots$$

$$A_t - (1 + 0.472)A_{t-1} + 0.472A_{t-2} = e_t - e_{t-1} + 65.074I_t^{190} - \dots$$

$$\begin{aligned} A_t = & 1.472A_{t-1} - 0.472A_{t-2} + e_t - e_{t-1} + 65.074I_t^{190} - 29.771I_t^{163} + 43.267I_t^{23} \\ & + 39.429I_t^{77} - 33.775I_t^{192} + 48.650I_t^{162} + 36.303I_t^{161} + 26.369I_t^{213} - 24.433I_t^{144} \\ & + 22.736I_t^{25} + 21.795I_t^{76} - 20.038I_t^{199} + 19.062I_t^{32} - 18.597I_t^{137} - \frac{20.637}{(1 - B)}S_t^{210} \\ & + \frac{20.012}{(1 - B)}S_t^{101} - \frac{18.286}{(1 - B)}S_t^{288} + \frac{20.254}{(1 - B)}S_t^{182} + \frac{13.724}{(1 - B)}S_t^{58} - \frac{8.027}{(1 - B)}S_t^{117} \end{aligned}$$

Berikut grafik perbandingan data *outsample* dengan prediksi kandungan PM<sub>2.5</sub> stasiun DKI2.



**Gambar 4.23** Plot Data *Outsample* dan Hasil Prediksi Kandungan  $PM_{2.5}$  Stasiun DKI2

Pada gambar 4.23 menunjukkan bahwa pergerakan kandungan  $PM_{2.5}$  hampir mengikuti data aktualnya yang mengalami kenaikan dan penurunan secara teratur dengan kandungan tertinggi sebesar 48.4417 dan kandungan terendah sebesar 18.8322 pada 26 Oktober dan 28 November 2021.

#### 4.5.3. Nilai Akurasi dan Model ARIMA $PM_{2.5}$ DKI3

Model terbaik stasiun DKI3 adalah ARIMA(3,1,1) yang telah memenuhi syarat kestasioneritasan dan memenuhi uji asumsi residual dengan penambahan *outlier*. Proses ARIMA pada stasiun DKI3 dapat dilihat pada Lampiran 8. Nilai MAPE model ARIMA(3,1,1) tanpa *outlier* dan model dengan *outlier* pada Tabel berikut.

**Tabel 4.16** Nilai akurasi Kandungan  $PM_{2.5}$  DKI3

ARIMA Model	MAPE
ARIMA(3,1,0) tanpa <i>outlier</i>	33.3105
ARIMA(3,1,0) dengan <i>outlier</i>	31.7628

Model ARIMA(3,1,1) dengan tambahan *outlier* memiliki nilai MAPE lebih kecil

dari model ARIMA tanpa *outlier*. Jika model digunakan untuk prediksi maka hasil prediksi yang didapatkan cukup baik. Persamaan ARIMA(3,1,1) dengan penambahan *outlier* stasiun DKI3 sebagai berikut.

$$A_t = \frac{(1 - 0.6004B)}{(1 + 0.342B^3)(1 - B)} + 59.768I_t^{21} + \dots$$


$$(1 + 0.342B^3)(1 - B)A_t = e_t - (1 - 0.6004B) + 59.768I_t^{21} + \dots$$

$$(1 - B + 0.342B^3 - 0.342B^4) = e_t(1 - 0.6004B)59.768I_t^{21} + \dots$$

$$A_t - A_{t-1} + 0.342A_{t-3} - 0.342A_{t-4} = e_t - 0.3996e_{t-1} + 59.768I_t^{21} + \dots$$

$$\begin{aligned} A_t = & A_{t-1} - 0.342A_{t-3} + 0.342A_{t-4} + e_t - 0.3996e_{t-1} + 59.768I_t^{21} + 34.033I_t^{195} \\ & + 36.379I_t^5 + 33.039I_t^{208} + 35.115I_t^{123} + 34.610I_t^{78} + 31.630I_t^{22} - 27.395I_t^{163} \\ & - 27.563I_t^{171} - 30.339I_t^{92} - 27.260I_t^{181} + 26.792I_t^{31} + 30.898I_t^{52} + 24.014I_t^{53} + \\ & - 26.437I_t^{69} - \frac{35.165}{(1 - B)}S_t^{190} + \frac{30.141}{(1 - B)}S_t^{193} - \frac{21.083}{(1 - B)}S_t^{211} - \frac{21.161}{(1 - B)}S_t^{200} - \frac{22.338}{(1 - B)}S_t^{290} \end{aligned}$$

Berikut grafik perbandingan data *outsample* dengan prediksi kandungan PM<sub>2.5</sub> stasiun DKI3.



Gambar 4.24 Plot Data *Outsample* dan Hasil Prediksi Kandungan PM<sub>2.5</sub> Stasiun DKI3

Pada gambar 4.24 pergerakan kandungan  $PM_{2.5}$  mengikuti dan sama dengan data aktualnya. Kandungan tertinggi berada pada nilai 75.943 dan kandungan terendah berada pada nilai 4.6488.

#### 4.5.4. Nilai Akurasi dan Model ARIMA $PM_{2.5}$ DKI4

Pada kandungan  $PM_{2.5}$  stasiun DKI4 model yang memenuhi uji stasioner, uji *white-noise*, dan berdistribusi normal adalah model ARIMA(1,1,1) yang langkah-langkahnya dapat dilihat pada Lampiran 9. Deteksi *outlier* tidak dilakukan karena data sudah memenuhi asumsi *white-noise* dan berdistribusi normal dengan nilai MAPE pada Tabel berikut.

**Tabel 4.17 Nilai akurasi Kandungan  $PM_{2.5}$  DKI4**

ARIMA Model	MAPE
ARIMA(1,1,1) tanpa <i>outlier</i>	36.1972

MAPE pada model ARIMA(1,1,1) sebesar 36.1972, apabila digunakan untuk prediksi maka hasil yang didapatkan cukup baik. Model ARIMA(1,1,1) dibentuk persamaan sebagai berikut.

$$\phi_p(B)(1 - B)^d A_t = \theta_q(B)e_t$$

$$(1 - \phi_1 B)(1 - B)^1 A_t = (1 - \theta_1 B)e_t$$

$$(1 - B - \phi_1 B + \phi_1 B^2)A_t = e_t - \theta_1 e_{t-1}$$


$$A_t - A_{t-1} - \phi_1 A_{t-1} + \phi_1 A_{t-2} = e_t - \theta_1 e_{t-1}$$

$$A_t = (1 - \phi_1)A_{t-1} - \phi_1 A_{t-2} - \theta_1 e_{t-1} + e_t$$

$$A_t = (1 - 0.40848)A_{t-1} - 0.40848A_{t-2} - 0.90999e_{t-1} + e_t$$

$$A_t = 0.59152A_{t-1} - 0.40848A_{t-2} - 0.90999e_{t-1} + e_t$$

Berikut grafik perbandingan data *outsample* dengan prediksi kandungan  $PM_{2.5}$  stasiun DKI4.



**Gambar 4.25** Plot Data *Outsample* dan Hasil Prediksi Kandungan  $PM_{2.5}$  Stasiun DKI4

Pada gambar 4.25 terlihat bahwa pergerakan kandungan  $PM_{2.5}$  mengalami kenaikan dan penurunan dengan kandungan tertinggi pada 26 Oktober 2021 sebesar 69.6695 dan kandungan terendah pada 28 November 2021 sebesar 22.1434.

#### 4.5.5. Nilai Akurasi dan Model ARIMA $PM_{2.5}$ DKI5

Langkah-langkah ARIMA kandungan  $PM_{2.5}$  stasiun DKI5 dapat dilihat pada Lampiran 10 dan didapat model ARIMA yang memenuhi uji stasioneritas dan uji asumsi residual adalah model ARIMA(1,1,1). Deteksi *outlier* tidak perlu dilakukan karena syarat ARIMA sudah terpenuhi. Nilai MAPE model ARIMA(1,1,1) ditunjukkan pada Tabel 4.18

**Tabel 4.18** Nilai akurasi Kandungan  $PM_{2.5}$  DKI5

ARIMA Model	MAPE
ARIMA(1,1,1) tanpa <i>outlier</i>	36.0728

Nilai MAPE model ARIMA(1,1,1) yaitu 36.0728. Prediksi yang dilakukan

mendapatkan hasil yang cukup baik karena nilai MAPE berkisar 20 - 50%. Persamaan ARIMA(1,1,1) adalah sebagai berikut.

$$\phi_p(B)(1 - B)^d A_t = \theta_q(B)e_t$$

$$(1 - \phi_1 B)(1 - B)^1 A_t = (1 - \theta_1 B)e_t$$

$$(1 - B - \phi_1 B + \phi_1 B^2)A_t = e_t - \theta_1 e_{t-1}$$


$$A_t - A_{t-1} - \phi_1 A_{t-1} + \phi_1 A_{t-2} = e_t - \theta_1 e_{t-1}$$

$$A_t = (1 - \phi_1)A_{t-1} - \phi_1 A_{t-2} - \theta_1 e_{t-1} + e_t$$

$$A_t = (1 - 0.44801)A_{t-1} - 0.44801A_{t-2} - 0.94821e_{t-1} + e_t$$

$$A_t = 0.55199A_{t-1} - 0.44801A_{t-2} - 0.94821e_{t-1} + e_t$$

Berikut grafik perbandingan data *outsample* dengan prediksi kandungan PM<sub>2.5</sub> stasiun DKI5.



**Gambar 4.26** Plot Data *Outsample* dan Hasil Prediksi Kandungan PM<sub>2.5</sub> Stasiun DKI5

Pada gambar 4.26 kandungan PM<sub>2.5</sub> mengalami kenaikan dan penurunan secara teratur yang tidak jauh dari data aktualnya. Kandungan tertinggi dan terendah pada 26 Oktober dan 30 November 2021.

Kandungan pencemaran udara di setiap daerah dapat berbeda-beda, hal tersebut terjadi karena beberapa faktor yang mempengaruhi produksi maupun penyebaran



polutan di udara. Setiap daerah memiliki tingkat kepadatan populasi dan jenis kegiatan manusia yang berbeda, yang dapat menyebabkan variasi dalam kandungan pencemaran udara. Selain itu, kondisi cuaca seperti suhu, kelembaban, dan angin dapat mempengaruhi sejauh mana polutan tersebar dan bertahan di suatu daerah. Untuk itu, pemodelan yang telah dilakukan dapat digunakan untuk memprediksi kandungan *Particulate Matter* 10 dan 2.5 yang diharapkan agar manusia dapat melakukan pencegahan serta mereduksi kandungan *Particulate Matter* 10 dan 2.5 dalam udara provinsi DKI Jakarta.

Salah satu langkah yang dapat diambil untuk mengurangi polusi udara yang dihasilkan oleh kendaraan bermotor adalah dengan menjaga kelestarian lingkungan agar tidak berdampak pada kesehatan manusia, maupun makhluk hidup lainnya. Sebagaimana firman Allah Swt yang memerintahkan manusia untuk menjaga dan memelihara lingkungan yang berbunyi:

وَلَا تُفْسِدُوا فِي الْأَرْضِ بَعْدَ إِصْلَاحِهَا وَدَعُوهُ خَوْفًا وَطَمَعًا قُلْ إِنَّ  
رَحْمَتَ اللَّهِ قَرِيبٌ مِّنَ الْمُحْسِنِينَ

Artinya: *"Dan janganlah kamu berbuat kerusakan di bumi setelah (diciptakan) dengan baik. Berdoalah kepada-Nya dengan rasa takut dan penuh harap. Sesungguhnya rahmat Allah sangat dekat kepada orang yang berbuat kebaikan"*(QS. Al-A'raf : 56)

Pada ayat di atas dijelaskan bahwasannya Allah Swt menciptakan bumi ini dengan lengkap, seperti gunung, lautan, daratan, udara, dan yang lainnya untuk

keperluan manusia agar dapat dimanfaatkan dengan baik, seperti menjaga udara agar tetap bersih dengan cara menanam pohon di sepanjang jalan supaya udara yang kotor dapat diserap dan diganti dengan udara yang bersih. Menanam pohon untuk mencegah terjadinya pencemaran udara juga termasuk dalam perbuatan baik, karena telah berupaya untuk menghidupkan tanah yang tandus. Selain itu, pohon juga dapat menghasilkan oksigen yang sangat bermanfaat untuk makhluk hidup. Sebagaimana firman Allah Swt dan hadis Nabi Saw yang berbunyi:

الَّذِي جَعَلَ لَكُمْ مِنَ الشَّجَرِ الْأَخْضَرِ نَارًا لَا فَاذًا أَنْتُمْ مِنْهُ تُوقِدُونَ

Artinya: "yaitu (Allah) yang menjadikan api untukmu dari kayu yang hijau, maka seketika itu kamu nyalakan (api) dari kayu itu"(Qs. Yasin : 80)

أَخْبَرَنَا عَبْدُ اللَّهِ بْنُ سَعِيدٍ حَدَّثَنَا أَبُو أُسَامَةَ عَنْ هِشَامِ بْنِ عُرْوَةَ قَالَ أَخْبَرَنِي عَبْدُ اللَّهِ بْنُ عَبْدِ الرَّحْمَنِ بْنِ رَافِعٍ أَنَّ جَابِرَ بْنَ عَبْدِ اللَّهِ أَخْبَرَهُ عَنْ رَسُولِ اللَّهِ صَلَّى اللَّهُ عَلَيْهِ وَسَلَّمَ قَالَ مَنْ أَحْيَا أَرْضًا مَيِّتَةً فَلَهُ فِيهَا أَجْرٌ وَمَا أَكَلَتْ الْعَافِيَةُ مِنْهَا فَلَهُ فِيهَا صَدَقَةٌ قَالَ أَبُو مُحَمَّدٍ الْعَافِيَةُ الطَّيْرُ وَغَيْرُ ذَلِكَ (رواه الدارمي)

Artinya: Telah mengabarkan kepada kami Abdullah bin Sa'id telah menceritakan kepada kami Abu Usamah dari Hisyam bin 'Urwah, ia berkata: telah mengabarkan kepadaku 'Ubaidullah bin Abdurrahman bin Rafi', bahwa Jabir bin Abdullah telah mengabarkan kepadanya dari Rasulullah shallallahu 'alaihi wasallam,

beliau bersabda ”Barangsiapa menghidupkan lahan yang mati, maka ia mendapatkan pahala apa yang dimakan oleh segala (makhluk) yang mencari rizqi, dan baginya sedekah dari lahan tersebut.” Abu Muhammad berkata: ”Al ’Afiyah adalah burung dan yang lainnya”(HR. Darimi : 2493)

Ayat Al-Quran dan hadis di atas menjelaskan bahwa Nabi Muhammad Saw menganjurkan umatnya untuk menanam lahan yang tandus supaya bermanfaat dan menguntungkan bagi sebagian makhluk hidup. Pohon yang tertanam dapat menghasilkan buah yang dapat dimakan oleh makhluk hidup yang membutuhkannya, hal itu terhitung sebagai sedekah untuk orang yang menanam pohon. Selain itu pohon yang hijau dapat menghasilkan oksigen yang bersih untuk dihirup oleh manusia dan hewan serta membantu jalan hidup bagi tumbuhan yang lainnya. Sebagaimana kaidah fikih menyebutkan:

دَرْءُ الْمَفَاسِدِ مُقَدَّمٌ عَلَى جَلْبِ الْمَصَالِحِ

Artinya: ”Menolak kerusakan itu didahulukan daripada menarik kebaikan.”

Kaidah fikih tersebut mengingatkan kita sebagai manusia agar menjauhi sesuatu yang berdampak negatif baik pada diri sendiri atau pada lingkungan sekitar, misalnya kita harus menjaga lingkungan dengan cara tidak membakar sampah plastik serta tidak menebang pohon sembarangan untuk mencegah tingginya pencemaran udara.

## BAB V

### PENUTUP

#### 5.1. Kesimpulan

Berdasarkan analisis data mengenai pemodelan kandungan *Particulate Matter* (PM) dalam pencemaran udara provinsi DKI Jakarta, maka didapatkan kesimpulan sebagai berikut:

1. Model terbaik yang digunakan untuk memodelkan kandungan  $PM_{10}$  pada stasiun DKI1 adalah ARIMA (1, 1, 1), pada stasiun DKI2 yaitu model ARIMA (1, 1, 1), kemudian stasiun DKI3 model terbaiknya adalah ARIMA (1, 1, 1), selanjutnya stasiun DKI4 yakni model ARIMA (3, 1, 1), dan pada stasiun DKI5 didapat model terbaik yakni model ARIMA (1, 1, 1). Pada kelima stasiun pengamatan tidak dilakukan deteksi *outlier* karena model ARIMA sudah memenuhi uji stasioneritas dan uji asumsi residual.
2. Model terbaik yang digunakan untuk memodelkan kandungan  $PM_{2.5}$  pada stasiun DKI1 adalah ARIMA (1, 1, 0), pada stasiun DKI2 yaitu model ARIMA (1, 1, 1), kemudian stasiun DKI3 model terbaiknya adalah ARIMA (3, 1, 1), selanjutnya stasiun DKI4 yakni model ARIMA (1, 1, 1), dan pada stasiun DKI5 didapat model terbaik yakni model ARIMA (1, 1, 1). Pada stasiun DKI1 dan DKI3 model dibentuk dengan penambahan *outlier* sedangkan stasiun DKI2, DKI4, dan DKI5 tanpa *outlier*.

3. Nilai akurasi pada prediksi kandungan *Particulate Matter* (PM) 10 dan 2.5 menggunakan nilai *Mean Absolute Percentage Error* (MAPE). Pada seluruh stasiun pengamatan diperoleh nilai MAPE yang bernilai 20% – 50% sehingga hasil prediksi yang didapatkan cukup baik.

## 5.2. Saran

Pada penelitian ini, terdapat beberapa model dalam metode ARIMA yang tidak memenuhi asumsi yang telah ditetapkan, terutama dalam hal asumsi *white-noise*. Asumsi tersebut tidak terpenuhi karena adanya *outlier* dalam data. Meskipun *outlier* telah diidentifikasi, namun penggunaan *outlier* tersebut belum mampu mengatasi ketidakpuasan terhadap asumsi residual. Oleh karena itu, dalam penelitian selanjutnya, disarankan untuk mempertimbangkan penggunaan jumlah *outlier* yang lebih besar dalam penanganan *outlier*. Dengan demikian, diharapkan asumsi yang dilanggar dapat diatasi dengan lebih efektif.

UIN SUNAN AMPEL  
S U R A B A Y A

## DAFTAR PUSTAKA

- Abidin, J. and Hasibuan, F. A. (2019). Pengaruh Dampak Pencemaran Udara terhadap Kesehatan untuk Menambah Pemahaman Masyarakat Awam tentang Bahaya dari Polusi Udara. *Pros. SNFUR-4*, (September):1–7.
- Arba, S. (2019). Konsentrasi Respirable Debu Particulate Matter (Pm<sub>2,5</sub>) dan Gangguan Kesehatan pada Masyarakat di Pemukiman Sekitar PLTU. *Promot. J. Kesehat. Masy.*, 9:178–184.
- Arba, S. and Mustafa, M. (2022). Efektifitas Alat Filtrasi Sederhana Berbahan Pelepap Pisang dalam Menurunkan PM<sub>2.5</sub> dan PM<sub>10</sub> pada Rumah Pengasapan Ikan di Kota Ternate. *J. Kesehat.*, 15(1):67–71.
- Ayundari, I. and Sutikno (2019). Penentuan Zona Musim di Mojokerto Menurut Karakteristik Curah Hujan Dengan Metode Time Series Based Clustering. *INFERENSI*, 2(2):63–70.
- Ciabattini, M., Rizzello, E., Lucaroni, F., Palombi, L., and Boffetta, P. (2021). Systematic Review and Meta-Analysis of Recent High-Quality Studies on Exposure to Particulate Matter and Risk of Lung Cancer. *Environ. Res.*, 196:1–15.
- Desvina, A. P. (2015). Peramalan Pencemaran Udara Oleh Particulate Matter ( Pm<sub>10</sub> ) Di Pekanbaru Dengan Metode Box-Jenkins. pages 63–73.
- DLHJakarta (2020). Pemantauan Kualitas Udara DKI Jakarta.

- DLHJakarta (2022). Laporan Pemantauan Kualitas Udara. <https://lingkunganhidup.jakarta.go.id/publikasi/laporanudara>.
- Farida, Y., Farmita, M., Ulinuha, N., and Yuliati, D. (2022). Forecasting Population of Madiun Regency Using ARIMA Method. *CAUCHY J. Mat. Murni dan Apl.*, 7(3):420–431.
- Fauzannissa, R. A., Yasin, H., and Ispriyanti, D. (2015). Peramalan Harga Minyak Mentah Dunia Menggunakan Metode Radial Basis Function Neural Network. *J. GAUSSIAN*, 5:193–202.
- Hartati (2017). Penggunaan Metode ARIMA Dalam Meramal Pergerakan Inflasi. *J. Mat. Saint, dan Teknol.*, 18:1–10.
- Haryanti, N., Tohawi, A., and Purnomo, M. W. (2022). Strategi Penanggulangan Pemanasan Global Terhadap Dampak Laju Perekonomian Dalam Pandangan Islam. *J. Din. Ekon. Syariah*, 9(2):168–183.
- Hutasuhut, A. H., Anggraeni, W., and Tyasnurita, R. (2014). Pembuatan Aplikasi Pendukung Keputusan Untuk Peramalan Persediaan Bahan Baku Produksi Plastik Blowing dan Inject Menggunakan Metode ARIMA (Autoregressive Integrated Moving Average) di CV. Asia. *J. Tek. POMITS*, 3(2):A–169.
- IQAir (2023). Kualitas Udara di Jakarta.
- Irawan, F. and Puteri, H. E. (2020). Interaksi Aspek Permodalan, Risiko Pembiayaan, Dan Indikator Makroekonomi Dalam Mempengaruhi Profitabilitas Bprs Di Indonesia Periode 2014-2018. *J. Benefita*, 5(3):401.

- JakartaOpenData (2022). Data Terbuka Pemerintah Provinsi DKI Jakarta.
- Jusoh, K. C. and Hamid, N. Z. A. (2020). Meramal Bacaan Maksimum Harian Nitrogen Dioksida Menerusi Pendekatan Kalut. *J. Qual. Meas. Anal.*, 16(1):79–89.
- Kondo Lembang, F. (2017). Prediksi Laju Inflasi di Kota Ambon Menggunakan Metode ARIMA Box Jenkins. *Stat. J. Theor. Stat. Its Appl.*, 16(2):95–102.
- Krisma, A., Azhari, M., Widagdo, P. P., Landia, B., Setialaksana, W., Sulaiman, D. R. A., Dewi, S. S., Lamasitudju, C. A., Ashadi, N. R., and Asriadi, M. (2020). Peramalan Jumlah Mahasiswa Baru Dengan Exponential Smoothing dan Moving Average. *J. Ilm. Intech Inf. Technol. J. UMUS*, 3(2):53.
- Kurniawan, A. (2018). Pengukuran Parameter Kualitas Udara (Co, No<sub>2</sub>, So<sub>2</sub>, O<sub>3</sub> Dan Pm<sub>10</sub>) Di Bukit Kototabang Berbasis Ispu. *J. Teknosains*, 7(1):1.
- Li, H., Xu, X.-L., Dai, D.-W., Huang, Z.-Y., Ma, Z., and Guan, Y.-J. (2020). Air Pollution and Temperature Are Associated with Increased COVID-19 Incidence: A Time Series Study. *Int. J. Infect. Dis.*, 97:278–282.
- Lorensya, Ambarwati, L., and Mahatma, Y. (2022). Analisis Model Intervensi Multi Input Fungsi Pulse Dan Fungsi Step Dengan Deteksi Outlier Terhadap Harga Saham. *J. EurekaMatika*, 10(1):71–86.
- Mokorimban, F. E., Nainggolan, N., and Langi, Y. A. R. (2021). Penerapan Metode Autoregressive Integrated Moving Average ( ARIMA ) dalam Model Intervensi Fungsi Step terhadap Indeks Harga Konsumen di Kota Manado. *d'Cartesian J. Mat. dan Apl.*, 10(2):91–99.



- Mulyadi, M. (2013). Penelitian Kuantitatif Dan Kualitatif Serta Pemikiran Dasar Menggabungkannya. *J. Stud. Komun. dan Media*, 15(1):128.
- Murdianto, W. and Pranoto, Y. (2018). Karakteristik Fisik Pati Ganyong (Canna eduliskerr) Hasil Modifikasi Menggunakan Ozon. *Semin. Nas. "Inovasi Pangan Lokal Untuk Mendukung Ketahanan Pangan"*, (April):228–231.
- Mursinto, D. and Kusumawardani, D. (2016). Estimasi Dampak Ekonomi Dari Pencemaran Udara Terhadap Kesehatan Di Indonesia. *J. Kesehat. Masy.*, 11(2):163172.
- Muslimah, D. D. L. (2019). Keadaan Lingkungan Fisik dan Dampaknya pada Keberadaan Mycobacterium Tuberculosis: Studi di Wilayah Kerja Puskesmas Perak Timur Surabaya. *J. Kesehat. Lingkung.*, 11(1):26.
- Nurwita, M., Maesaroh, and Widowati, N. (2021). Upaya Dinas Lingkungan Hidup dalam Pengendalian Pencemaran Udara di Kota Tangerang.
- Perdana, A. R., Pangastuti, A. I., and Haryanto, Y. D. (2023). Analisis Konsentrasi PM10 dan PM2.5 Pada Titik Pemantauan Bundaran HI Jakarta Pusat Periode Data Februari-Oktober 2021. *J. Kaji. Ilmu dan Pendidik. Geogr.*, 06(1):1–8.
- Purba, L. S. L. and Harefa, N. (2020). Pengaruh Kandungan Oksigen Udara Sekolah Terhadap Konsentrasi Belajar Siswa. *J. EduMatSains*, 4(2):169–182.
- Puspita, R. N. (2022). Perbandingan Metode Double Exponential Smoothing Dan Triple Exponential Smoothing Pada Peramalan Nilai Ekspor Di Indonesia. *Jambura J. Probab. Stat.*, 3(2):141–150.

- Rahmadania, N. (2022). Pemanasan Global Penyebab Efek Rumah Kaca dan Penanggulangannya. *Ilmuteknik.org*, 2(3):1–12.
- Ratnani, R. D. (2008). Teknik Pengendalian Pencemaran Udara Yang Diakibatkan oleh Partikel. *Momentum*, 4(2):27–32.
- Ridayanti, D. D. P., Khambali, and Suryono, H. (2022). Risiko Paparan Debu/Particulate Matter (PM2.5) Terhadap Kesehatan Masyarakat (Studi Kasus: Tempat Pembuatan Batu Bara di Desa Kaloran, Kecamatan Ngronggot, Nganjuk). *J. Penelit. Kesehat. Suara Forikes*, 13(April):437–443.
- Risky Arifanti, D. and Asrirawan (2021). Peramalan Volume Debit Air Kota Palopo Menggunakan Model ARIMA Deteksi Pencilan. *Infin. J. Mat. dan Apl.*, 1(2):31–39.
- Rixson, L., Riani, E., and Santoso, M. (2016). Karakterisasi Paparan Long Term Particulate Matter di Puspipstek Serpong-Kota Tangerang Selatan. *J. Ilm. Apl. Isot. dan Radiasi*, 11(1):51.
- Rosha, P. T., Fitriyana, M. N., Ulfa, S. F., and Dharminto (2013). Pemanfaatan Sansevieria Tanaman Hias Penyerap Polutan Sebagai Upaya Mengurangi Pencemaran Udara di Kota Semarang. *J. Ilm. Mhs.*, 3(1):1–6.
- Ruhiat, F., Heryadi, D., and Akim (2019). Strategi NGO Lingkungan Dalam Menangani Polusi Udara di Jakarta (Greenpeace Indonesia). *Andalas J. Int. Stud.*, 8(1):16.
- Sari, I. R. J., Fatkhurrahman, J. A., and Andriani, Y. (2019). Pola Sebaran Polutan PM 2.5 dan PM 10 Harian Terhadap Faktor Suhu dan Kelembaban. *Pros. SNST ke-10*, 82:95–100.

- Schraufnagel, D. E., Balmes, J. R., Cowl, C. T., De Matteis, S., Jung, S. H., Mortimer, K., Perez-Padilla, R., Rice, M. B., Riojas-Rodriguez, H., Sood, A., Thurston, G. D., To, T., Vanker, A., and Wuebbles, D. J. (2019). Air Pollution and Noncommunicable Diseases: A Review by the Forum of International Respiratory Societies' Environmental Committee, Part 2: Air Pollution and Organ Systems. *Chest*, 155(2):417–426.
- Suhartono and Putri, I. K. (2019). Deteksi Outlier pada Model ARIMA Musiman Ganda untuk Peramalan Beban Listrik Jangka Pendek di Jawa Timur. *J. Sains Dan Seni ITS*, 4(1):31–36.
- Suparti and Sa'adah, A. F. (2015). Analisis Data Inflasi Indonesia Menggunakan Model Autoregressive Integrated Moving Average (ARIMA) Dengan Penambahan Outlier. *Media Stat.*, 8(1):1–11.
- Suryanto, J. (2016). Perbandingan Kinerja Model ARIMA dan Thomas-Fiering dalam Memprediksi Debit Sungai Loning, Magelang. *J. AGRIFOR*, XV:65–74.
- Syaifulloh, M. M. (2021). Prediksi Indeks Standar Pencemaran Udara di Kota Surabaya Berdasarkan Konsentrasi Gas Karbon Monoksida. *Jambura J. Probab. Stat.*, 2(2):89–95.
- Trydini, T. R., Helmi, and Huda, N. M. (2023). Prediksi Harga Saham Menggunakan Model Autoregressive Integrated Moving Average dengan Innovational Outlier. *Bul. Ilm. Math, Stat, dan Ter.*, 12(1):1–10.
- Umri, S. S. A., Firdaus, M. S., and Primajaya, A. (2021). ANALISIS DAN

KOMPARASI ALGORITMA KLASIFIKASI DALAM INDEKS PENCEMARAN UDARA DI DKI JAKARTA. *JIKO (Jurnal Inform. dan Komputer)*, 4(2):98–104.

Wei, W. S. (2006). *Time Series Analysis Univariate and Multivariate Methods*. United State of America: Pearson Education Inc, second edition.

WHO (2012). *Burden of Disease From Household Air Pollution For 2012*. Public Health Organization Determinants of Health Department, Geneva, Switzerland.

Wijiarti, K., D, Y. H., and D, N. A. Y. (2016). Analisis Risiko Kesehatan Lingkungan Paparan Sulfur Dioksida (SO<sub>2</sub>) Udara Ambien Pada Pedagang Kaki Lima Di Terminal Bus Pulogadung, Jakarta Timur. *J. Kesehat. Masy.*, 4.

Wirdyacahya, B. S. and Prastuti, M. (2022). Peramalan Permintaan Semen di PT. XYZ Menggunakan Time Series Regression dan ARIMA. *J. Sains Dan Seni ITS*, 11(1):96–101.

Zulfa, E. I., Ferryan, D. A., and Novitasari, D. C. R. (2022a). Analisis Pendekatan Statistik Dan Fuzzy Mamdani Dalam Prediksi Produktivitas Padi. *Maj. Ilm. Mat. dan Stat.*, 22(1):105.

Zulfa, E. I., Sunariadi, N. M., and Khaulasari, H. (2022b). Perbandingan Metode Untuk Memprediksi Luas Panen Padi di Indonesia. *J. Mat. Algebr.*, 03(02):130–142.