

**ALGORITMA SUPPORT VECTOR REGRESSION (SVR) DENGAN PARTICLE
SWARM OPTIMIZATION (PSO) UNTUK MEMPREDIKSI INDEKS POLUSI
UDARA DI KOTA YOGYAKARTA**

TUGAS AKHIR

Tugas Akhir ini sebagai salah satu syarat untuk memperoleh gelar sarjana Teknik Informatika Universitas Pembangunan Nasional “Veteran” Yogyakarta



Disusun oleh:

Adfanizar Muhammad

123160151

**PROGRAM STUDI INFORMATIKA
JURUSAN TEKNIK INFORMATIKA
FAKULTAS TEKNIK INDUSTRI
UNIVERSITAS PEMBANGUNAN NASIONAL “VETERAN”
YOGYAKARTA
2021**

SURAT PERNYATAAN KARYA ASLI TUGAS AKHIR

Sebagai mahasiswa Program Studi Informatika Fakultas Teknik Industri Universitas Pembangunan Nasional “Veteran” Yogyakarta, yang bertanda tangan di bawah ini, saya:

Nama : Adfanizar Muhammad

NIM : 123160151

Menyatakan bahwa karya ilmiah saya yang berjudul:

ALGORITMA SUPPORT VECTOR REGRESSION (SVR) DENGAN PARTICLE SWARM OPTIMIZATION (PSO) UNTUK MEMPREDIKSI INDEKS POLUSI UDARA DI KOTA YOGYAKARTA

Merupakan karya asli saya dan belum pernah dipublikasikan dimanapun. Apabila ada di kemudian hari, karya saya disinyalir bukan merupakan karya asli saya, maka saya bersedia menerima konsekuensi apa pun yang diberikan Program Studi Informatika Fakultas Teknik Industri Universitas Pembangunan Nasional “Veteran” Yogyakarta kepada saya.

Demikian surat pernyataan ini saya buat dengan sebenarnya.

Dibuat di : Yogyakarta

Pada tanggal :

Yang menyatakan,

(Adfanizar Muhammad)

PERNYATAAN BEBAS PLAGIAT

Saya yang bertanda tangan di bawah ini:

Nama : Adfanizar Muhammad

NIM : 123160151

Dengan ini saya menyatakan bahwa judul Tugas Akhir:

ALGORITMA SUPPORT VECTOR REGRESSION (SVR) DENGAN PARTICLE SWARM OPTIMIZATION (PSO) UNTUK MEMPREDIKSI INDEKS POLUSI UDARA DI KOTA YOGYAKARTA

Adalah hasil kerja saya sendiri dan benar bebas dari plagiat kecuali cuplikan serta ringkasan yang terdapat di dalamnya setalah saya jelaskan sumbernya (sitasi) dengan jelas. Apabila pernyataan ini terbukti tidak benar maka saya bersedia menerima sanksi sesuai peraturan Mendiknas RI No. 17 Tahun 2000 dan Pernyataan dan Perundang-undangan yang berlaku. Demikian surat pernyataan ini saya buat dengan penuh tanggung jawab.

Dibuat di : Yogyakarta

Pada tanggal :

Yang menyatakan,

(Adfanizar Muhammad)

HALAMAN PERSEMBAHAN

Kepada Tuhan Yang Maha Esa

“Sesungguhnya seorang manusia tidak akan memperoleh apapun selain yang telah diusahakannya”

ABSTRAK

Polusi udara memiliki dampak langsung bagi kesehatan manusia. Diantaranya dapat menyebabkan alergi peradangan dan eksaserbasi asma akut. Salah satu contoh penyebab polusi udara ialah polutan karbon monoksida (CO) yang di keluarkan oleh kendaraan bermotor. Polutan CO merupakan gas yang sangat beracun yang berdampak pada kesehatan manusia. Ketika senyawa CO ini terhirup oleh seseorang, jumlah Oksigen (O_2) didalam tubuh akan berkurang dan jumlah CO akan meningkat yang dapat mengalami sesak napas, pingsan, bahkan kematian, sehingga topik tersebut menjadi permasalahan pada penelitian ini.

Tahap awal yang dilakukan pada penelitian ini yaitu melakukan analisis data konsentrasi polutan udara Yogyakarta yang diawali dengan menghitung korelasi antar data polutan udara dengan faktor meteorologi. Kemudian melakukan preprocessing untuk menginisialisasikan nilai awal data, memilih jumlah fitur dan normalisasi data. Setelah tahap analisis, maka dilakukan perhitungan regresi untuk membandingkan nilai prediksi dan nilai aktual menggunakan metode Support Vector Regression dengan optimasi parameter Particle swarm optimization dan tanpa optimasi parameter.

Pada penelitian ini, konsentrasi polutan yang di prediksi meliputi data konsentrasi polutan karbon monoksida (CO), sulfur dioksida (SO_2), Particulate matter (PM10), Ozon (O_3), Nitrogen dioksida (NO_2) dan faktor meteorologi suhu udara, tekanan udara, kelembaban, kecepatan angin, arah angin, radiasi solar dan curah hujan. Prediksi yang dilakukan menggunakan metode Support Vector Regression setelah analisis dilakukan mendapatkan nilai error MAPE terbaik 0.218 dan MAE sebesar 5.32.

Kata kunci: Prediksi, Polusi Udara, *Support Vector Regression*, *Particle Swarm Optimization*.

ABSTRACT

Air pollution has a direct impact on human health. Among them can cause allergic inflammation and acute asthma exacerbations. One example of the cause of air pollution is the pollutant *carbon monoxide* (CO) emitted by motor vehicles. CO is a highly toxic gas that has an impact on human health. When this CO compound is inhaled by a person, the amount of *Oxygen* (O₂) in the body will decrease and the amount of CO will increase, which can lead to shortness of breath, fainting, and even death, so this topic becomes a problem in this study.

The initial stage of this research is to analyze data on the concentration of air pollutants in Yogyakarta, which begins with calculating the correlation between air pollutant data and meteorological factors. Then do preprocessing to initialize the initial value of the data, choose the number of features, and normalize the data. After the analysis stage, a regression calculation is carried out to compare the predicted value and the actual value using the Support Vector Regression method with Particle swarm optimization parameter optimization and without parameter optimization.

In this study, the predicted pollutant concentrations include data on pollutant concentrations of *carbon monoxide* (CO), *sulfur dioxide* (SO₂), *particulate matter* (PM10), *ozone* (O₃), *nitrogen dioxide* (NO₂) and meteorological factors of air temperature, air pressure, humidity, wind speed, wind direction, solar radiation and rainfall. Predictions were made using the Support Vector Regression method after the analysis was carried out to get the best MAPE error value of 0.218 and MAE of 5.32.

Keywords: *Forecasting, Air Pollutant, Support Vector Regression, Particle Swarm Optimization.*

KATA PENGANTAR

Puji syukur kehadirat Tuhan Yang Maha Esa yang telah memberikan karunia, rahmat serta hidayah-nya sehingga penulis dapat menyelesaikan tugas akhir yang berjudul “Algoritma Support Vector Regression (SVR) Dengan Particle Swarm Optimization (PSO) Untuk Memprediksi Indeks Polusi Udara Di Kota Yogyakarta”. Tugas akhir ini merupakan salah satu syarat kelulusan untuk menyelesaika pendidikan pada jenjang strata satu (S1) Program Studi Informatika Fakultas Teknik Industri Universitas Pembangunan Nasional “Veteran” Yogyakarta.

Laporan ini tidak dapat terselesaikan tanpa bantuan dari berbagai pihak, baik secara langsung maupun tidak langsung. Pada kesempatan ini, penulis ingin menyampaikan ucapan terima kasih kepada:

1. Tuhan Yang Maha Esa yang senantiasa memberikan petunjuk dan kemudahan dalam penulisan tugas akhir.
2. Ayahanda Ardiansyah, Ibunda Mardiningsih, Mas Aden Agyandi, Mba Azmilla Nurrachmalia Adha, Mas Andika Fahrurrozi yang selalu memberikan do'a dan dukungan dalam menyelesaikan tugas akhir ini.
3. Ibu Herlina Jayadanti, S.T., M. T. dan Ibu Wilis Kaswidjanti, S.Si., M. Kom. selaku dosen pembimbing atas ilmu dan bimbingannya yang telah diberikan kepada penulis.
4. Bapak Dr. Awang Hendrianto P, S.T., M.T. dan Bapak Mangaras Yanu F, S.T., M.Eng. selaku dosen penguji.
5. Bapak Dr. Heriyanto, A.Md., S. Kom., M. Cs selaku Ketua Jurusan Teknik Informatika Universitas Pembangunan Nasional “Veteran” Yogyakarta.
6. Ibu Hafsa S.Si., M.T. dan Bapak Mangaras Yanu F, S.T., M.Eng. selaku dosen wali.
7. Bella Febriantikaningrum, S.E. selaku *support system* dan teman seperjuangan.
8. Kawan seperjuangan Kontrakan Otw Eskom “Bona Joshua Hutasoit, Reyhan Javier Lutzow, Reza Muhamad Hasbi, Dhimas Banu Dewantoro, Muhammad Iqbal Yusuf, Muhammad Hafizh Rasyid, Yudhistira Anom Kurniawan”
9. Kawan seperjuangan Kontrakan Tokek “Aryandi, Wahid Rochman Nugroho, Mahendra Pangestu, Yoshua Aruan Linggi Tulak, Muhammad Fahmi Adam”
10. Teman-teman Informatika Angkatan 2016 yang telah mendukung dan memberikan bantuan selama pelaksanaan tugas akhir, terkhusus kepada saudara Awang Suria Trisakti.
11. Seluruh pihak yang telah membantu penyusuan laporan tugas akhir ini.

DAFTAR ISI

TUGAS AKHIR	i
HALAMAN PENGESAHAN PEMBIMBING	ii
HALAMAN PENGESAHAN PENGUJI.....	iii
SURAT PERNYATAAN KARYA ASLI TUGAS AKHIR	iv
PERNYATAAN BEBAS PLAGIAT.....	v
HALAMAN PERSEMBAHAN.....	vi
ABSTRAK.....	vii
ABSTRACT.....	viii
KATA PENGANTAR	ix
DAFTAR ISI	x
DAFTAR GAMBAR	xiii
DAFTAR TABEL	xiv
DAFTAR MODUL PROGRAM	xv
BAB I PENDAHULUAN	xv
1.1 Latar Belakang	1
1.2 Rumusan Masalah	2
1.3 Batasan Masalah	3
1.4 Tujuan Penelitian	3
1.5 Manfaat Penelitian	3
1.6 Metodologi Penelitian dan Pengembangan Sistem	3
1.7 Metodologi Penelitian	3
1.8 Metode Pengembangan Sistem	4
1.9 Sistematika Penulisan	4
BAB II TINJAUAN PUSTAKA	6
2.1 Udara	6
2.2 Pencemaran Udara	6
2.3 <i>Air Quality Index (AQI)</i>	7
2.4 Faktor Meteorologi	9
2.5 Prediksi	10
2.5.1 Time Frame	10
2.6 <i>Support Vector Machine (SVM)</i>	11
2.6.1 Support Vector Machine Linier Nonseperable Data	11
2.6.2 Support Vector Machine Non-Linier Nonseperable Data	12
2.6.3 <i>Support Vector Regression</i>	13
2.7 <i>Particle Swarm Optimization</i>	15
2.8 Normalisasi Dan Denormalisasi Data	16
2.9 Perhitungan <i>Error</i>	17
2.9.1 <i>Mean Absolute Percentage Error (MAPE)</i>	17
2.10 <i>Mean Square Error (MSE)</i>	17
2.11 Korelasi Data	17
2.12 <i>State of Art</i>	18
BAB III METODOLOGI PENELITIAN DAN PERANCANGAN SISTEM	20

3.1 Metodologi Penelitian.....	20
3.1.1 Pengumpulan data	20
3.1.2 Tahap analisis	21
3.1.2.1 Korelasi data	21
3.1.3 Data <i>preprocessing</i>	21
3.1.3.1 Inisialisasi awal data	22
3.1.3.2 Pemilihan jumlah fitur	22
3.1.3.3 Normalisasi data.....	22
3.1.3.2 Pemilihan jumlah fitur.....	22
3.1.3.3 Normalisasi data.....	23
3.1.4 Pelatihan <i>Support Vector Regression</i>	23
3.1.4.1 Pembagian data <i>training</i> dan <i>testing</i>	24
3.1.4.2 Tentukan kernel.....	25
3.1.4.3 Tentukan nilai <i>C</i> dan parameter kernel	25
3.1.4.4 Tentukan awal a_i dan a_i^*	25
3.1.5 Pengujian <i>Support Vector Regression</i>	25
3.1.5.1 Hitung nilai jarak antar data.....	25
3.1.5.2 Tentukan matriks.....	25
3.1.5.3 <i>Sequential learning</i>	25
3.1.5.4 Peramalan dengan kernel, <i>loss function</i> dan parameter	25
3.1.5.5 Denormalisasi data.....	25
3.1.5.6 Hitung MAPE	25
3.1.5.7 Hitung MAE.....	25
3.1.6 Optimasi <i>Particle Swarm Optimization</i>	29
3.1.6.1 Inisialisasi partikel	29
3.1.6.2 Evaluasi partikel.....	29
3.1.6.3 Mencari <i>Pbest</i>	30
3.1.6.4 Mencari <i>Gbest</i>	30
3.1.6.5 Memperbarui posisi dan kecepatan partikel.....	30
3.2 Metode Pengembangan Sistem	31
3.2.1 Pengumpulan kebutuhan	32
3.2.1.1 Analisis dan pengumpulan kebutuhan	32
3.2.1.2 Analisis dan kebutuhan sistem	32
3.2.2 Perancangan Sistem.....	34
3.2.2.1 Data flow diagram level 0	34
3.2.2.2 Data flow diagram level 1	34
3.2.2.3 Perancangan antar muka	34
3.2.3 Pengujian parameter	39
BAB IV HASIL, PENGUJIAN DAN PEMBAHASAN	39
4.1 Hasil Penelitian	39
4.1.1 Modul korelasi data.....	39
4.1.2 Modul <i>preprocessing</i>	39
4.1.3 Modul SVR	40

4.1.4 <i>Particle swarm optimization</i>	40
4.1.5 Modul MAPE dan MAE	41
4.2 Hasil Pengujian	41
4.2.1 Pengujian penelitian	42
4.2 Pembasan.....	41
BAB V KESIMPULAN DAN SARAN.....	45
5.1 Kesimpulan	41
5.2 Saran	41
DAFTAR PUSTAKA	46
LAMPIRAN	50

DAFTAR GAMBAR

Gambar 2.1 ISPU PM10 & SO ₂ satuan SI dalam bentuk grafik	8
Gambar 2.3 ISPU NO ₂ satuan SI dalam bentuk grafik.....	8
Gambar 2.4 Tingkatan ISPU skala warna kualitas udara	9
Gambar 2.5 Ilustrasi SVM.....	11
Gambar 2.6 Fungsi kernel	12
Gambar 3.1 Tahapan penelitian.....	20
Gambar 3.2 <i>Flowchart</i> data <i>preprocessing</i>	22
Gambar 3.4 <i>Flowchart</i> pelatihan SVR	24
Gambar 3.4 <i>Flowchart</i> pengujian SVR	26
Gambar 3.5 Flowchart Sequential Learning.....	27
<i>Sequential learning</i> memiliki beberapa langkah sebagai berikut.....	27
Gambar 3.6 <i>Flowchart</i> optimasi PSO	30
Gambar 3.7 Metode pengembangan sistem.....	32
Gambar 3.8 DFD level 0	34
Gambar 3.9 DFD level 1	34
Gambar 3.10 Halaman utama	35
Gambar 3.11 Halaman <i>login</i>	36
Gambar 3.12 Halaman <i>input</i> data admin	36
Gambar 3.13 Halaman <i>user</i>	37
Gambar 3.14 Halaman grafik	37
Gambar 4.1 Contoh hasil optimasi parameter	41
Gambar 4.2 Contoh hasil kombinasi konsentrasi PM10 dengan faktor meteorologi.....	43
Gambar 4.3 Contoh hasil kombinasi konsentrasi CO dengan faktor meteorologi	43
Gambar 4.4 Contoh hasil kombinasi konsentrasi SO ₂ dengan faktor meteorologi	43
Gambar 4.5 Contoh hasil kombinasi konsentrasi O ₃ dengan faktor meteorologi	43
Gambar 4.6 Contoh hasil optimasi parameter kombinasi 1.....	43
Gambar 4.7 Contoh hasil optimasi parameter kombinasi 2.....	46
Gambar 4.8 Contoh hasil optimasi parameter kombinasi 8.....	46

DAFTAR TABEL

Tabel 2.1 Periode Waktu Pengukuran	6
Tabel 2.2 ISPU Satuan SI Dalam Bentuk Tabel.....	7
Tabel 2.3 Tabel Angka dan Kategori ISPU.....	9
Tabel 2.4 Tabel Fungsi <i>Kernel</i> Umum Pada SVM.....	13
Tabel 2.5 Nilai MAPE Evaluasi Peramalan	17
Tabel 2.6 Daftar Penelitian Sebelumnya	18
Tabel 3.1 Contoh Hasil Penyatuan Konsentrasi Polutan dan Faktor Meteorologi.....	21
Tabel 3.2 Data Indeks Polutan CO	22
Tabel 3.3 Hasil Pemilihan Fitur.....	23
Tabel 3.4 Data Normalisasi Indeks Polutan CO.....	23
Tabel 3.5 Data <i>Training</i> Untuk Pelatihan SVR.....	24
Tabel 3.6 Data <i>Testing</i> Untuk Pelatihan SVR	24
Tabel 3.7 Nilai C dan Parameter Kernel.....	25
Tabel 3.8 Inisialisasi Awal <i>ai</i> dan <i>ai</i> *	25
Tabel 3.9 Hasil Matriks <i>Hessian</i> $\gamma = 1$	26
Tabel 3.10 Hasil Perhitungan E_i	27
Tabel 3.11 Hasil Perhitungan δa^* dan δa Pada Iterasi Pertama.....	28
Tabel 3.12 Hasil Perhitungan a_i^* dan a_i Pada Iterasi Pertama.....	28
Tabel 3.13 Hasil Fungsi Peramalan Data <i>Training</i> Ke Data <i>Testing</i>	29
Tabel 3.14 Hasil Denormalisasi.....	29
Tabel 3.15 <i>Range</i> Partikel	30
Tabel 3.16 Kebutuhan Perangkat Keras	33
Tabel 3.17 Kebutuhan Perangkat Lunak	33
Tabel 3.18 Struktur Tabel Polusi Udara	35
Tabel 3.19 Tabel Perhitungan Korelasi PM10 dan CO dengan Faktor Meteorologi	38
Tabel 3.20 Tabel Pengujian Kombinasi Parameter	38
Tabel 4.1 Urutan Korelasi Data dari yang Paling Berpengaruh	42

DAFTAR MODUL PROGRAM

Modul Program 4.1 Algoritma 1: Fungsi Korelasi Data	38
Modul Program 4.2 Algoritma 2: Deret Waktu.....	38
Modul Program 4.3 Algoritma 3: Pisah Data Training dan Data Testing.....	39
Modul Program 4.4 Algoritma 4: SVR	39
Modul Program 4.5 Algoritma 5: Fungsi Pre-processing.....	40
Modul Program 4.6 Algoritma 6: Fungsi Pre-processing Lanjutan	40
Modul Program 4.7 Algoritma 7: Fungsi MAPE	41
Modul Program 4.8 Algoritma 8: Fungsi MAE	41

BAB I

PENDAHULUAN

1.1 Latar Belakang

Polusi udara memiliki dampak langsung bagi kesehatan manusia. Diantaranya dapat menyebabkan alergi peradangan dan eksaserbasi asma akut. Salah satu contoh penyebab polusi udara ialah polutan karbon monoksida (CO) yang di keluarkan oleh kendaraan bermotor. Polutan CO merupakan gas yang sangat beracun yang berdampak pada kesehatan manusia. Ketika senyawa CO ini terhirup oleh seseorang, jumlah Oksigen (O_2) didalam tubuh akan berkurang dan jumlah CO akan meningkat yang dapat mengalami sesak napas, pingsan, bahkan kematian. Karena itu, dibutuhkan pemantauan dan prediksi polusi udara untuk mencegah memburuknya kualitas udara dalam jangka panjang. Selain itu, prediksi kualitas udara jangka pendek juga diperlukan untuk mengambil tindakan pencegahan dan tindakan menghindari tahapan-tahapan polusi di udara (Lu & Wang, 2005).

Saat ini penelitian tentang *machine learning* tentang prediksi telah banyak dilakukan. Seperti prediksi saham, stok barang, pengunjung, kualitas udara, dll. Sebagai contoh prediksi konsentrasi polutan udara untuk menentukan kualitas udara, salah satu teknik prediksi yang digunakan ialah *Back Propagation Neural Network* (BPNN) yang dioptimasi dengan *Wavelet Decomposition* (Bai et al., 2016) untuk memprediksi tiga konsentrasi polutan udara PM10, SO_2 dan NO_2 dipengaruhi dengan data meteorologi, yaitu kecepatan angin (m/s), temperature ($^{\circ}C$), kelembaban (%). BPNN mendapatkan hasil yang kurang maksimal karena mendapatkan persentase error yang lumayan besar, 31,2% untuk PM10, 22,1% untuk SO_2 dan 35,03% untuk NO_2 , setelah di optimasi menggunakan *Wavelet Decomposition* hasil persentase *error* PM10, SO_2 , dan NO_2 turun 15,989%, 6,253%, dan 18,486% jika dibandingkan dengan BPNN. Penelitian (Kumar & Goyal, 2011) menghitung kualitas udara yang terpengaruhi oleh pencemar seperti *karbon monoksida* (CO), *respirable suspended particulate matter* (RSPM), *sulfur dioxide* (SO_2), *nitrogen dioxide* (NO_2), *suspended particulate matter* (SPM), *ozon* (O_3) menggunakan *auto regressive integrated moving average* (ARIMA), *principal component regression* (PCR) dan kombinasi keduanya. Akan tetapi, ada banyak ketidakpastian yang ada dalam model. Ketidakpastian ini mungkin terlibat pada saat pengembangan persamaan model atau mungkin karena kualitas input. Kemudian penelitian lainnya menggunakan *Artificial Neural Networks* (ANN)(Feng et al., 2015) untuk memprediksi kualitas udara dengan menghitung konsentrasi polutan udara PM2,5 tanpa faktor meteorologi yang menggunakan data latih sebanyak 344 (85%) dan data uji sebanyak 60 (15%) yang mendapatkan hasil yang cukup baik akan tetapi untuk *band error*nya memiliki persentase hasil yang tidak stabil pada set pengujian terbatas meskipun validasi silang telah digunakan. Dalam penelitian (He et al., 2014) ANN sendiri telah dioptimalkan menggunakan algoritma *Particle Swarm Optimization* (PSO) untuk memprediksi konsentrasi *Particulate Matter* (PM). Namun, mereka tidak mengusulkan mekanisme formal untuk menangani pembatasan tersebut, karena pembatasan tersebut pada awalnya membawa risiko konvergensi minimum lokal. Pada penelitian (Hermawan, 2019) menggunakan *Support Vector Machine* (SVM) dengan *kernel Radial Basis Function* (RBF) untuk memprediksi indeks kualitas udara kota DKI Jakarta dan mendapatkan hasil pengujian

prediksi kualitas udara yaitu diatas 87% disetiap daerah yang dilakukan penelitian. Literatur yang mencakup teknik lain seperti *Support Vector Regression* (SVR) seperti pada penelitian (Agmalaro et al., 2019) yang menggunakan 8 atribut *dataset* untuk penelitian dan menggunakan kernel *Radial Basis Function* (RBF) dan mendapatkan hasil persentase error yang cukup baik. Pada penelitian SVR lainnya (Maharesi et al., 2013) algoritma SVR dikatakan lebih baik dari model proses training model regresi biasa dan Jaringan Syaraf Tiruan (JST) dalam mengatasi masalah *overfitting* sehingga SVR menghasilkan performasi yang lebih baik (Raharyani et al., 2018). Penelitian SVR sendiri pernah dioptimalkan menggunakan algoritma PSO (Zhao et al., 2016) memprediksi konsentrasi polutan PM2,5 dalam 3 bulan menggunakan 6 parameter meteorologi yang mendapatkan hasil persentase *error* cukup baik, 11.35 untuk bulan pertama, 9.46 untuk bulan kedua dan 8.32 untuk bulan ketiga.

Particle Swarm Optimization (PSO) sendiri merupakan strategi pengoptimalan yang diperkenalkan pertama kali oleh (Kennedy & Eberhart, 1995) PSO dalam beberapa tahun terakhir, telah menunjukkan kinerja yang baik dalam banyak masalah pengoptimalan fungsi dan masalah pengoptimalan parameter. Banyak penelitian yang menggunakan PSO (Murillo-Escobar et al., 2019) terbukti meningkatkan persentase performa dalam penelitian yang menggunakan 5 fitur data eksternal dan 5 fitur konsentrasi polutan udara. Menurut (Shi & Eberhart, 1999) Keunggulan lain dari PSO adalah algoritma PSO dapat dengan cepat mencapai nilai konvergensi dan tidak sensitif terhadap ukuran populasi. Dalam penelitian (Arampongansuwan & Meesad, 2012) ini, parameter optimal SVR yang dicari oleh PSO adalah $C = 5009$, $\epsilon = 0.0011$, $\sigma = 0.1072$ dan data estimasi uji dan hasil percobaan menunjukkan bahwa PSO-SVR merupakan salah satu metode untuk memprediksi polutan. Model *support vector regression* dapat digunakan untuk memperkirakan keberhasilan prediksi polutan. Salah satu contoh prediksi lain yang menggunakan SVR dan PSO merupakan penelitian (Rusdi, 2017) memprediksi suhu udara di kota Banjarmasin dengan mendapatkan hasil RMSE untuk 0,991 tanpa optimasi PSO dan 0,900 dengan optimasi PSO.

Oleh karena itu, penelitian ini akan mengusulkan metode *Support Vector Regression* (SVR) dengan *Particle Swarm Optimization* (PSO) untuk memprediksi polusi udara di kota Yogyakarta yang mencakup parameter-parameter yang berpengaruh. Penelitian ini akan menggunakan data yang bersumber dari data dinas lingkungan hidup dan kehutanan yang telah memvalidasi data indeks standar pencemar udara (ISPU) di Yogyakarta. Data tersebut akan menjadi data latih dan juga data uji. Penelitian ini diharapkan dapat mengetahui tingkatan performa metode *forecasting* SVR dalam memprediksi polusi udara. Kemudian, penelitian ini diharapkan dapat menghasilkan sebuah sistem yang dapat digunakan untuk memprediksi polusi udara sehingga mengetahui tingkatan polutan yang baik dan tidak baik untuk dikonsumsi oleh manusia.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah dipaparkan, maka dapat diambil rumusan masalah yaitu bagaimana pengaruh optimasi parameter pada penggunaan algoritma *Support Vector Regression* (SVR) dalam memprediksi indeks polusi udara tanpa dan dengan faktor meteorologi di kota Yogyakarta.

1.3 Batasan Masalah

Menghindari terjadinya topik permasalahan yang lebih luas, maka diberikan batasan masalah sebagai berikut:

1. Data penelitian didapatkan dari dinas lingkungan hidup dan kehutanan kota Yogyakarta.
2. Data penelitian yang digunakan dari tahun 2020 sampai dengan 2021.
3. Bahasa yang digunakan dalam penelitian adalah Bahasa Indonesia.
4. Metode yang digunakan adalah algoritma *Support Vector Regression* dengan optimasi *Particle Swarm Optimization*.
5. Data penelitian yang digunakan berdasarkan data dari Indeks Standar Polusi Udara (ISPU) di kota Yogyakarta.
6. Data faktor meteorologi yang digunakan ialah suhu udara ($^{\circ}\text{C}$), tekanan udara(mb) kelembaban (%), kecepatan angin (m/s), arah angin ($^{\circ}$), radiasi solar (Wh/m^2), curah hujan (mm), yang didapat dari website dinas lingkungan hidup dan kehutanan kota Yogyakarta.

1.4 Tujuan Penelitian

Tujuan dari penelitian tugas akhir ini adalah untuk mengetahui tingkat performa dari optimasi parameter *Particle Swarm Optimization* pada hasil dari algoritma *Support Vector Regression* dalam memprediksi indeks polusi udara di kota Yogyakarta tanpa dan dengan faktor meteorologi.

1.5 Manfaat Penelitian

Manfaat penelitian yang diharapkan dengan dilakukannya penelitian dari algoritma *Support Vector Regression* dengan optimasi parameter *Particle Swarm Optimization* dalam memprediksi prediksi polusi udara adalah dapat membantu melakukan prediksi kualitas udara. Selain itu, bagi ilmu pengetahuan diharapkan penelitian ini dapat menjadi referensi penelitian *forecasting* dan menjadi referensi ketika akan dikembangkan.

1.6 Metodologi Penelitian dan Pengembangan Sistem

Pada bagian ini dijelaskan tentang metode dalam melakukan penelitian. Metode tersebut yaitu:

1.7 Metodologi Penelitian

Metodologi yang digunakan dalam penelitian ini secara berurutan adalah sebagai berikut:

1. Identifikasi Masalah

Identifikasi merupakan pembuatan rumusan masalah yang baik dan relevan dengan tema yang diangkat, bersifat baru, asli dan menarik perhatian.

2. Studi Literatur

Studi literatur dilakukan dengan cara mencari dan menghimpun data ataupun sumber-sumber pustaka yang dapat mendukung penelitian serta memberikan informasi untuk menyelesaikan permasalahan pada penelitian ini. Studi kepustakaan yang digunakan bersumber dari buku, jurnal, artikel dan paper yang berkaitan pada penelitian ini

3. Pengumpulan Data

Data yang digunakan pada penelitian ini bersumber dari data kementerian lingkungan hidup dan kehutanan yang telah memvalidasi data indeks standar pencemar udara (ISPU) di Yogyakarta. Pengumpulan data dilakukan dengan pengambilan data terbuka di website Dinas Lingkungan Hidup Kota Yogyakarta.

4. Analisis Data

Analisis data dilakukan untuk mengubah data dari penelitian ini menjadi informasi yang dapat digunakan untuk menarik kesimpulan nantinya.

5. Pengolahan Data

Pengolahan data meliputi pengembangan sistem dan proses *input* data. Pemrograman sistem dilakukan dengan menggunakan bahasa pemrograman *Python*. Proses pembuatan sistem dilengkapi dengan proses data *mining*, menggunakan algoritma *Support Vector Machine* untuk prediksi, dan menggunakan algoritma *Particle Swarm Optimization* untuk mengoptimalkan keakuratannya. Data pelatihan akan diolah untuk menghasilkan nilai yang berbeda dari setiap objek, kemudian nilai tersebut akan digunakan untuk pelatihan dan pengujian sistem. Selain itu, gunakan data pengujian untuk melakukan pengujian guna menentukan tingkat keberhasilan sistem.

6. Laporan Akhir

Proses pembuatan laporan meliputi proses yang dilakukan dalam proses penelitian dan memberikan kesimpulan.

1.8 Metode Pengembangan Sistem

Metode pengembangan sistem yang berkaitan dengan perancangan sistem pada penelitian ini menggunakan metode *prototype*. Pemilihan metode *prototype* karena metode tersebut menekankan bahwa pengembang dan pelanggan dapat saling berinteraksi dalam perancangan dan produksi sistem. Beberapa langkah yang dilakukan dalam metode *prototype* adalah sebagai berikut (Pressman, 2012):

1. Pengumpulan Kebutuhan

Pada tahap ini dilakukan komunikasi dan pertemuan atau diskusi kelompok untuk menentukan tujuan keseluruhan, persyaratan yang diharapkan, dan deskripsi bagian-bagian yang dibutuhkan selanjutnya. Pada saat yang sama, rincian persyaratan mungkin tidak dibahas pada tahap ini, tetapi pada tahap selanjutnya.

2. Design

Pada tahap ini, *prototype* yang dibangun dengan sistem desain sementara kemudian dievaluasi sesuai dengan kebutuhan pengguna, apakah sudah memenuhi persyaratan atau masih perlu dievaluasi ulang. Setelah mempertimbangkan sistem sesuai ekspektasi pelanggan, langkah selanjutnya adalah membuat aplikasi (kode) untuk desain sistem dan menerjemahkannya ke dalam bahasa pemrograman.

3. Evaluasi

Pada tahap ini, klien / pengguna telah melakukan evaluasi prototipe dan telah digunakan untuk mengevaluasi kebutuhan perangkat lunak.

1.9 Sistematika Penulisan

Sistematika penulisan yang digunakan dalam menyusun laporan penelitian ini adalah sebagai berikut :

Bab I Pendahuluan

Pada bagian ini membahas tentang latar belakang masalah, perumusan masalah, batasan masalah, tujuan penelitian, manfaat penelitian, metodologi penelitian, dan sistematika penulisan.

Bab II Tinjauan Pustaka

Tinjauan pustaka memuat tentang dasar teori yang digunakan untuk analisis dan perancangan sistem serta implementasi pada penelitian ini. Selain itu juga sebagai bahan referensi dan pondasi untuk memperkuat argumentasi dalam penelitian ini. Teori-teori yang sesuai dengan penelitian ini antara *forecasting*, *support vector regression*, dan polusi udara.

Bab III Metodelogi Penelitian dan Pengembangan Sistem

Pada bab ini akan menyajikan hasil penelitian yang berisi hasil implementasi dari perancangan yang telah dibuat pada bab sebelumnya. Selain itu berisi pengujian terhadap hasil penelitian beserta pembahasannya.

Bab IV Hasil, Pengujian dan Pembahasan

Pada bagian ini berisi kesimpulan dari hasil penelitian dan saran yang diajukan oleh penulis untuk pengembangan penelitian selanjutnya.

Bab V Kesimpulan dan Saran

Pada bagian ini berisi kesimpulan dari hasil penelitian dan saran yang diajukan oleh penulis untuk pengembangan penelitian selanjutnya.

BAB II

TINJAUAN PUSTAKA

2.1 Udara

Udara adalah campuran dari gas yang terdapat di permukaan bumi yang tidak dapat dilihat oleh mata yang terletak pada lapisan atmosfir. Udara termasuk salah satu jenis sumber daya alam yang sangat penting bagi kelangsungan hidup makhluk hidup di bumi baik manusia, hewan ataupun tumbuhan.

Kandungan udara yang ada di bumi menurut penelitian (Purba & Harefa, 2020) meliputi 78,09% *nitrogen* (N_2), 20,95% *oksigen* (O_2), 0,93% *argon*, 0,04% *karbon dioksida* (CO_2), dan gas-gas lain yang tercampur dalam kandungan udara seperti *neon*, *helium*, *metana*, *kripton*, *hidrogen*, *xenon*, *ozon*, *radon*. Salah satu zat yang terpenting bagi kelangsungan hidup makhluk hidup di muka bumi adalah *oksigen* (O_2) yang digunakan untuk bernafas bagi manusia dan hewan. Sedangkan untuk tumbuhan yaitu *karbon dioksida* (CO_2) untuk proses fotosintesis dan *ozon* yang berfungsi sebagai penahan dari radiasi pancaran sinar *ultraviolet* matahari.

2.2 Pencemaran Udara

Kondisi dimana kehadiran satu atau lebih substansi biologi, kimia ataupun fisik di lapisan atmosfir bumi yang berlebihan yang dapat membahayakan kesehatan makhluk hidup biasa disebut dengan pencemaran udara. Dalam undang-undang Nomor 23 tahun 1997 pasal 1 ayat 12 mengenai Pengelolaan Lingkungan hidup, yang mana Pencemaran udara adalah disebabkan oleh kegiatan manusia seperti pencemaran limbah pabrik, kendaraan bermotor, pembakaran sampah, dan lain-lain yang membuat kualitasnya menurun sampai ketingkat tertentu dan lingkungan hidup tidak dapat berfungsi sesuai dengan peruntukannya.

Di kota Yogyakarta sendiri memiliki parameter udara ambien yang di pantau mengacu pada Keputusan Kepala Badan Pengendalian Dampak Lingkungan No. KEP-107/KABAPEDAL/11/1997 meliputi *ozon* (O_3), *karbon monoksida* (CO), *partikel tersuspensi* (PM10), *nitrogen dioksida* (NO_2), dan *sulfur dioksida* (SO_2). Parameter-parameter ini memiliki periode waktu pengukuran, dapat dilihat di Tabel 2.1 sebagai berikut:

Tabel 2.1 Periode Waktu Pengukuran

No	Parameter	Waktu Pengukuran
1	<i>Partikel tersuspensi</i> (PM10)	24 jam (Periode pengukuran rata-rata)
2	<i>Sulfur dioksida</i> (SO_2)	24 jam (Periode pengukuran rata-rata)
3	<i>Karbon monoksida</i> (CO)	8 jam (Periode pengukuran rata-rata)
4	<i>Ozon</i> (O_3)	1 jam (Periode pengukuran rata-rata)
5	<i>Nitrogen dioksida</i> (NO_2)	1 jam (Periode pengukuran rata-rata)

Sumber : Keputusan Kepala Badan Pengendalian Dampak Lingkungan Nomor: Kep- 107/Kabapedal/11/1997

Prinsip dari pencemaran udara yang terjadi adalah ketika dalam udara terdapat suatu gas-gas polutan yang bersumber dari aktifitas alam dan juga kebanyakan dari aktifitas manusia. Pencemaran udara dapat mempengaruhi kualitas udara normal pada lapisan atmosfir bumi yang dapat mengakibatkan gangguan terhadap kelangsungan hidup pada makhluk hidup yang berada di muka bumi.

2.3 Air Quality Index (AQI)

Air Quality Index (AQI) (Budiyono, 2010; Kumar & Goyal, 2011; Trianisa et al., 2020; S. Zhu et al., 2017) sebagai tinjauan nilai parameter (indikator) kualitas udara ambien yang dikonversi pada lokasi dan waktu tertentu. Hasilnya diperoleh sebagai persamaan konversi parameter, yang dapat mengubah parameter pencemaran udara menjadi nilai tanpa dimensi yang bermakna, untuk kemudian menjadi gambaran masalah pencemaran udara. Indeks standar pencemaran udara (ISPU) digunakan sebagai bahan pertimbangan pemerintah pusat dan pemerintah daerah di Indonesia dalam melaksanakan pengelolaan dan pengendalian pencemaran udara.

ISPU sendiri memiliki penomoran dan perhitungan nilai menggunakan metode yang telah ditetapkan melalui Keputusan Kepala Badan Pengendalian Dampak Lingkungan No. KEP-107/KABAPEDAL/11/1997, yaitu:

Keterangan:

Dimana ;

I = ISPU

Ia = ISPU batas atas

Ib = ISPU batas bawah

Xa = Ambien batas atas

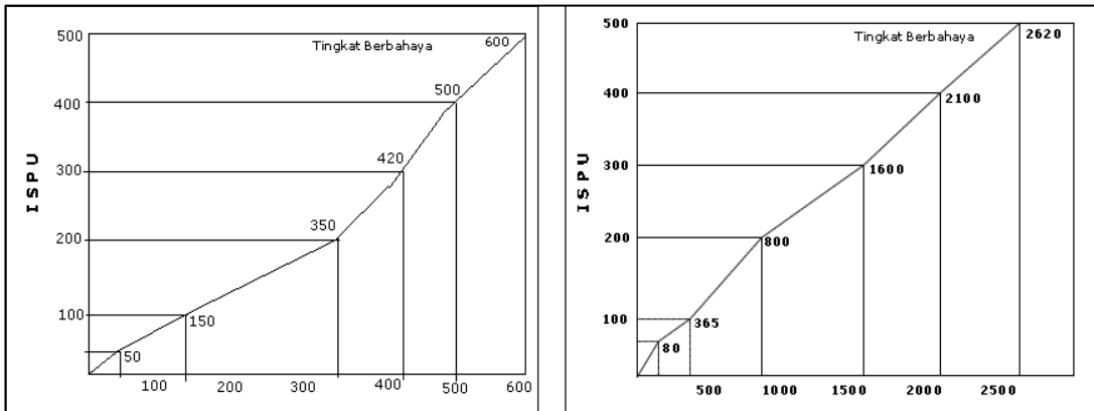
Xb = Ambien batas bawah

X_x = Ambien hasil pengukuran
Untuk batas indeks standar pencemaran udara dalam satuan SI dapat dilihat pada

Tabel 2.2 ISPU Satuan SI Dalam Bentuk Tabel					
ISPU	24 Jam PM10 ug/m3	8 Jam SO2 ug/m3	8 Jam CO ug/m3	1 Jam O3 ug/m3	1 Jam NO2 ug/m3
50	50	80	5	120	
100	150	365	10	253	
200	350	800	17	400	1130
300	420	1600	34	800	2260
400	500	2100	46	1000	3000
500	600	2620	57.5	1200	3750

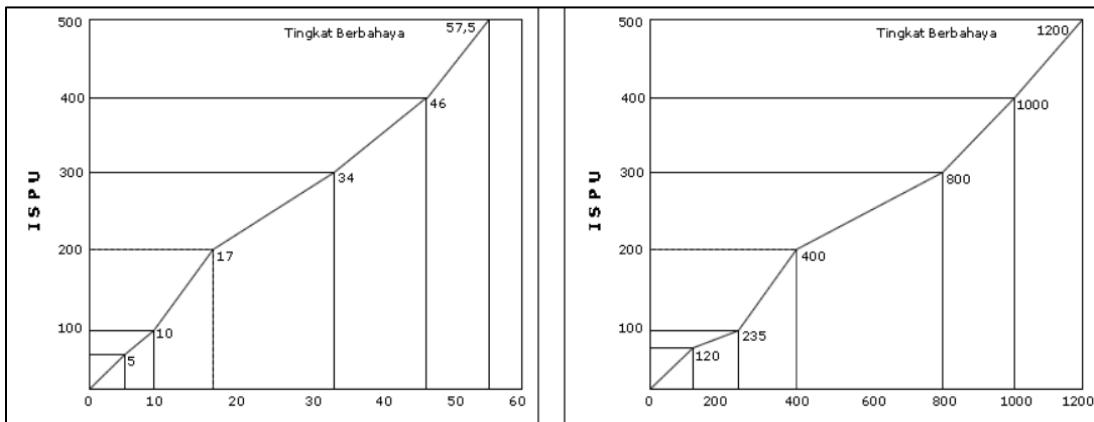
Sumber : Peraturan Pemerintah No. 41 Tahun 1999

Nilai ISPU dihitung untuk semua parameter yang diukur sehingga diperoleh nilai ISPU untuk setiap parameter kualitas udara. Nilai tersebut akan diambil sebagai nilai akhir dari Standard Air Pollution Index (ISPU) yang digunakan untuk mengukur kualitas udara, yang merupakan nilai tertinggi dalam perhitungan parameter udara. Pada Gambar 2.1, Gambar 2.2 dan Gambar 2.3 merupakan indeks standar pencemaran udara dalam bentuk grafik.



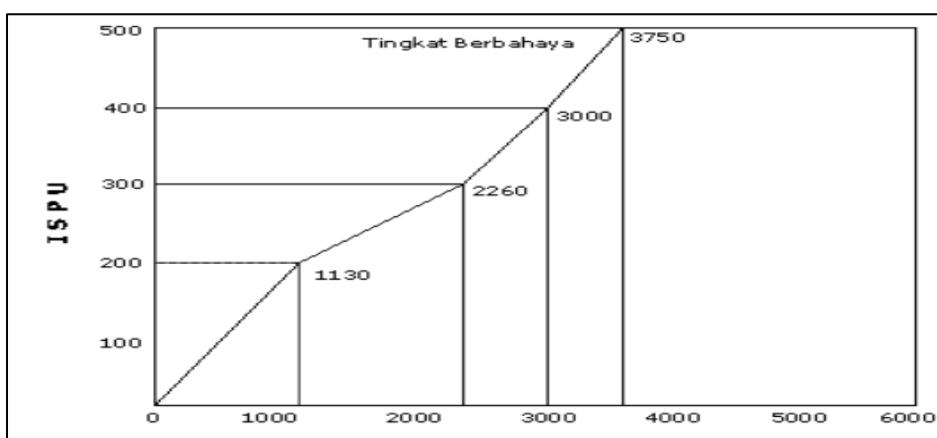
Gambar 2.1 ISPU PM10 & SO₂ satuan SI dalam bentuk grafik

Sumber : Keputusan Kepala Badan Pengendalian Dampak Lingkungan Nomor: Kep-107/Kabapedal/11/1997



Gambar 2.2 ISPU CO & O₃ satuan SI dalam bentuk grafik

Sumber : Keputusan Kepala Badan Pengendalian Dampak Lingkungan Nomor: Kep-107/Kabapedal/11/1997



Gambar 2.3 ISPU NO₂ satuan SI dalam bentuk grafik

Sumber : Keputusan Kepala Badan Pengendalian Dampak Lingkungan Nomor: Kep-107/Kabapedal/11/1997

Penelitian (Welim & Wisjhnuadji, 2014) menggunakan data ISPU sebagai dataset, kemudian membandingkan nilai ISPU dengan nilai ISPU critical yang menimbulkan selisih

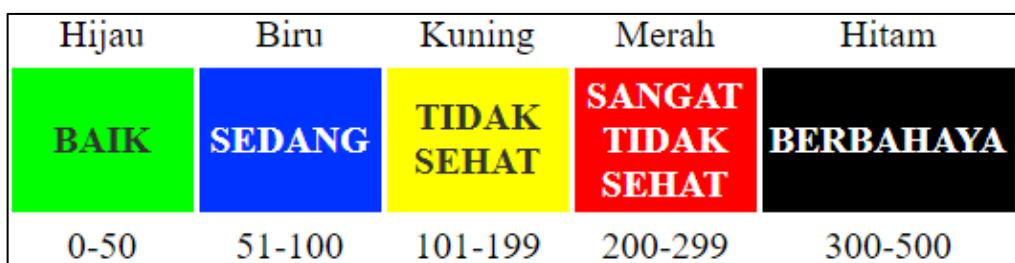
sebesar 2,97% dengan menggunakan metode Adaptive Neuro Fuzzy. Berikut merupakan Tabel 2.3 yang berisikan batasan angka dan kategori ISPU.

Tabel 2.3 Tabel Angka dan Kategori ISPU

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

Sumber : Keputusan Kepala Badan Pengendalian Dampak Lingkungan Nomor: Kep-107/Kabapedal/11/1997

ISPU memiliki tingkatan Skala warna kualitas udara berdasarkan Keputusan Kepala Badan Pengendalian Dampak Lingkungan No. KEP- 107/KABAPEDAL/11/1997 seperti pada Gambar 2.4.



Gambar 2.4 Tingkatan ISPU skala warna kualitas udara

Sumber : Keputusan Kepala Badan Pengendalian Dampak Lingkungan Nomor: Kep-107/Kabapedal/11/1997

2.4 Faktor Meteorologi

Faktor meteorologi merupakan salah satu faktor yang mempengaruhi kualitas udara. Berikut merupakan beberapa faktor yang mempengaruhi pencemaran udara:

1. Temperatur
Temperatur merupakan pergerakan dari lapisan udara dingin secara tiba-tiba yang dapat menyebabkan inversi suhu. Dengan kata lain, udara dingin yang terperangkap tidak dapat keluar dari area tersebut dan akan memerangkap polutan dilapisan permukaan bumi, sehingga konsentrasi polutan semakin meningkat (Chandra, 2006).
2. Arah dan Kecepatan Angin
Angin kencang dapat membawa polutan terbang kemana-mana dan dapat mencemari udara. Karena besarnya gesekan yang timbul pada aliran udara akan membuat kecepatan angin di daerah perkotaan akan cenderung menurun (Soedomo, 2001). Semakin tinggi nilai kecepatan angin, maka semakin kecil konsentrasi pencemar. Sebaliknya, rendahnya kecepatan angin akan mengakibatkan konsentrasi pencemar semakin meninggi di udara.
3. Kelembaban
Kelembaban merupakan hubungan antara jumlah nyata uap air di udara dengan jumlah uap air pada saat udara dijenuhkan pada suhu yang sama, yang dinyatakan dalam persentase. Pada kelembaban udara tinggi, kandungan uap di udara akan bereaksi dengan polutan udara dan menjadi zat lain yang tidak berbahaya atau menjadi polutan sekunder.

2.5 Prediksi

Prediksi atau bisa disebut dengan *forecasting* adalah suatu kegiatan untuk meramalkan atau memprediksi keadaan di masa mendatang melalui pengujian di masa lalu. *Forecasting* (Fajarita & Hati, 2018) merupakan Proses meramalkan permintaan masa depan akan mencakup permintaan dalam hal kuantitas, kualitas, waktu dan lokasi untuk memenuhi permintaan barang, jasa atau lingkungan. Ada dua jenis prakiraan: kualitatif dan kuantitatif. Beberapa teknik peramalan mencoba memproyeksikan pengalaman sejarah dalam bentuk deret waktu ke masa depan.

Meskipun kenyataannya tidak ada metode yang benar-benar 100% memberikan hasil yang akurat untuk memprediksi sesuatu. Namun dengan adanya metode penelitian prediksi, seseorang bisa mempersiapkan keputusan untuk melakukan sesuatu yang didapat dari hasil prediksi. Salah satu contoh metode yang pernah dipakai untuk prediksi ialah *Support Vector Machine* (SVM). Penelitian SVM model regresi (Chuentawat et al., 2017; Hirtl et al., 2014; Liu et al., 2017; Pai et al., 2010; Sanchez-Torres & Bolaño, 2019; H. Zhu & Hu, 2019) mendapatkan hasil yang cukup baik, membuktikan bahwa kemampuan generalisasi yang baik untuk prediksi. Kemudian penelitian (Liu et al., 2017) memprediksi kualitas udara di beberapa kota yang ada di Cina menggunakan menggunakan model *Support Vector Regression* (SVR) yang bertujuan untuk meningkatkan hasil peramalan dengan meminimalkan kesalahan prediksi dari algoritma pembelajaran mesin saat ini. Model SVR dapat diandalkan untuk memprediksi nilai AQI dihitung kesalahan prediksi antara lain *mean square error* (MSE), prediksi eksperimental *root mean square error* (RMSE), *mean average error* (MAE) dan *mean absolute percentage error* (MAPE), dalam 4 kasus menilai kinerja yang berbeda model. Namun, arah Angin memiliki pengaruh yang besar pada kualitas udara suatu kota dan wilayah tertentu. Kualitas udara bisa menjadi lebih baik atau lebih buruk berdasarkan arah angin. Jika angin datang dari daerah yang sangat mengurangi polusi, maka kualitas udara meningkat secara signifikan.

Pada penelitian (Hermawan, 2019) menggunakan *Support Vector Machine* (SVM) dengan *kernel Radial Basis Function* (RBF) untuk memprediksi indeks kualitas udara DKI Jakarta dan mendapatkan hasil pengujian prediksi kualitas udara yaitu diatas 87% disetiap daerah yg di teliti. Salah satu contoh prediksi lain menggunakan SVR dan PSO merupakan penelitian (Rusdi, 2017) memprediksi suhu udara di kota Banjarmasin dengan mendapatkan hasil RMSE untuk 0,991 tanpa optimasi PSO dan 0,900 dengan optimasi PSO.

2.5.1 Time Frame

Prediksi atau *forecasting* dibagi menjadi 3 berdasarkan jangka waktunya (Montgomery et al., 2008) yakni:

- Jangka Pendek (*Short Time*)

Jangka pendek yang meliputi kurun waktu mulai dari satu hari sampai dengan satu musim ataupun sampai satu tahun.

- Jangka Menengah (*Medium Term*)

Jangka menengah meliputi kurun waktu dari satu musim (kuartal, triwulan atau yang lain) hingga dua tahun.

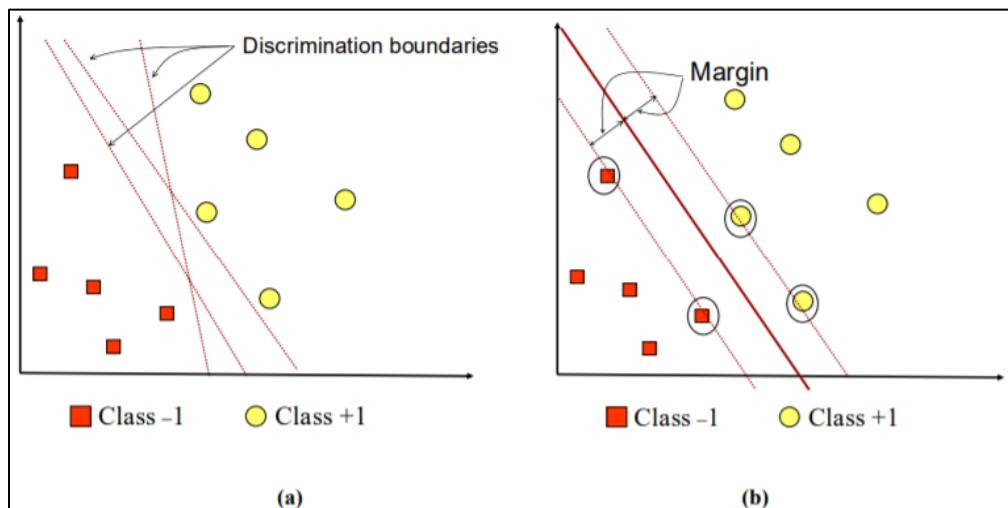
- Jangka Panjang (*Long Term*)

Jangka panjang meliputi peramalan untuk kurun waktu minimal lima tahun.

2.6 Support Vector Machine (SVM)

Support Vector Machine (SVM) dikembangkan oleh Boser, Guyon, Vapnik, dan dipresentasikan untuk pertama kalinya pada tahun 1992 di *Annual Workshop on Computational Learning Theory*. SVM awalnya digunakan untuk klasifikasi, tetapi prinsip SVM bisa meluas menjadi *Support Vector Regression* (SVR) dan prediksi deret waktu. Menurut (Kusumodestoni, 2017) *Support Vector Machine* (SVM) adalah salah satu model prediksi yang menggunakan sistem ruang hipotesis berupa fungsi-fungsi linier dalam sebuah ruang fitur berdimensi tinggi dengan menggunakan algoritma pembelajaran yang didasarkan pada teori optimasi dari pembelajaran statistik teori. Metode SVM (Yasin et al., 2014) sangat baik untuk memprediksi karena metode SVM ini dapat meminimalkan kesalahan klasifikasi dan penyimpangan data pada data training.

SVM dikembangkan untuk menyelesaikan masalah klasifikasi pada dua kelas dengan mencari *hyperplane* terbaik. *Hyperplane* adalah sebuah fungsi untuk pemisah antar kelas membuat data-data tersebut sehingga dapat dilakukan klasifikasi dan analisa regresi. Pada Gambar 2.5 merupakan ilustrasi dari SVM.



Gambar 2.5 Ilustrasi SVM

Pada gambar 2.5 (a) diperlihatkan beberapa *pattern* dari dua kelas berbeda yang dimana kelas : -1 yang di simbolkan dengan warna merah dan +1 yang disimbolkan dengan warna kuning yang dipisahkan oleh alternative garis pemisah (*discrimination boundaries*). Sedangkan pada gambar 2.5 (b) terdapat *hyperplane* tepat diantara 2 kelas dengan cara mengukur *margin* *hyperplane* tersebut dan mencari titik maksimalnya yang dimana merupakan prinsip dasar dari analisis ini. Salah satu penelitian yang menggunakan SVM ialah penelitian (Sotomayor-Olmedo et al., 2013) yang menggunakan SVM dan 3 fungsi kernel, yaitu Gaussian, Polynomial and Spline untuk memprediksi Ozon (O_3), Particulate Matter (PM10), dan Nitrogen Dioksida (NO_2) dengan tingkatan akurasi tertinggi 90% untuk kernel Gaussian, 90,3% untuk kernel Polynomial, dan 93,5% kernel Spline.

2.6.1 Support Vector Machine Linier Nonseparable Data

Pada kasus *linier nonseparable* yaitu mengklasifikasikan data *linier* yang tidak dapat dipisahkan. Akan tetapi, tingkatan *error* terendah dapat dicari. Sehingga nanti akan ada *variable slack* non-negatif ξ_i $i = 1, \dots, m$ sehingga mendapatkan persamaan dibawah ini:

Kemudian formula untuk pencarian bidang pemisah dan meminimasi *error* yang dihasilkan sebagai berikut:

$$\min_{\vec{w}, b, \xi} \frac{1}{2} \|\vec{w}\|^2 + C \sum_{i=1}^p \xi_i \quad \dots \quad (2.4)$$

Persamaan (2.12) dan (2.13) dapat di gabungkan ke dalam dua *constraint* seperti berikut

$$y_i(w \cdot x + b) \geq 1 - \xi \quad \dots \dots \dots \quad (2.5)$$

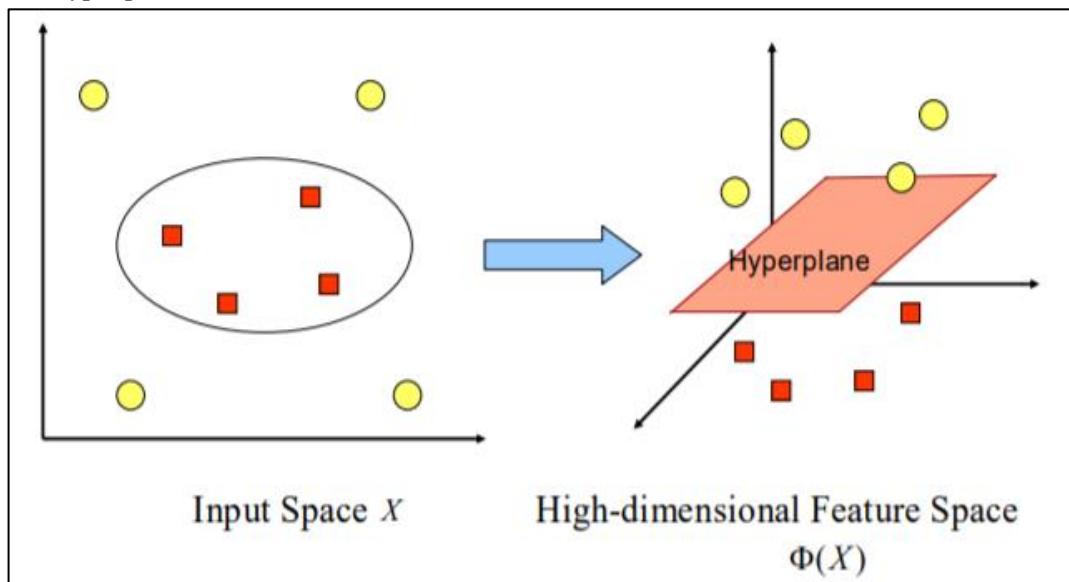
Dalam kasus *nonseperable* untuk mengoptimasi, rumus *Langrange* dapat digunakan untuk mendapatkan solusi paling optimal (Naufal, 2017):

$$\max W(\alpha) = \sum_{i=1}^p \alpha_i - \sum_{i=1}^p \sum_{j=1}^p \alpha_i \alpha_j y_i y_j \vec{x}_i \vec{x}_j \dots \quad (2.6)$$

Dimana α merupakan *Lagrange*. Kemudian batasannya sebagai berikut:

2.6.2 Support Vector Machine Non-Linier Nonseperable Data

Pada kenyataannya tidak semua data itu bersifat *linier* sehingga mencari bidang pemisah secara *linier* itu menjadi sulit. Maka dari itu pada kasus *non-linier* menggunakan fungsi *kernel*. Fungsi ini dapat melakukan *mapping* pada ruang *input* dari data *training* ke *feature space* yang lebih tinggi. Pada ilustrasi gambar 2.6 (kiri) memperlihatkan data pada kelas kuning dan data pada kelas merah yang berada di *input space* dua dimensi tidak dapat dipisahkan secara linier. Kemudian gambar 2.6 (kanan) menunjukan bahwa fungsi *kernel* (ϕ) memetakan tiap data pada *input space* tersebut ke ruang vektor baru yang berdimensi tiga dimensi yang membuat kedua kelas tersebut dapat di pisahkan secara *linier* dengan sebuah *hyperplane*.



Gambar 2.6 Fungsi kernel

SVM memiliki persamaan fungsi *kernel trick* sebagai berikut:

$$\left(\phi(x_i) \phi(x_j) \right) := k(x_i, x_j) \quad \dots \dots \dots \quad (2.8)$$

Tidak hanya persamaan (2.8), ada beberapa fungsi *kernel* yang umum dipakai dalam SVM sebagai pada Tabel 2.4.

Tabel 2.4 Tabel Fungsi Kernel Umum Pada SVM

Jenis Kernel	Definisi
<i>Linier</i>	$K(\vec{x}_i, \vec{x}_j) = \vec{x}_i^T \vec{x}_j$
<i>Polynomial</i>	$K(\vec{x}_i, \vec{x}_j) = (\vec{x}_i \cdot \vec{x}_j + 1)^p$
<i>Radial Basis Function</i>	$K(\vec{x}_i, \vec{x}_j) = \exp(-y \vec{x}_i - \vec{x}_j ^2)$
<i>Sigmoid</i>	$K(\vec{x}_i, \vec{x}_j) = \tanh(\alpha \vec{x}_i \cdot \vec{x}_j + \beta)$

Selanjutnya fungsi umum dari *non linier* SVM dari hasil klasifikasi data \vec{x} diperoleh dari hasil persamaan berikut (Cristianini & Taylor, 2000):

$$f(\phi(\vec{x})) = \vec{w} \cdot \phi(\vec{x}) + b \dots \quad (2.9)$$

Keterangan:

\vec{x} = vektor input

\vec{w} = parameter bobot

b = bias

Kemudian memanfaatkan *constraint* pengoptimalan dan memasukan *Lagrange multipliers*, maka rumus (2.19) dapat menghasilkan persamaan berikut:

$$f(x, a_i, a_i^*) = \sum_{i=1}^n (a_i - a_i^*) K(x, x_i) + b \dots \quad (2.10)$$

Akan tetapi, hasilnya bisa menjadi pemisah yang kurang optimal Ketika pemilihan parameternya salah. Untuk melakukan peramalan kedepan, SVM (Chiu & Chen, 2009) dapat menggunakan persamaan (2.21).

$$f(x) = \text{Sign}(\sum_{i=1}^p y_i a_i K(x, x_i) + y_i - w \cdot x_i) \dots \quad (2.11)$$

2.6.3 Support Vector Regression

Support vector machine (SVR) merupakan salah satu dari bagian SVM yang menggunakan ruang hipotesis berupa fungsi-fungsi *linier* dalam sebuah ruang fitur. Konsep SVR (Smola & Schölkopf, 2004) yang paling popular yaitu ε -*insensitive loss function* yang merupakan model fungsi kerugian ε -*insensitive* yang membatasi $f(x)$ ke kesalahan dibawah ε . Konsep SVR sendiri yaitu untuk mengestimasikan suatu fungsi dengan cara meminimalkan batas atas dari kesalahan generalisasi yang membuat SVR dapat mengatasi *overfitting* (Ganesh et al., 2021; Murillo-Escobar et al., 2019; Yasin et al., 2014). Penelitian SVR pernah digunakan (H. Zhu & Hu, 2019) untuk memprediksi kualitas udara. SVR dapat menurunkan risiko *overfitting* dan dapat memilih *sparsity* yang sesuai dengan parameter. Akan tetapi, ketika rasio *sparsity* besar dapat menyebabkan *overfitting* selama proses berlangsung. Kinerja pada SVR sendiri memiliki beberapa parameter yang mempengaruhi, yaitu:

- Parameter *Complexity* (C) yang menyajikan *trade-off* antara kompleksitas model dan jumlah sehingga penyimpangan yang lebih besar dapat ditoleransi. Untuk nilai C yang besar, pengoptimalan akan memilih hyperplane dengan margin lebih kecil jika hyperplane tersebut melakukan pekerjaan yang lebih baik untuk mengklasifikasikan semua poin pelatihan dengan benar (Aeni et al., 2020).
- Epsilon (ε) untuk mengontrol lebar zona sensitive, dimana ε digunakan untuk menyesuaikan data latih dan digunakan sebagai pengatur batas kesalahan fungsi $f(x)$.

Pada SVR, jika ingin menemukan suatu fungsi $f(x)$ yang mempunyai deviasi paling besar ε dari target y_i untuk data latih. Contohnya pada garis regresi

$$f(x) = w^T \phi(x) + b \dots \quad (2.12)$$

dimana $\phi(x)$ menunjukkan titik didalam *feature space* F hasil dari pemetaan x di dalam input dimensi dan b merupakan bias. Kemudian untuk memaksimalkan *hyperplane* dengan meminimalkan *Loss Function*

$$R(f(x)) = \frac{1}{2} \|w\|^2 + \frac{C}{n} \sum_{i=1}^n L_\varepsilon(y_i, f(x_i)) \dots \quad (2.13)$$

Dimana

$$L_\varepsilon(y_i, f(x_i)) = \begin{cases} 0 & ; y_i - f(x_i) \leq \varepsilon \\ |y_i - f(x_i)| - \varepsilon & ; \text{lainnya} \end{cases} \dots \quad (2.14)$$

Dengan L_ε merupakan ε - *insensitive loss function*, kemudian C dan ε adalah parameter. Namun, dalam banyak kasus (Kazem et al., 2013), ini merupakan masalah optimasi yang tidak layak karena setiap pasangan (x, y) di data set tidak dapat didekati. dengan presisi ε . Untuk memenuhi batasan optimasi, variabel *slack* ξ_i , ξ_i^* harus diperkenalkan dan optimalisasi masalah dirumuskan sebagai.

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \dots \quad (2.15)$$

$$\text{subject to: } \begin{cases} y_i - (w^T x_i + b) \leq \varepsilon + \xi_i \\ (w^T x_i + b) - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \dots \quad (2.16)$$

di mana $C > 0$ adalah konstanta biaya yang berfungsi untuk mengontrol *trade-off* antara kompleksitas model dan tingkat maksimum deviasi di atas ε (Smola & Schölkopf, 2004). Menggunakan formulasi ganda melalui pengali *Lagrange*, SVR dapat diperluas ke fungsi *non-linier*. Dalam hal ini, masalah pengoptimalan didefinisikan hanya dalam istilah pengali *Lagrange* α_i dan α_i^* , ini mungkin karena fungsi Kernel $\Phi(x_i, x_j)$ mengembalikan hasil perkalian titik antara berpasangan dalam ruang dimensi orde tinggi tanpa secara eksplisit memetakan data (Kazem et al., 2013).

$$\max -\frac{1}{2} \sum_{ij=1}^n (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) \Phi(x_i, x_j) - \varepsilon \sum_{i=1}^n (\alpha_i + \alpha_i^*) + \sum_{i=1}^n y_i(\alpha_i - \alpha_i^*) \dots \quad (2.17)$$

$$\text{subject to: } \begin{cases} \sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0 \\ \alpha_i, \alpha_i^* \in [0, C] \end{cases} \dots \quad (2.18)$$

Fungsi prediksi dapat dirumuskan dalam istilah pengali *Lagrange* dan fungsi kernel sebagai berikut:

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \Phi(x_i, x) \dots \quad (2.19)$$

Penelitian menggunakan SVR terbukti efektif salam prediksi polutan udara, seperti prediksi konsentrasi polutan udara PM₁₀ (Sanchez-Torres & Bolaño, 2019) & prediksi konsentrasi PM₁₀ dan SO₂ (Wang et al., 2015). Untuk menyelesaikan permasalahan *non-linier* dapat menggunakan metode *sequential learning* (Vijayakumar & Wu, 1999) dengan langkah sebagai berikut:

- a. Menghitung *error* tiap data *training*

$$E_i = y_i \sum_{j=1}^n (\alpha_j) R_{ij} \dots \quad (2.20)$$

Keterangan:

y_i = nilai target data latih ke-*i*

E_i = nilai *error* data ke-*i*

α_j = Lagrange Multipliers

- b. Menghitung *variable* tunggal $\delta\alpha^*$ dan $\delta\alpha$

Keterangan:

δ_a^* , δ_a = variable slack dari α_i^* dan α_i

C = complexity

$\varepsilon = epsilon$

γ = parameter *gamma*

- c. Memperbarui nilai α_i^* dan α_i

2.7 Particle Swarm Optimization

Particle Swarm Optimization (PSO) pertama kali dikenalkan oleh kennedy & Eberhart pada tahun 1995. PSO muncul sebagai teknik optimasi yang terinspirasi dari perilaku kolektif sosial. Dalam PSO, masalah pengoptimalan didefinisikan sebagai: *swarm particle* yang bergerak dalam parameter ruang sesuai dengan jalur yang ditentukan oleh posisi paling terkenal dan tetangganya (Marini & Walczak, 2015). *Swarm* adalah (Saputra et al., 2019) jumlah partikel dalam populasi dalam algoritma ukuran populasi, yang bergantung pada kompleksitas masalah. Umumnya, saat mencari solusi terbaik, ukuran grup dalam algoritma PSO cenderung lebih kecil dibandingkan dengan algoritma *evolusioner* lainnya. Pada saat yang sama, partikel adalah sekelompok individu yang mewakili solusi untuk masalah. Posisi dan kecepatan setiap partikel bergantung pada representasi solusi pada saat itu. Penelitian (Li et al., 2019) PSO mengoptimasi SVR untuk membandingkan dengan model *genetic algorithm*-SVR dan *grid search*-SVR. PSO-SVR terbukti dapat berkerja lebih cepat, namun masalah perhitungan besar dan kinerja real-time yang buruk akan muncul di model SVR ketika sampel terlalu besar. Berikut merupakan formula dari algoritma PSO.

$$V_{id}^{t+1} = w \times V_{id}^t + C_1 \times \text{Rand1} \times (P_{id} - X_{id}) + C_2 \times \text{Rand2} \times (P_{ad} - X_{id}) \dots \dots \quad (2.25)$$

$$X_{id}^{t+1} = X_{id}^t + V_{id}^{t+1} \quad \dots \quad (2.26)$$

w ≡ Bobot inersia

V_{id} = Kecepatan individu i pada d dimensi

X_{id} = Posisi individu i pada d dimensi

C_1 = Faktor belajar kognitif

C_2 = Faktor pembelajaran sosial

P_{id} = Komponen posisi P_{best} dari partikel d th di dimensi

P_{sd} = Komponen posisi G_{best} dalam dimensi d^{th}

Rand() = Angka acak antara [0,1]

Untuk mengatasi masalah gerak partikel yang hanya terjadi di wilayah solusi lokal dan global, perlu dilakukan pengurangan secara linier nilai w dari nilai maksimum ke nilai minimum yang meningkat di setiap iterasi (X. Lu & Geng, 2011).

$$w = w_{max} \text{ iter } \frac{w_{max} - w_{min}}{iter_{max}} \dots \quad (2.27)$$

Iter adalah iterasi saat ini, dan $iter_{max}$ menunjukkan iterasi maksimum, biasanya w_{max} dan w_{min} diatur ke 0,9 dan 0,1 (X. Lu & Geng, 2011). Selain mereduksi nilai w secara linier, perubahan nilai c_1 dan c_2 juga dilakukan berdasarkan waktu, atau disebut *Time-Varying Acceleration Coefficients* (TVSC). Tujuannya agar perubahan koefisien akan mempengaruhi komponen kognisi dan sosial, sehingga partikel PSO akan bergerak lebih leluasa di ruang pencarian dibandingkan hanya berpindah ke populasi terbaik, dan seiring perubahan berlangsung, akhir pengoptimalan akan lebih jelas. Koefisien akan memungkinkan partikel berkumpul pada nilai optimal global (Ratnaweera et al., 2004) Persamaan perubahan nilai C_1 dan C_2 sebagai berikut:

Nilai C_{1i} , C_{1f} , C_{2i} adalah konstanta, $iter$ adalah nilai dari iterasi saat ini, dan $itermax$ adalah iterasi maksimum. Nilai dari C_{1i} , C_{1f} , C_{2i} dan C_{2f} masing-masing diatur ke 2.5, 0.5 dan 2.5 (Ratnaweera et al., 2004). *Particle Swarm Optimization* (PSO) pernah dilakukan untuk mengoptimasi ANN (He et al., 2014) dan terbukti meningkatkan akurasi hasil memprediksi konsentrasi polutan *Particulate Matter* (PM). Namun, mereka tidak mengusulkan mekanisme formal untuk menangani pembatasan tersebut, karena pembatasan tersebut pada awalnya membawa risiko konvergensi minimum lokal. Pada penelitian (Li et al., 2019) PSO mengoptimasi SVR untuk membandingkan dengan model *genetic algorithm*-SVR dan *grid search*-SVR. PSO-SVR terbukti dapat berkerja lebih cepat, namun masalah perhitungan besar dan kinerja real-time yang buruk akan muncul di model SVR ketika sampel terlalu besar.

2.8 Normalisasi Dan Denormalisasi Data

Normalisasi data dilakukan bertujuan agar data berada pada rentang yang sama sehingga kompleksitas perhitungan berkurang. Kemudian normalisasi data bertujuan untuk mengurangi tingkatan *error* dalam komputasi. Pada penelitian ini menggunakan normalisasi data *min-max* dengan rentang *min-max* 0,1 sampai 1,0. Menurut (Luqyana et al., 2018) Normalisasi data bertujuan untuk meminimalisir kesalahan proses dalam data *mining*. Berikut merupakan formulasi perhitungan normalisasi data.

$$x_i' = \left(\frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \right) \dots \quad (2.30)$$

Keterangan:

x_i = hasil normalisasi data ke- i

x_i \equiv nilai data ke- i

x_{min} = nilai data minimum dari keseluruhan

x_{max} = nilai data maksimum dari keseluruhan

Sedangkan denormalisasi data adalah proses pengembalian data ke awal data sebelum dilakukannya normalisasi data untuk mendapatkan data asli. Proses denormalisasi dilakukan pada hasil akhir atau *output* peramalan. Perhitungan denormalisasi disajikan pada persamaan sebagai berikut.

$$x_i' = y(\max - \min) + \min \dots \quad (2.31)$$

Keterangan:

y = hasil *output*
 min = data minimum
 max = data maksimum

2.9 Perhitungan *Error*

Perhitungan *error* adalah hal yang digunakan untuk melaporkan perbedaan pengukuran antara data hasil prediksi dengan data aktual. Didalam penelitian ini menggunakan dua metode untuk melakukan perhitungan *error*, yakni:

2.9.1 Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) digunakan untuk mengukur keakuratan dari hasil prediksi. Nilai MAPE memiliki satuan pecahan (presentase). Persamaan dari MAPE sebagai berikut (Rahmadya, 2018):

Dari rumus (2.23), jika $actual = forecast$ maka MAPE bernilai nol yang berarti sangat akurat. Penelitian sebelumnya yang menggunakan MAPE ialah penelitian (Lin et al., 2011) yang memprediksi konsentrasi polutan udara menggunakan SVR dengan algoritma *immune*. Mendapatkan akurasi MAPE sebesar 26.43 untuk konsentrasi PM₁₀, kemudian 23.35 untuk konsentrasi NO, dan 27.92 untuk konsentrasi NO₂. Menurut (Lewis, 1982) jika nilai MAPE kurang dari 10% maka hasil peramalan dinyatakan memiliki akurasi tinggi, sedangkan nilai MAPE lebih dari 50% maka hasil peramalan dinyatakan tidak akurat seperti pada Tabel 2.5 yang berisikan batasan MAPE.

Tabel 2.5 Nilai MAPE Evaluasi Peramalan

MAPE (%)	Evaluasi
MAPE \leq 10%	Peramalan dengan akurasi tinggi
10% < MAPE \leq 20%	Peramalan dengan akurasi baik
20% < MAPE \leq 50%	Peramalan dengan nilai wajar
MAPE > 50%	Peramalan tidak akurat

Sumber : (Lewis, 1982)

2.10 Mean Absolute Error (MAE)

MAE merupakan metode pengukuran keakuratan dari hasil prediksi. MAE menunjukkan rata-rata *error* absolut nilai prediksi dengan nilai aktual (Subagyo, 1986).

$$MAE = \left(\frac{1}{n} \sum_{i=1}^n |f_i - y_i| \right) \dots \quad (2.33)$$

Keterangan:

f_i = nilai peramalan

γ_i = nilai sebenarnya

n = jumlah data

Berdasarkan persamaan 2.33 MAE menghitung rata-rata *error* dengan memberikan bobot yang sama ke setiap data. Menurut (Suryanto dan Muqtadir, 2019) MAE lebih intuitif dalam memberikan rata-rata *error* setiap data.

2.11 Korelasi Data

Secara analisis statistik, analisis korelasi dilakukan untuk mengetahui hubungan antar *variable* yang nanti akan diolah. Persamaan uji korelasi dapat dilihat pada persamaan 2.34 sebagai berikut:

$$r_{xy} = \frac{N \sum XY - (\sum X)(\sum Y)}{\sqrt{\{N \sum X^2 - (\sum X)^2\}\{N \sum Y^2 - (\sum Y)^2\}}} \quad (2.34)$$

Keterangan:

R = nilai faktor korelasi

N = jumlah data

X = data *variable* independen

Y = data *variable* dependen

Keterangan faktor korelasi:

0 : Tidak ada korelasi antar dua *variable*

0 – 0,25 : Korelasi sangat lemah

0,25 – 0,5 : Korelasi cukup

0,5 – 0,75 : Korelasi kuat

0,75 – 0,99 : Korelasi sangat kuat

Pada penelitian (Ginting, 2017) menghitung nilai korelasi antara nilai konsentrasi polutan udara CO dan faktor meteorologi, pada faktor meteorologi suhu udara memiliki korelasi yang lemah dengan konsentrasi CO dan berbanding terbaik, ketika suhu udara semakin tinggi maka konsentrasi CO yang dihasilkan akan semakin rendah. Pada faktor meteorologi kecepatan angin memiliki korelasi yang kuat dan berbanding terbalik, dimana semakin semakin tinggi kecepatan angin maka konsentrasi CO akan semakin rendah. Kemudian pada faktor meteorologi kelembaban memiliki hubungan korelasi yang sangat lemah dan berbanding lurus dengan keadaan, dimana semakin tinggi kelembaban maka konsentrasi CO akan tinggi.

2.12 State of Art

Berikut ini merupakan penelitian prediksi yang pernah dilakukan sebelumnya yang digunakan sebagai referensi untuk mengerjakan penelitian ini.

Tabel 2.6 Daftar Penelitian Sebelumnya

Peneliti	Output	Metode	Hasil
Wei-Zhen Lu & Wen Jian Wang (2004) (W. Lu et al., 2002)	Prediksi Udara di Hongkong	<i>Support Vector Machine</i> (SVM)	SVM menyediakan alternatif yang menjanjikan dan keuntungan dalam deret waktu ramalan cuaca. Ini menawarkan beberapa keuntungan dibandingkan dengan jaringan syaraf umpan balik RBF konvensional.
M. A. Agmalaro, I. S. Sitanggang, L. S. Hasibuan, M. M. Ramadhan (2018)	Prediksi Konsentrasi Polutan Kabut Asap Kebakaran	<i>Support Vector Regression</i> (SVR)	Berhasil memprediksi konsentrasi polutan CO dan CO ₂ . Model terbaik untuk memprediksi CO didapatkan dengan menggunakan kernel RBF ketika parameter gamma 20 yang menghasilkan RMSE $1,1742 \times 10^{-8}$ dan nilai koefisien korelasi sebesar 0,5879 dengan menggunakan data konsentrasi polutan CO dan CO ₂ dari kabut asap kebakaran lahan gambut Sumatra pada tanggal 22 s/d 25 September 2015.

Tabel 2.7 Daftar Penelitian Sebelumnya (Lanjutan)

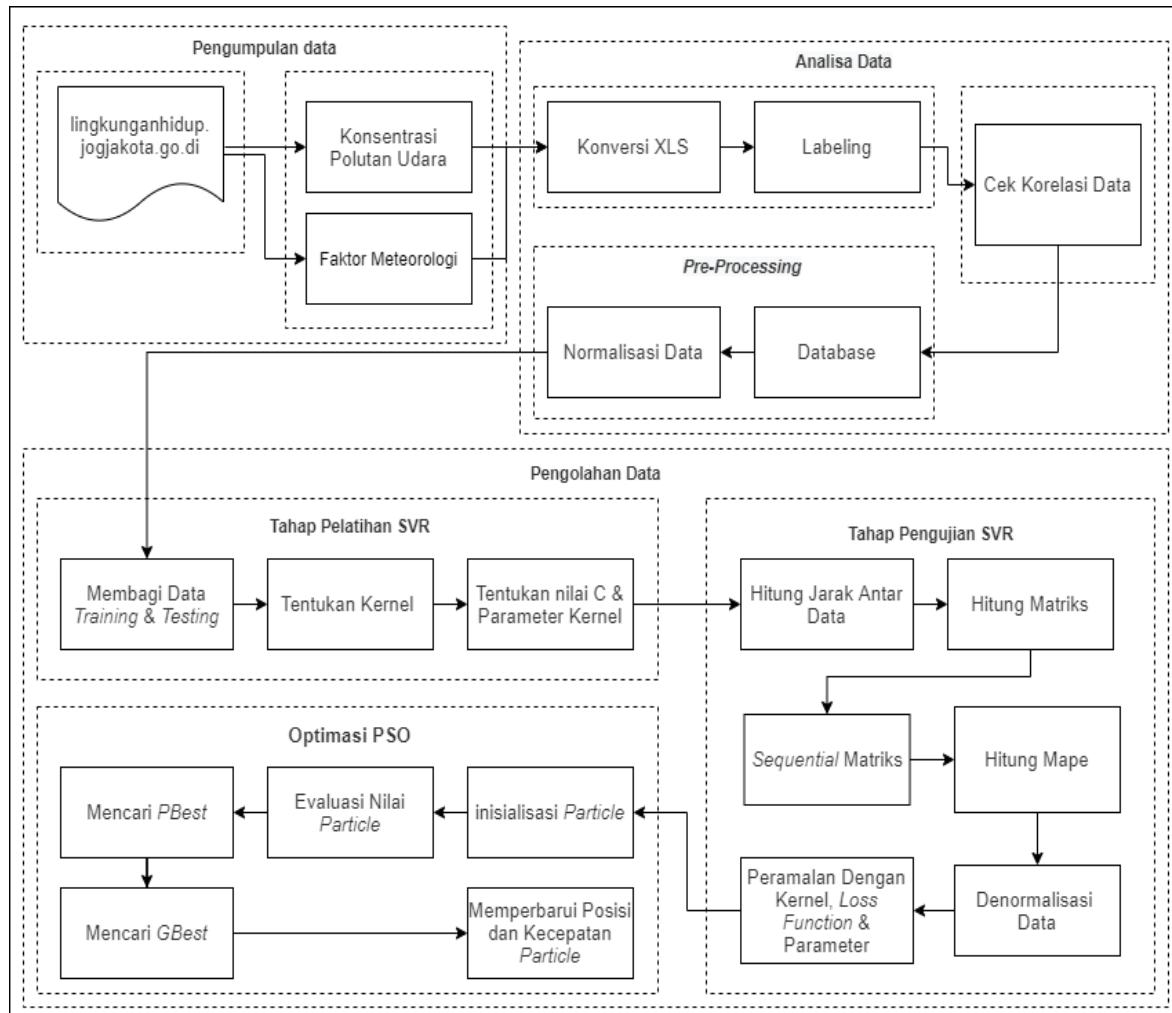
Peneliti	Output	Metode	Hasil
S. S. Ganesh, S. H. Modali, S. R. Palreddy, Dr. Arulmozhivarman P (2017)	Prediksi Indeks Kualitas Udara Kota Delhi	<i>Support Vector Regression (SVR)</i> dan <i>Model Linier</i>	Model SVR mengungguli model linier lainnya. SVR membuat <i>hyperplane</i> untuk mengubah batas dimensi ke dalam ruang dimensi yang lebih tinggi sehingga, untuk membuat pemisah sampel data yang meningkatkan akurasi regresi jauh lebih mudah. Kesalahan generalisasi akan berkurang dalam kasus SVR.
S. S. Ganesh, S. H. Modali, S. R. Palreddy, Dr. Arulmozhivarman P (2017)	Prediksi Indeks Kualitas Udara Kota Delhi	<i>Support Vector Regression (SVR)</i> dan <i>Model Linier</i>	Model SVR mengungguli model linier lainnya. SVR membuat <i>hyperplane</i> untuk mengubah batas dimensi ke dalam ruang dimensi yang lebih tinggi sehingga, untuk membuat pemisah sampel data yang meningkatkan akurasi regresi jauh lebih mudah. Dengan ini, kesalahan generalisasi akan berkurang dalam kasus SVR.
Aditya Hermawan, (2019)	Indeks Kualitas Udara Kota DKI Jakarta	<i>Support Vector Machine (SVM)</i> dengan <i>kernel radial basis function (RBF)</i>	Hasil pengujian prediksi kualitas udara memiliki akurasi yang cukup tinggi, yaitu diatas 87% di setiap daerah yang di teliti.
Muhammad Rusdi (2017)	Prediksi Suhu Udara Di Kota Banjarmasin	<i>Support Vector Machine</i> Dengan <i>Particle Swarm Optimization</i>	Algoritma <i>Support Vector Machines</i> berbasis PSO hasilnya RMSEnya lebih rendah dibandingkan dengan <i>Support Vector Machines</i> tanpa optimasi. Hasil RMSE untuk SVM adalah 0,991.Sedangkan Hasil RMSE SVM-PSO adalah 0,900.
J. Murillo-Escobar, J. P. Sepulveda-Suescun, M. A. Correa, D. Orrego-Metaute (2019)	Prediksi Konsentrasi Polusi Udara	<i>Support Vector Regression (SVR)</i> dengan <i>Particle Swarm Optimization</i>	Dalam perbandingan metodenya, SVR-PSO dan Feedforward Neural Networks (FANN), metode SVR-PSO secara statistic lebih baik dari pada metode FANN.

BAB III

METODOLOGI PENELITIAN DAN PERANCANGAN SISTEM

3.1 Metodologi Penelitian

Metode penelitian kuantitatif, metode ini merupakan metode ilmiah karena sesuai dengan kaidah ilmiah yaitu spesifik / pengalaman, obyektif, terukur, wajar dan sistematis. Cara ini disebut juga metode konfirmasi karena dapat digunakan untuk membuktikan. Berikut merupakan metode penelitian yang disajikan seperti pada Gambar 3.1.



Gambar 3.1 Tahapan penelitian

3.1.1 Pengumpulan data

Data merupakan salah satu hal terpenting dalam penelitian. Tanpa data, penelitian tidak dapat dilakukan. Penelitian perlu mengolah data sehingga menjadi informasi yang dapat membantu pengambilan keputusan atau menghasilkan teori. Oleh karena itu, data yang dibutuhkan untuk penelitian harus dikumpulkan terlebih dahulu. Proses pengumpulan data dilakukan dengan cara mengunduh dan meminta langsung data konsentrasi polutan kota Yogyakarta dan data faktor meteorologi kota Yogyakarta dari dinas lingkungan hidup dan kehutanan (DLHK) kota Yogyakarta dan website lingkunganhidup.jogjakota.go.id yang bersifat data terbuka. Data yang didapatkan adalah data konsentrasi polutan Yogyakarta 1 Januari 20 sampai dengan 26 Juli 2021 dalam bentuk pdf yang berjumlah 573 data

konsentrasi polutan dan faktor. Tabel 3.1 merupakan contoh dari hasil penyatuan dua parameter tersebut.

Tabel 3.1 Contoh Hasil Penyatuan Konsentrasi Polutan dan Faktor Meteorologi

Waktu	PM10	CO	SO2	O3	Kecepatan Angin	Arah Angin	Kelembaban	Suhu	Tekanan Udara	Solar Radiation	Curah Hujan
01/01/2020	28	84	2	19	2	73	93	24	1000	10	6
02/01/2020	17	54	2	33	2	158	84	27	999	67	5
03/01/2020	12	84	2	18	2	190	85	27	997	44	7
04/01/2020	9	55	2	29	2	210	85	27	996	52	36
05/01/2020	9	79	3	0	1	173	91	26	996	37	8
06/01/2020	14	100	2	18	2	197	82	28	996	48	3
07/01/2020	9	49	3	0	2	215	88	26	996	52	32
08/01/2020	11	178	4	0	1	170	86	27	996	42	3
09/01/2020	14	81	4	5	1	148	82	28	995	51	1
10/01/2020	7	65	3	30	2	205	87	26	996	53	32
11/01/2020	8	43	2	16	2	224	83	27	997	65	17
12/01/2020	9	43	2	9	2	150	75	28	996	54	16
13/01/2020	12	41	2	8	2	195	73	29	995	58	0
14/01/2020	15	61	2	0	2	170	76	29	996	53	0
15/01/2020	21	70	2	25	1	233	79	29	997	55	0

3.1.2 Tahap analisis

Pada tahapan analisis adalah korelasi antar data konsentrasi polutan dan faktor meteorologi. Setiap parameter akan dihitung korelasinya yang bertujuan untuk mendapatkan nilai variabel dependen terhadap variabel independent.

3.1.2.1 Korelasi antar data

Korelasi antar data konsentrasi polutan dan faktor meteorologi dibagi menjadi beberapa bagian, yaitu konsentrasi PM10-Kecepatan angin, PM10-Arah angin, PM10-Kelembaban, PM10-suhu, PM10-Tekanan udara, PM10-Radiasi solar, PM10-Curah hujan, konsentrasi CO-Kecepatan angin, CO-Arah angin, CO-Kelembaban, CO-suhu, CO-Tekanan udara, CO-Radiasi solar, CO-Curah hujan. Tiap faktor meteorologi akan dihitung menggunakan persamaan 2.34 untuk mendapatkan hasil dari nilai korelasi. Berikut merupakan contoh hasil perhitungan korelasi data.

$$r_{xy} = \frac{31(85864.8125) - (\sum 543)(\sum 5225)}{\sqrt{31(11587) - 294849}\sqrt{31(920143) - 27301133}}$$

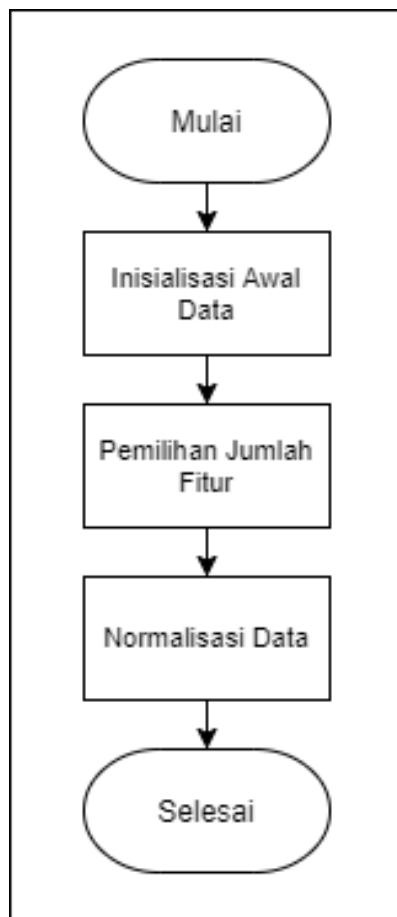
$$r_{xy} = -0.6251$$

3.1.3 Data preprocessing

Preprocessing dalam penelitian ini ada tiga tahapan, yaitu:

- Inisialisasi awal data
- Pemilihan jumlah fitur untuk dataset yang akan menjadi data *training* dan data *testing*
- Normalisasi data.

Contoh *flowchart* ditampilkan pada Gambar 3.2 seperti berikut:



Gambar 3.2 Flowchart data preprocessing

3.1.3.1 Inisialisasi awal data

Data diinisialisasikan berdasarkan data indeks polutan *CO* yang ada pada Tabel 3.1 tanggal 4 Januari 2020 sampai dengan 10 Januari 2020. Berikut merupakan data indeks polutan *CO* disajikan pada Tabel 3.2.

Tabel 3.2 Data Indeks Polutan CO

Tanggal	CO
4/01/2020	84
5/01/2020	50
6/01/2020	97
7/01/2020	70
8/01/2020	87
9/01/2020	118
10/01/2020	73

3.1.3.2 Pemilihan jumlah fitur

Pada pemilihan jumlah fitur, langkah pertama yang dilakukan adalah memilih jumlah fitur yang akan digunakan. Fitur yang digunakan merupakan data indeks polutan *co* hari sebelumnya yang ditandai dengan X_1 , X_2 , X_3 dan Y yang diartikan sebagai X_1 merupakan satu hari sebelum nilai aktual, X_2 merupakan dua hari sebelum nilai aktual, X_3 tiga hari sebelum

nilai aktual dan Y sebagai nilai aktual. Berikut merupakan hasil dari pemilihan fitur pada Tabel 3.3.

Tabel 3.3 Hasil Pemilihan Fitur

Tanggal	X_1	X_2	X_3	Y
4/01/2020	69	58	46	84
5/01/2020	58	46	84	50
6/01/2020	46	84	50	97
7/01/2020	84	50	97	70
8/01/2020	50	97	70	87
9/01/2020	97	70	87	118
10/01/2020	70	87	118	73

3.1.3.3 Normalisasi data

Pada tahap ini dilakukannya normalisasi agar data training dan data testing berada pada rentang yang sama sehingga kompleksitas perhitungan berkurang dan untuk mengurangi tingkat error dalam komputasi. Pada penelitian ini, nilai $x_{min} = 29$ dan $x_{max} = 139$. Contoh perhitungan normalisasi data *training* dan data *testing* seperti pada persamaan 2.30 sebagai berikut

$$x_1' = \frac{(x_1 - x_{min})}{(x_{max} - x_{min})}$$

$$x_1' = \frac{(84 - 50)}{(118 - 50)}$$

$$x_1' = 0,500$$

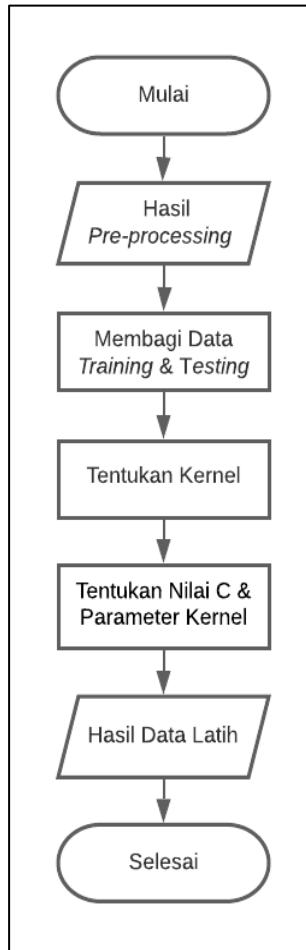
Hasil dari nilai normalisasi dilakukan sampai nilai konsentrasi polutan yang ingin dihitung selesai dan dicantumkan pada Tabel 3.4.

Tabel 3.4 Data Normalisasi Indeks Polutan CO

Tanggal	CO
4/01/2020	0,500
5/01/2020	0,000
6/01/2020	0,691
7/01/2020	0,294
8/01/2020	0,544
9/01/2020	1,000
10/01/2020	0,338

3.1.4 Pelatihan *Support Vector Regression*

Dalam tahapan ini akan membahas mengenai proses pelatihan dalam SVR. Hasil dari *preprocessing* yang disajikan pada Tabel 3.4 akan menjadi data yang dibagi menjadi data *training* dan data *testing* pada tahap ini. Pelatihan yang akan dilakukan dalam SVR memiliki beberapa tahapan proses diantaranya pembagian data *training* dan *testing* menentukan kernel, menentukan nilai C dan parameter kernel, serta hasil dari data pelatihan. Berikut merupakan *flowchart* dari tahapan pelatihan seperti pada Gambar 3.4.

**Gambar 3.4 Flowchart pelatihan SVR****3.1.4.1 Pembagian data *training* dan *testing***

Pada tahap ini, data dibagi menjadi dua jenis yaitu data *training* dan data *testing*. Penentuan data *training* dan data *testing* pada penelitian ini didapatkan setelah melakukan normalisasi data. Dengan contoh data *training* sebanyak 4 data (29 Januari 2020 s.d 01 Februari 2021) dan data *testing* pada tanggal 2 Februari 2021 s/d 4 Februari 2021 dengan format seperti pada Tabel 3.3. Berikut merupakan Tabel 3.5 yang berisikan data *training* dan Tabel 3.6 berisikan data *testing*.

Tabel 3.5 Data *Training* Untuk Pelatihan SVR

Tanggal	X_1	X_2	X_3	Y
29/01/2020	0,319	0,167	0,000	0,528
30/01/2020	0,167	0,000	0,528	0,056
31/01/2020	0,000	0,528	0,056	0,708
01/02/2020	0,528	0,056	0,708	0,333

Tabel 3.6 Data *Testing* Untuk Pelatihan SVR

Tanggal	X_1	X_2	X_3	Y
02/02/2020	0,056	0,708	0,333	0,569
03/02/2020	0,708	0,333	0,569	1,000
04/02/2020	0,333	0,569	1,000	0,375

3.1.4.2 Tentukan kernel

Menutur (Hsu et al., 2016) fungsi kernel yang direkomendasikan adalah fungsi kernel RBF, karena memiliki kinerja yang sama dengan kernel linier pada beberapa parameter, dan memiliki perilaku tertentu, seperti fungsi kernel tipe-S dengan parameter tertentu dan rentang nilai yang kecil [0,1].

3.1.4.3 Tentukan nilai C dan parameter kernel

parameter yang perlu ditentukan pada SVR adalah C , ε dan γ sebagai parameter kernel RBF, untuk inisialisasi partikel yang digunakan merupakan nilai *default* dari library *sklearn* yang dapat di lihat pada Tabel 3.7.

Tabel 3.7 Nilai C dan Parameter Kernel

C	ε	γ
1	0.1	1

3.1.4.4 Tentukan awal α_i dan α_i^*

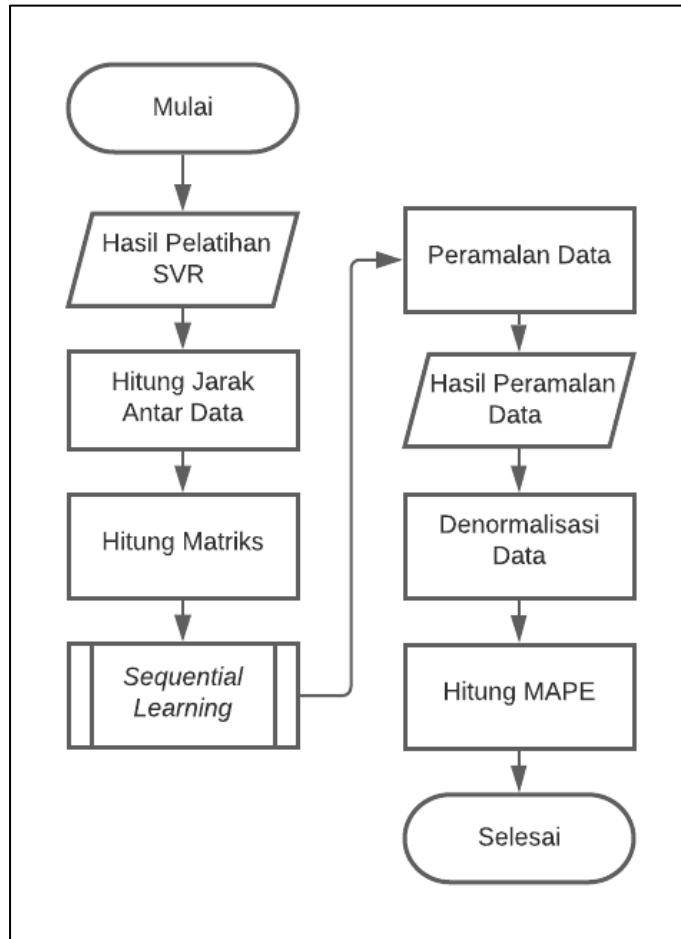
Tentukan nilai awal α_i dan α_i^* dari setiap data yang akan di ramalkan, data diinisialisasi sebagai 0 yang dapat di lihat pada Tabel 3.8.

Tabel 3.8 Inisialisasi Awal α_i dan α_i^*

I	α_i	α_i^*
1	0	0
2	0	0
3	0	0
4	0	0

3.1.5 Pengujian Support Vector Regression

Tahapan pengujian dilakukannya proses peramalan dari data yang dihasilkan dari tahapan pelatihan SVR. Dalam proses tahapan pengujian melakukan perhitungan jarak antar data ke data, hitung matriks, *sequential learning*, peramalan dan hasil peramalan, denormalisasi data serta menghitung nilai MAPE. Berikut disajikan *flowchart* dari tahap pengujian SVR seperti pada Gambar 3.4.



Gambar 3.4 Flowchart pengujian SVR

3.1.5.1 Hitung nilai jarak antar data

Perhitungan jarak antar data dilakukan untuk mengetahui jarak antara setiap data *training*. *Radial basis function* (RBF) merupakan fungsi yang digunakan untuk perhitungan jarak antar data. Berikut merupakan contoh perhitungan jarak antara data 1 dengan data 1 menggunakan persamaan RBF Tabel 2.4 dengan menggunakan data pada Tabel 3.6.

$$\begin{aligned}
 K(\vec{x}_i, \vec{x}_j) &= \exp(-1 \\
 &(\sqrt{(0,319 - 0,056)^2 + (0,167 - 0,708)^2 + (0,000 - 0,333)^2}^2 \\
 &= 0,688
 \end{aligned}$$

Lakukan perhitungan jarak antara data ke-*i* dengan *j* sampai dengan *n* dan data ke-*j* dengan *i* sampai dengan *n*.

3.1.5.2 Tentukan matriks

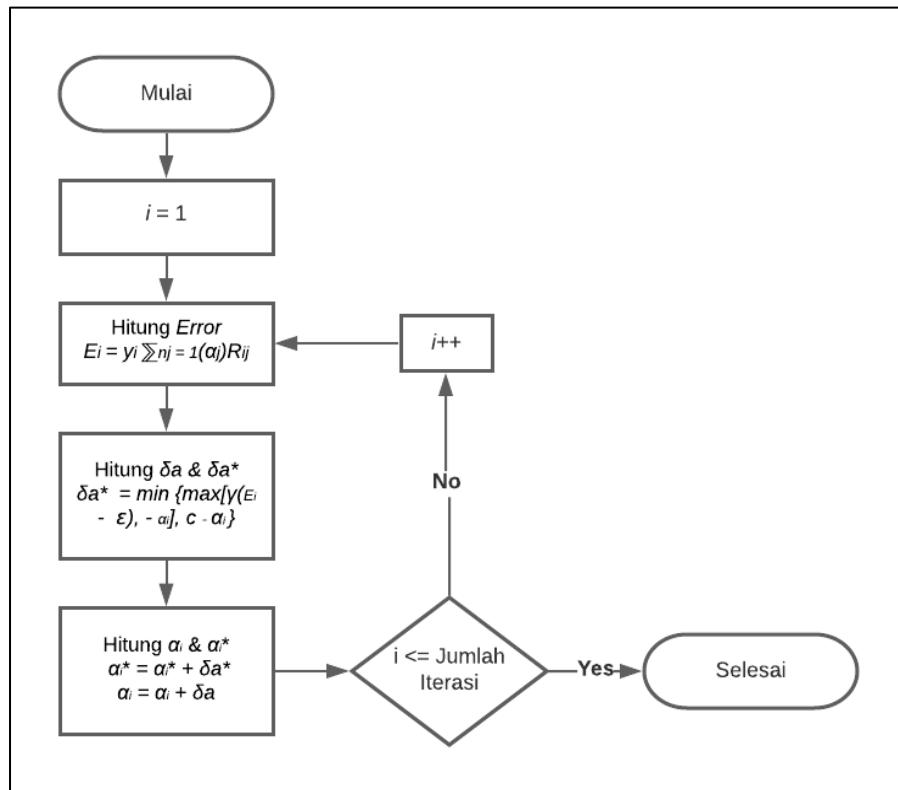
Setelah dilakukan perhitungan jarak antar data, maka didapatkan sebuah matriks *hessian* R_{ij} . Nilai dari matriks R_{ij} didapatkan dari hasil perhitungan nilai jarak antar data dengan menggunakan persamaan RBF pada Tabel 2.4. Hasil matriks R_{ij} dapat dilihat pada Tabel 3.9.

Tabel 3.9 Hasil Matriks Hessian $\gamma = 1$

i/j	1	2	3	4
1	0,688	0,597	0,959	0,513
2	0,753	0,668	0,544	0,896
3	0,313	0,670	0,404	0,735

3.1.5.3 Sequential learning

Sequential learning merupakan algoritma dalam SVR untuk penyelesaian masalah *non-linier*. Tahapan *sequential learning* dilakukan dengan melalui proses yang diantaranya menghitung nilai *error*, menghitung nilai δ_a dan δ_a^* , dan menghitung nilai α_i dan α_i^* . Dalam tahapan ini, i diinisialisasikan dengan nilai 1 dihitung sampai dengan jumlah iterasi yang ditentukan. Berikut merupakan *flowchart* dari *sequential learning* seperti pada Gambar 3.5.



Gambar 3.5 Flowchart Sequential Learning

Sequential learning memiliki beberapa langkah sebagai berikut.

a. Menghitung nilai E (*Error*)

Formulasi perhitungan nilai E (*Error*) seperti pada persamaan 2.20. Dilakukan setiap data latih, dan ulangi hingga kondisi berhenti terpenuhi. Berikut merupakan contoh perhitungan pada nilai E_i dengan $i = 1$.

$$E_1 = 0,528 + ((0)x0,319) + ((0)x0,167) + ((0)x0,000)$$

$$E_1 = 0,528 + 0$$

$$E_1 = 0,528$$

Lakukan perhitungan nilai E sampai dengan data E selesai seperti pada Tabel 3.10.

Tabel 3.10 Hasil Perhitungan E_i

i	E_i
1	0,528
2	0,056
3	0,708
4	0,333

b. Menghitung nilai δ_a dan δ_a^*

Setelah menghitung nilai *error* kemudian hitung nilai *variable* tunggal δ_a dan δ_a^* setiap data training seperti pada rumus 2.21 dan 2.22. Berikut merupakan contoh perhitungan δ_a dan δ_a^* dengan $i = 1$ pada persamaan 2.21 dan 2.22.

$$\delta_1 = \min \{ \max[1(1 - 0.528), -0], 1 - 0 \}$$

$$\delta_1 = 0.472$$

$$\delta_1^* = \min \{ \max[1(0.528 - 0.1), -0], 1 - 0 \}$$

$$\delta_1^* = 0,2545$$

Lakukan perhitungan nilai δ_a dan δ_a^* sampai dengan data δ_a dan δ_a^* selesai seperti pada Tabel 3.12.

Tabel 3.11 Hasil Perhitungan δ_a^* dan δ_a Pada Iterasi Pertama

i	δ_a	δ_a^*
1	0,472	0,428
2	0,944	0,000
3	0,292	0,608
4	0,667	0,233

c. Memperbarui nilai α_i dan α_i^*

Perhitungan untuk memperbarui nilai α_i dan α_i^* seperti pada persamaan 2.23 dan 2.24 menggunakan *variable* tunggal δ_a dan δ_a^* yang telah dihitung sebelumnya. Berikut merupakan contoh dari perhitungan persamaan 2.23 dan 2.24 dengan $i = 1$.

$$\alpha_1 = 0 + 0.472 = 0.472$$

$$\alpha_1^* = 0 + 0.428 = 0.428$$

Lakukan perhitungan nilai α_i dan α_i^* sampai dengan data α_i dan α_i^* selesai seperti pada Tabel 3.12.

Tabel 3.12 Hasil Perhitungan α_i^* dan α_i Pada Iterasi Pertama

i	α_i	α_i^*
1	0,472	0,428
2	0,944	0,000
3	0,292	0,608
4	0,667	0,233

3.1.5.4 Peramalan dengan kernel, loss function dan parameter

Pada tahap ini akan dilakukan peramalan data *testing* terhadap data yang telah ditraining sebelumnya. Fungsi peramalan dilakukan berdasarkan persamaan 2.19 dengan α_i dan α_i^* yang telah didapatkan sebelumnya.

$$f(x) = \sum_{i=1}^4 (\alpha_i - \alpha_i^*) \Phi(x_i, x)$$

$$f(x) = ((0.472 - 0.428)\Phi(x_1, x)) + ((0.944 - 0.000)\Phi(x_2, x)) + ((0.292 - 0.608)\Phi(x_3, x)) + ((0.667 - 0.233)\Phi(x_4, x))$$

$$f(x) = ((0.044)(0.688) + (0.944)(0.597) + (-0.316)(0.959) + (0.434)(0.513))$$

$$f(x) = 0,513$$

Pada Tabel 3.13 berikut merupakan hasil fungsi dari peramalan data *training* dan data *testing*.

Tabel 3.13 Hasil Fungsi Peramalan Data Training Ke Data Testing

Data ke-	$f(x)$	$Y(actual)$
1	0,513	0,569
2	0,880	1,000
3	0,837	0,375

3.1.5.5 Denormalisasi data

Pada tahap ini dilakukannya proses denormalisasi data untuk mengembalikan nilai data ke nilai yang semula menggunakan persamaan 2.31. Contoh perhitungan dapat dilihat sebagai berikut.

$$x = 0,1665(139 - 29) + 29$$

$$x = 47,3150$$

Pada Tabel 3.14 berikut merupakan hasil fungsi dari peramalan yang telah di denormalisasi.

Tabel 3.14 Hasil Denormalisasi

Data ke-	$f(x)$	$f(x)$ Denormalisasi	$Y(actual)$
1	0,513	84,884	87
2	0,880	109,84	118
3	0,837	106,916	73

3.1.5.6 Hitung MAPE

Perhitungan *Mean Absolute Percentage Error* (MAPE) merupakan evaluasi SVR yang dilakukan untuk menghitung tingkat *error* yang dihasilkan dari model SVR. Berikut merupakan contoh perhitungan dari persamaan 2.32.

$$\begin{aligned} MAPE &= \left(\frac{1}{3} \left(\left| \frac{87-84,884}{87} \right| + \left| \frac{118-109,840}{118} \right| + \left| \frac{73-106,916}{73} \right| \right) \right) \times 100 \\ &= 0,117 \times 100 \\ &= 11,7\% \end{aligned}$$

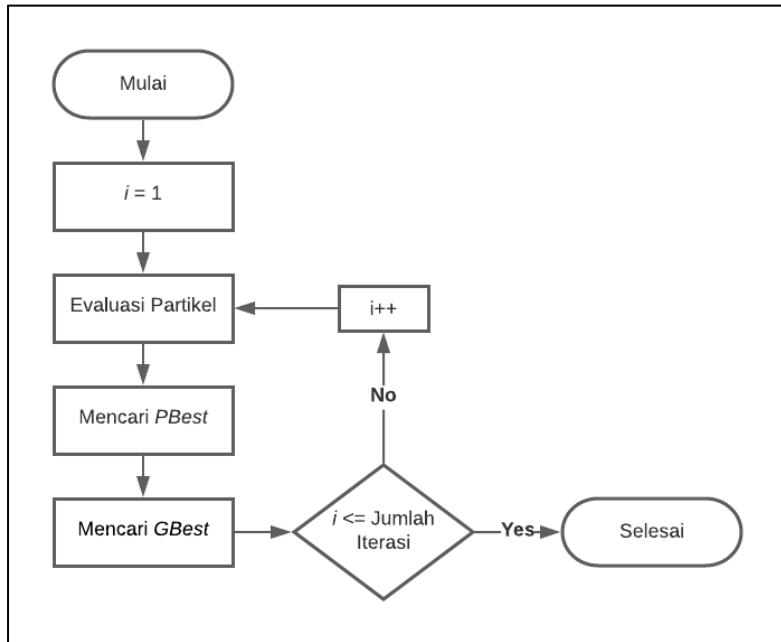
3.1.5.7 Hitung MAE

Perhitungan *Mean Absolute Error* (MAE) merupakan evaluasi SVR yang dilakukan untuk menghitung rata-rata *error* yang dihasilkan dari model SVR setiap data. Berikut merupakan contoh perhitungan dari persamaan 2.34.

$$\begin{aligned} MAE &= \left(\frac{1}{3} |84,884 - 87| + |109,840 - 118| + |106,916 - 73| \right) \\ &= 23,64 \end{aligned}$$

3.1.6 Optimasi Particle Swarm Optimization

Dilakukannya optimasi parameter bertujuan untuk menemukan parameter terbaik yang dapat memberikan hasil yang lebih baik. Proses ini meliputi beberapa tahapan yaitu inisialisasi partikel, evaluasi partikel, mencari nilai personal best (Pbest), mencari global best (GBest), dan memperbarui posisi dan kecepatan jumlah tiap partikel. Untuk mengoptimalkan penggunaan particle swarm optimization (PSO), langkah pertama yang dilakukan adalah membentuk rangkaian partikel yang terdiri dari gamma (γ) dan C yang membentuk range partikel. Pada Gambar 3.6 merupakan flowchart dari tahapan optimasi PSO.



Gambar 3.6 Flowchart optimasi PSO

Nilai batas atas dan batas bawah dari pembentukan awal *range* partikel dapat dilihat pada Tabel 3.15.

Tabel 3.15 Range Partikel

Batas	γ	C	ε
Bawah	0,001	0,1	0,1
Atas	1	10	1

Output dari *range* partikel pada Tabel 3.16 adalah nilai parameter dari uji kernel SVR. *Particle Swarm Optimization* dilakukan dalam beberapa proses prosedur setelah *range* partikel terbentuk.

3.1.6.1 Inisialisasi partikel

Inisialisasi partikel untuk menentukan nilai awal setiap partikel, dan nilai awal tersebut akan dievaluasi berdasarkan nilai *fitness*. Misalnya, menggunakan jumlah partikel yang sama dengan tiga untuk inisialisasi maka didapatkan:

$$\gamma_1 = 0.01, \gamma_2 = 0.1, \gamma_3 = 1$$

Nilai awal setiap partikel ditentukan secara acak sesuai dengan batasan yang ada pada Tabel 3.34.

3.1.6.2 Evaluasi partikel

Evaluasi partikel untuk menentukan nilai *fitness* setiap partikel relatif terhadap fungsi yang digunakan. Partikel tersebut akan dievaluasi terhadap fungsi kernel di SVR untuk mendapatkan partikel tersebut. Misal dilakukan perhitungan untuk x_i, i pada iterasi ke-1 dalam fungsi kernel *radial basis function* (RBF) seperti yang ada pada persamaan RBF Tabel 2.4.

$$\begin{aligned}
 K(\vec{x}_i, \vec{x}_j) &= \exp(-0.01 \\
 &\quad (\sqrt{(0,319 - 0,319)^2 + (0,167 - 0,167)^2 + (0,000 - 0,000)^2})^2 \\
 &= \exp(-0.01(0)) = 1
 \end{aligned}$$

Fungsi kernel dilakukan untuk mendapatkan nilai yang akan digunakan dalam perhitungan *MAPE*, sehingga didapatkan $MAPE = 11,7\%$ untuk $\gamma = 0.01$, $MAPE = 27,7\%$ untuk $\gamma = 0.1$ dan $MAPE = 26,9\%$.

3.1.6.3 Mencari *Pbest*

Mencari (*Personal Best*) *Pbest* dengan membandingkan nilai *Pbest* sebelum dan sesudah iterasi. Jika nilai *fitness* dari partikel baru lebih baik dari nilai *fitness* *Pbest* sebelumnya maka nilai partikel baru tersebut adalah *Pbest*. Pada iterasi pertama, nilai *Pbest* adalah nilai dari partikel itu sendiri. Maka didapatkan hasil $Pbest_1 = 0.01$, $Pbest_2 = 0.1$ dan $Pbest_3 = 1$.

3.1.6.4 Mencari *Gbest*

Nilai (*Global Best*) *Gbest* didapat dari partikel dengan nilai *fitness* terbaik. Jika *Pbest* diperoleh dengan membandingkan nilai partikel pada iterasi saat ini dengan iterasi sebelumnya, maka nilai *Gbest* diperoleh dari perbandingan nilai *Pbest* masing-masing partikel. Maka didapatkan *Gbest* = 1.

3.1.6.5 Memperbarui posisi dan kecepatan partikel

Perbarui kecepatan dan posisi partikel dengan menggunakan persamaan 2.25 dan 2.26. Sehingga didapatkan hasil sebagai berikut:

untuk $i = 1$

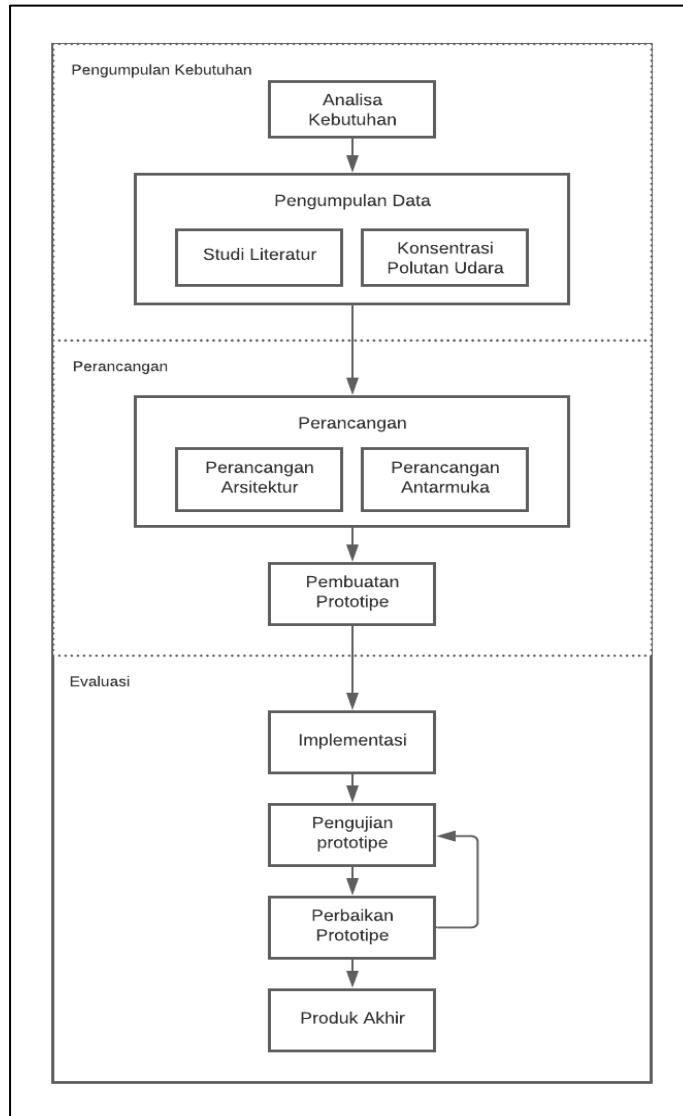
$$v_1(1) = 0.9 \times 0 + 0.1 \times 1(0.01 - 0.319) + 0.2 \times 1 (0.1 - 0.319) = -0,074$$

$$X_1(1) = 0.319 + -0,074 = 0.245$$

Lakukan langkah 3.1.5.1 sampai 3.1.5.5 hingga nilai i tidak kurang dari jumlah iterasi.

3.2 Metode Pengembangan Sistem

Metode yang digunakan dalam pengembangan sistem dalam penelitian ini adalah metode pengembangan sistem prototipe. Tahap metode pengembangan sistem prototipe melalui pengumpulan kebutuhan, perancangan (*design*), evaluasi. Pengumpulan kebutuhan dilakukan untuk komunikasi dan pertemuan atau diskusi kelompok untuk menentukan tujuan keseluruhan, persyaratan yang diharapkan, dan deskripsi bagian-bagian yang dibutuhkan selanjutnya. Pada saat yang sama, rincian persyaratan mungkin tidak dibahas pada tahap ini, tetapi pada tahap selanjutnya. Kemudian, tahapan perancangan dilakukan dengan cepat dan desain mewakili aspek perangkat lunak yang diketahui. Kemudian desain ini menjadi dasar pembuatan prototipe. Setelah itu evaluasi dilakukan melakukan evaluasi prototipe dan telah digunakan untuk mengevaluasi kebutuhan perangkat lunak. Berikut merupakan *flowchart* dari pengembangan sistem pada Tabel 3.7.



Gambar 3.7 Metode pengembangan sistem

3.2.1 Pengumpulan kebutuhan

Pada bagian ini akan dibahas kebutuhan berupa data dan informasi yang akan dianalisis. Pengumpulan kebutuhan meliputi beberapa tahapan yaitu analisis dan pengumpulan data dan analisis kebutuhan sistem.

3.2.1.1 Analisis dan pengumpulan kebutuhan

Pada tahapan ini akan dilakukan analisis dan pengumpulan ada yang akan dibutuhkan dalam pengembangan sistem. Analisis data dilakukan dengan membaca studi literatur yang terkait dengan penelitian dan dijadikan pedoman yang bisa dipertanggung jawabkan. Setelah analisis data didapatkan data yang dibutuhkan dengan cara mengunduh dan meminta data konsentrasi polutan kota Yogyakarta dan faktor meteorologi tersebut dari Dinas Lingkungan Hidup kota dan website resmi www.lingkunganhidup.jogjakota.go.id yang akan digunakan sebagai data yang dibutuhkan didalam sistem.

3.2.1.2 Analisis kebutuhan sistem

Bagian ini akan menganalisis kebutuhan yang dibutuhkan untuk mengembangkan sistem untuk penelitian ini. Tujuan dari analisis ini adalah untuk mendefinisikan masalah dan mempersiapkan sistem sehingga kendala terkait sumber daya dapat diminimalkan. Analisis kebutuhan sistem dibagi menjadi dua bagian, yaitu kebutuhan fungsional dan kebutuhan non fungsional.

a. Analisis kebutuhan fungsional

Pada tahapan ini merupakan kebutuhan yang berhubungan langsung dengan sistem. Kebutuhan fungsional akan berisi gambaran umum dari keseluruhan proses yang dapat dilakukan sistem, dan berisi informasi apa pun yang harus ada dan dihasilkan oleh sistem. Berikut ini adalah kebutuhan fungsional yang akan dijalankan oleh sistem:

1. Sistem dapat melakukan proses pembuatan model dengan metode *Support Vector Regression* dengan pengoptimalan *Particle Swarm Optimization*.
2. Sistem dapat melakukan proses *training* dan *testing* menggunakan metode *Support Vector Regression* dengan pengoptimalan *Particle Swarm Optimization*.
3. Sistem dapat memprediksi konsentrasi polusi udara kota Yogyakarta.
4. Sistem dapat membuat grafik prediksi konsentrasi polusi udara kota Yogyakarta.
5. Sistem dapat menampilkan hasil prediksi konsentrasi polusi kota Yogyakarta.
6. Sistem dapat menampilkan korelasi data konsentrasi dan data faktor meteorologi.

b. Analisis kebutuhan fungsional

Kebutuhan non-fungsional merupakan kebutuhan yang tidak berkaitan langsung dengan fitur yang ada pada sistem. Pada kebutuhan non-fungsional ini terdiri dari kebutuhan perangkat keras dan perangkat lunak.

1. Perangkat Keras

Perangkat keras yang dibutuhkan untuk mengembangkan sistem pada penelitian ini memiliki spesifikasi seperti pada Tabel 3.16.

Tabel 3.16 Kebutuhan Perangkat Keras

No	Perangkat Keras	Keterangan
1	Processor	AMD FX-7500 Radeon R7
2	RAM	8GB DDR3
3	Storage	Harddisk 1TB & SSD 128GB
4	Graphic	AMD Radeon (TM) R7 Graphics
5	Perangkat I/O	Keyboard, Mouse dan Monitor
6	Koneksi Internet	Wifi dan kuota internet

2. Perangkat Lunak

Adapun perangkat lunak yang dibutuhkan untuk mengembangkan sistem pada penelitian ini dapat dilihat pada Tabel 3.17.

Tabel 3.17 Kebutuhan Perangkat Lunak

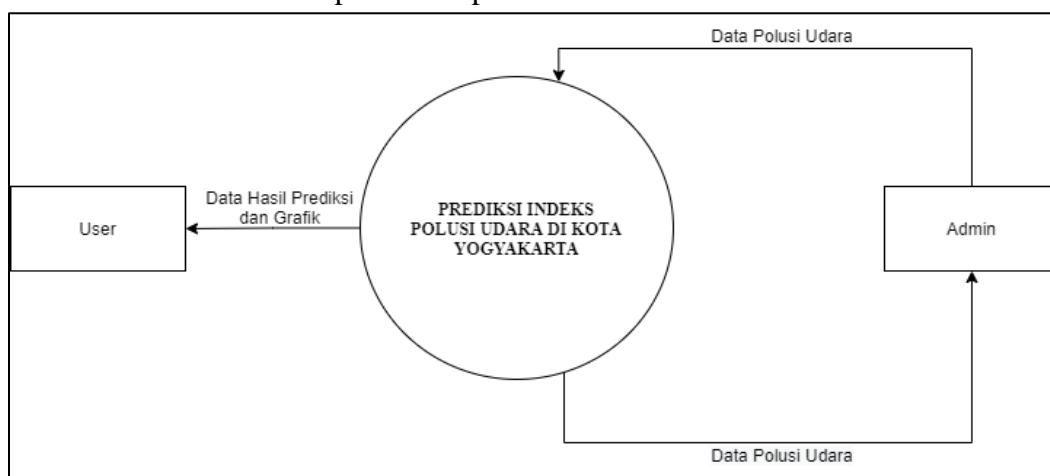
No	Perangkat Lunak	Keterangan
1	<i>Operating System</i>	Windows 10 Pro 64 bit
2	<i>Python</i>	Bahasa pemrograman
3	<i>Spyder 5</i>	<i>Code Editor</i>
4	<i>Jupyter Notebook</i>	<i>Code Editor</i>
5	<i>Lucid.app</i>	Website untuk membuat desain diagram
6	Microsoft Excel	Perangkat lunak tempat dataset
7	Chrome	<i>Web Browser</i>

3.2.2 Perancangan Sistem

Pada tahap ini akan dibahas perancangan sistem yang akan dibangun. Rancangan yang akan dilakukan dalam pengembangan sistem prediksi konsentrasi polutan udara di Yogyakarta meliputi desain arsitektur sistem, desain proses, desain antarmuka dan desain pengujian.

3.2.2.1 Data flow diagram level 0

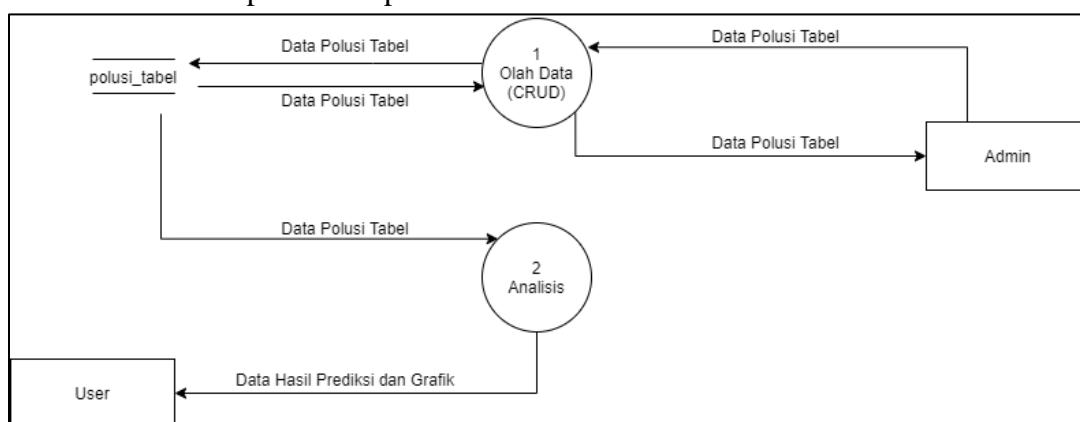
DFD level 0 merupakan analisis dari prediksi indeks polusi udara di kota Yogyakarta yang terdapat dua entitas yaitu admin dan *user*. Pada entitas user terdapat informasi dari prediksi polutan udara. Sedangkan entitas admin terdapat aliran yang masuk dan keluar yaitu *login* admin, input data polusi udara dan informasi data analisis prediksi polutan udara. DFD level 0 dapat dilihat pada Gambar 3.8.



Gambar 3.8 DFD level 0

3.2.2.2 Data flow diagram level 1

DFD level 1 merupakan gambaran terhadap proses dari system yang akan dibuat. Pada DFD level 1 terdapat dua proses dalam diagram yaitu proses olah data dan analisis. Pada proses olah data menjelaskan admin melakukan *input* data agar data *input* tersebut bisa masuk kedalam *database*. Data dalam *database* dapat dihapus dan ditambahkan oleh admin. Kemudian proses analisis merupakan hasil dari analisis data yang telah *diinputkan* oleh admin yang dapat dilihat pada *interface* user yang berisikan prediksi dan grafik dari polutan udara. DFD level 1 dapat dilihat pada Gambar 3.9.



Gambar 3.9 DFD level 1

3.2.2.3 Struktur tabel database

Database dalam pembangunan sistem ini hanya menggunakan satu tabel yang berisikan data konsentrasi polutan udara dan konsentrasi polutan udara. Tabel ini terdiri dari sepuluh atribut. Struktur tabel dapat dilihat pada tabel 3.18.

Tabel 3.18 Struktur Tabel Polusi Udara

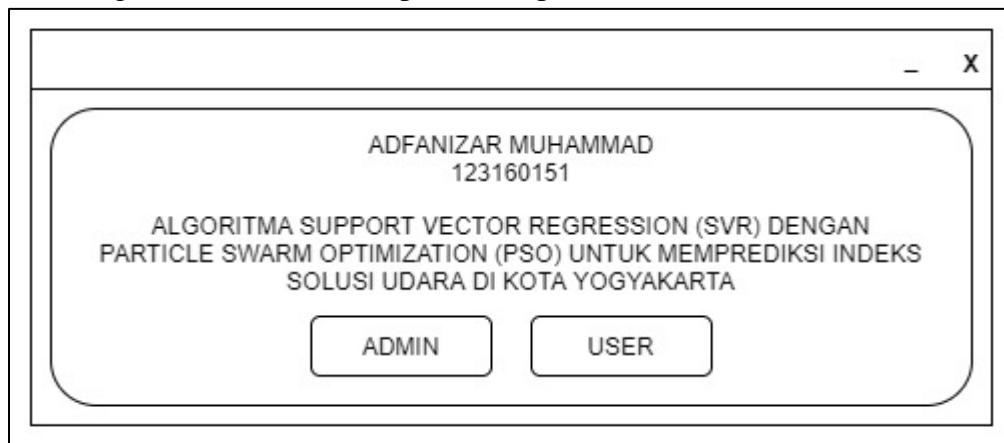
No	Nama Field	Tipe Data	Keterangan
1	Waktu	TEXT	Tanggal konsentrasi & faktor polutan udara
2	PM10	INTEGER	Konsentrasi udara
3	CO	INTEGER	Konsentrasi udara
4	KecepatanAngin	INTEGER	Faktor meteorologi
5	ArahAngin	INTEGER	Faktor meteorologi
6	Kelembapan	INTEGER	Faktor meteorologi
7	Suhu	INTEGER	Faktor meteorologi
8	TekananUdara	INTEGER	Faktor meteorologi
9	SolarRadiation	INTEGER	Faktor meteorologi
10	CurahHujan	INTEGER	Faktor meteorologi

3.2.2.4 Perancangan antarmuka

Bagian ini akan membahas hal-hal yang berkaitan dengan desain antarmuka sistem. Perancangan antarmuka sistem penelitian meliputi struktur menu dan *user interface* (UI). Desain struktur menu untuk mendeskripsikan menu dan submenu yang terdapat dalam sistem, dan desain UI untuk mendeskripsikan antarmuka sistem.

a. Perancangan halaman utama

Halaman utama merupakan tampilan yang akan menampilkan halaman *home* yang berisikan tombol judul dan identitas pembuat program serta dua tombol, yaitu admin dan *user*. Perancangan halaman utama dapat dilihat pada Gambar 3.10.



Gambar 3.10 Halaman utama

b. Perancangan halaman login

Halaman ini merupakan *login* admin yang berisikan dua *field*, yang pertama *field username* dan *field password*. *Username* dan *password* admin pada program ini telah dirancang di dalam program.

Gambar 3.11 Halaman *login*

c. Perancangan *input* data admin

Setelah admin berhasil *login* maka akan tampil halaman *input* dan rekap data. Halaman ini berisikan jumlah data yang ditampilkan dalam tabel dan input data yang berjenis tabel. Kemudian pada halaman ini terdapat tiga tombol, yaitu *input*, *delete* dan *back to menu*. Yang dimana data tersebut dapat di-*input*-kan dan dihapus serta dapat kembali ke halaman utama.

Gambar 3.12 Halaman *input* data admin

d. Perancangan halaman *user*

Halaman ini merupakan halaman setelah tombol *user* pada halaman utama ditekan. Berisikan satu tabel, dua tombol dan tiga *field*. Tabel berisikan hasil dari penelitian yang telah dibangun. Kemudian *field* berisikan best parameter dalam penelitian dan tombol grafik akan memunculkan halaman grafik. Perancangan halaman *user* di tampilkan pada Gambar 3.13.

Gambar 3.13 Halaman user

e. Perancangan halaman grafik

Halaman ini memiliki dua *field* yang berfungsi menampilkan gambar dari hasil prediksi. Gambar tersebut akan muncul berbeda-beda ketika tombol disamping *field* pertama ditekan. Perancangan halaman grafik seperti berikut.

PM10	GRAFIK
PM10, CO	
PM10, CO, MF1	
PM10, CO, MF2	
PM10, CO, MF3	
PM10, CO, MF4	
PM10, CO, MF5	
PM10, CO, MF6	

Gambar 3.14 Halaman grafik

3.2.3 Pengujian parameter

Pada pengujian parameter, setiap parameter konsentrasi polutan udara dan faktor meteorologi akan dihitung korelasinya dengan tujuan mendapatkan nilai kesesuaian variabel independent dan variabel dependen. Korelasi data dihitung sebanyak jumlah parameter konsentrasi udara dan parameter faktor meteorologi. Hasil perhitungan persamaan 2.34 akan dituliskan pada Tabel seperti Tabel 3.19 berikut.

Tabel 3.19 Tabel Perhitungan Korelasi PM10 dan CO dengan Faktor Meteorologi

Konsentrasi Polutan	Faktor Meteorologi						
	Kecepatan Angin	Arah Angin	Kelembapan	Suhu	Tekanan Udara	Solar Radiation	Curah Hujan
PM10							
CO							

Kemudian untuk mengetahui kombinasi parameter konsentrasi udara dan faktor meteorologi yang paling baik, maka akan dilakukan perbandingan nilai MAPE dan MAE dari masing-masing hasil kombinasi. Hal ini dilakukan untuk mengetahui nilai tertinggi dan terendah MAPE dan MAE yang dihasilkan dari kombinasi parameter. Hasil kombinasi dapat dilihat pada Tabel 3.20.

Tabel 3.20 Tabel Pengujian Kombinasi Parameter

BAB IV

HASIL, PENGUJIAN DAN PEMBAHASAN

Pada bab ini akan menjelaskan mengenai implementasi dari hasil rancangan yang telah dibangun sebelumnya. Pembahasan ini akan mengetahui bahwa system yang telah dibangun telah mencapai tujuan yang diinginkan berdasarkan analisis dan perancangan yang telah dilakukan.

4.1 Hasil Penelitian

Berikut merupakan bagian yang akan membahas hasil implementasi dari rancangan yang telah dibangun sebelumnya. Hasil penelitian ini akan dibagi menjadi dua bagian yaitu implementasi prediksi polutan dan implementasi aplikasi.

4.1.1 Modul korelasi data

Nilai korelasi data didapatkan dari persamaan 2.34. Persamaan ini dituliskan dalam pseudocode Algoritma 1 yang diinisialisasikan dengan variabel N sebagai banyak data X atau data Y , kemudian variabel X sebagai variabel independent dan variabel Y sebagai variabel dependen. Variabel disubstitusikan ke dalam persamaan korelasi data.

Algoritma 1: Fungsi Korelasi Data

```
1  FUNCTION korelasi-data
2  REQUIRE : N : banyak data X atau Y
3  REQUIRE : X : data array variabel X
4  REQUIRE : Y : data array variabel Y
5
6      //korelasi data
7
8       $r \leftarrow N \sum XY - (\sum X)(\sum Y) / \sqrt{\{N \sum X^2 - (\sum X)^2\}\{N \sum Y^2 - (\sum Y)^2\}}$ 
9      return r;
```

4.1.2 Modul preprocessing

Pseudocode pada Algoritma 2 merupakan langkah-langkah dari pembuatan tiga periode deret waktu. Contohnya bila memiliki data harian runtut pada satu kolom, maka dengan pseudocode ini dapat membuat tiga periode deret waktu sebelum nilai aktualnya seperti satu hari sebelum kejadian (x_1), dua hari sebelum kejadian (x_2), dan tiga hari sebelum kejadian.

Algoritma 2: Deret Waktu

```
1  FUNCTION deret-waktu
2  REQUIRE : x1 : banyak data
3  REQUIRE : temp, x : variabel tampung
4
5      for i=(1 to len(x1)) do
6          if i > 2 do
7              temp.append(x1[i-3][1])    //tiga hari sebelum
8              temp.append(x1[i-2][1])    //dua hari sebelum
9              temp.append(x1[i-1][1])    //satu hari sebelum
10             x.append(temp)        //gabungkan data
11             return x;
```

Kemudian Algoritma untuk memisahkan antara data *training* dan data *testing* diproses seperti pada pseudocode Algoritma 3. Pada penelitian ini menggunakan 80% data

training dan 20% data *testing* yang berformat tanggalan urut. Berikut merupakan Algoritma 3 yang berisikan fungsi memisahkan data *training* dan data *testing*.

Algoritma 3: Pisah Data Training dan Data Testing

```

1  FUNCTION training-testing
2  REQUIRE : n : banyak data
3  REQUIRE : x_train : data train x
4  REQUIRE : y_train : data train y
5  REQUIRE : x_test : data test x
6  REQUIRE : y_test : data test y
7
8      train_index ← (0.8*len(n))
9      x_train, x_test ← nx[:train_index],nx[train_index:]
10     y_train, y_test ← ny[:train_index],ny[train_index:]

```

4.1.3 Modul SVR

Algoritma 4 yang berisikan fungsi proses *support vector regression* (SVR) untuk Menyusun nilai parameter, *training*, *testing*. Pada program SVR ini memanfaatkan *library* yang ada pada *scikit-learn*. Dalam melakukan penyusunan nilai gamma menggunakan fungsi SVR () berisikan parameter gamma, complexity, epsilon yang parameternya bernilai *default*, gamma = 1, complexity = 1 dan epsilon = 0,1.

Pada proses *training* dilakukan dengan memanggil fungsi *svr_reg.fit()* dengan melamparkan fungsi yang berisikan data input *training* dan *testing*. Kemudian untuk proses *testing* fungsi yang dipanggil adalah *svr_reg.predict()* dengan melemparkan fungsi yang berisikan data input *testing*. Kemudian hasil prediksi dan model di-*return*-kan.

Algoritma 4: SVR

```

1  FUNCTION svr
2  REQUIRE : n : banyak data
3  REQUIRE : x_train : data train x
4  REQUIRE : y_train : data train y
5  REQUIRE : x_test : data test x
6
7      svr_reg ← SVR()    //library svr dalam scikit-learn
8      svr_reg.fit(x_train, y_train)
9      svr_y_predict ← svr_reg.predict(x_test)
10     return svr_reg, svr_y_predict

```

4.1.4 Particle swarm optimization

Modul *particle swarm optimization* (PSO) adalah modul optimasi parameter yang terdapat pada algoritma *support vector regression* (SVR). Performa algoritma SVR dioptimasi untuk mengetahui evaluasi dari algoritma SVR dengan dan tanpa optimasi parameter. Modul PSO dapat dilihat pada Algoritma 5 dan 6.

Algoritma 5: Fungsi Pre-processing

```

1  FUNCTION PSO
2  REQUIRE : N : jumlah partikel
3  REQUIRE : iter : Jumlah iterasi
4  REQUIRE : f(x) : Fungsi yang akan di optimasi
5
6      J ← 0
7      for i=(1 to n) do
8          //Inisialisasi partikel

```

Algoritma 6: Fungsi Pre-processing Lanjutan

```

9      Xi ← random()
10     While j < iter do
11         For i=(1 to n) do
12             f(Xi) //Evaluasi terhadap fungsi
13             PBesti ← Xi
14             if f(PBesti) > f(GBest) then
15                 GBest ← PBesti
16             //Memperbarui kecepatan posisi partikel
17             Vi = w x Vidt + C1 x Rand1 x (Pid - Xid) + C2 x Rand2 x (Pgd - Xid)
18             Xi = Xidt + Vidt+1
19             J ← J + 1

```

Dengan dijalankannya Algoritma 5 dan 6 maka akan didapatkan hasil seperti pada gambar 4.1

Optimum Parameter : [0.02615295 9.10693278 0.10609789]

Gambar 4.1 Contoh hasil optimasi parameter

4.1.5 Modul MAPE dan MAE

Modul MAPE pada persamaan 2.32 bila dituliskan dalam pseudocode terlihat seperti pada Algoritma 7. Sebelum melakukan proses, dibutuhkan beberapa variabel. Variabel n sebagai banyak data, variabel *Actual* sebagai data actual dan variabel *Forecast* sebagai data prediksi. Kemudian disubstitusikan ke dalam persamaan 2.32.

Algoritma 7: Fungsi MAPE

```

1  FUNCTION MAPE
2  REQUIRE : n : banyak data
3  REQUIRE : Actual : data actual
4  REQUIRE : Forecast : data prediksi
5
6      MAPE ←  $\left( \frac{1}{n} \sum \frac{|Actual - Forecast|}{|Actual|} \right) \times 100$ 
7      return MAPE

```

Modul MAE hampir seperti MAPE, akan tetapi berbeda pada substitusinya. Proses MAE membutuhkan beberapa variabel. Variabel n sebagai banyaknya data, variabel y_i sebagai data *actual* dan variabel f_i sebagai data prediksi. Kemudian disubstitusikan ke dalam persamaan 2.33.

Algoritma 8: Fungsi MAE

```

1  FUNCTION MAE
2  REQUIRE : n : banyak data
3  REQUIRE : yi : data actual
4  REQUIRE : fi : data prediksi
5
6      MAE ←  $\left( \frac{1}{n} \sum_{i=1}^n |f_i - y_i| \right)$ 
7      return MAE

```

4.2 Hasil Pengujian

Pada bagian ini menjelaskan mengenai hasil pengujian yang telah dilakukan. Pada penelitian ini memiliki dua pengujian yaitu pengujian penilitian dan pengujian sistem.

4.2.1 Pengujian penelitian

Pengujian korelasi antar data pada setiap parameternya dapat dilihat dari Gambar 4.2. Korelasi data memiliki nilai potisif dan negatif. Nilai positif menandakan parameter tersebut berbanding lurus dengan nilai konsentrasi polutan udara, sedangkan nilai negatif berbanding terbalik dengan nilai konsentrasi polutan udara. Semakin dekat nilai parameter dengan nilai nol, maka parameter tersebut paling tidak berpengaruh terhadap konsentrasi polutan. Sehingga semakin tinggi nilai parameter maka semakin berpengaruh parameter tersebut terhadap konsentrasi polutan udara. Berikut merupakan hasil dari korelasi data konsentrasi polutan dengan data faktor meteorologi.

Tabel 4.1 Urutan Korelasi Data dari yang Paling Berpengaruh

Konsentrasi Polutan	Faktor Meteorologi						
	Kecepatan Angin	Arah Angin	Kelembapan	Suhu	Tekanan Udara	Solar Radiation	Curah Hujan
PM10	-0,0087	-0,3156	-0,0758	0,2527	0,3392	-0,2281	-0,1659
CO	-0,0907	-0,2008	0,2564	0,1307	0,4716	-0,3746	0,1837
SO₂	-0,0770	-0,2012	0,2506	0,0233	0,5868	-0,5148	0,2494
O₃	-0,2648	0,2772	0,1344	-0,1735	-0,3961	0,2770	-0,0498

Pada Tabel 4.1 nilai yang berbanding lurus dengan faktor meteorologi pada PM10 adalah suhu 0,2527 dan tekanan udara 0,3392, kemudian pada CO adalah kelembapan 0,2564, suhu 0,1307, tekanan udara 0,4716 dan 0,1837 pada curah hujan, lalu pada SO₂ adalah kelembapan 0,2506, suhu 0,0233, tekanan udara 0,5856 dan curah hujan 0,2494 dan pada O₃ adalah arah angin 0,2772, kelembapan 0,1344 dan solat radiasi 0,2770 dan sisanya merupakan nilai yang berbanding terbalik pada faktor meteorologi. Lalu hasil penelitian parameter yang menggabungkan antara parameter konsentrasi polutan udara dan parameter faktor meteorologi dapat dilihat pada Gambar 4.2, Gambar 4.3, Gambar 4.4 dan Gambar 4.5. Pada gambar tersebut merupakan tabel yang dapat menyelesaikan rumusan masalah. Percobaan *forecasting* dilakukan dengan mengkombinasikan kedua jenis parameter (konsentrasi polutan dan faktor meteorologi) satu persatu untuk mendapatkan nilai MAPE dan MAE terbaik disetiap konsentrasi.

CO	WIND SPEED	WIND DIRECTION	HUMIDITY	TEMPERATURE	AIR PRESSURE	SOLAR RADIATION	RAINFALL	MAPE	MAE	MAPE SVR-PSO
V	V	V						0.293	2.862	0.371
V	V	V						0.962	8.658	0.353
V	V	V	V					0.88	7.694	0.615
V	V	V	V	V				0.855	7.574	1.717
V	V	V	V	V				0.884	7.761	1.773
V	V	V	V	V	V			0.916	8.199	0.391
V	V	V	V	V	V	V		0.892	7.985	0.617
V	V	V	V	V	V	V	V	0.893	8.037	1.771

Gambar 4.3 Contoh hasil kombinasi konsentrasi CO dengan faktor meteorologi

PM10	WIND SPEED	WIND DIRECTION	HUMIDITY	TEMPERATURE	AIR PRESSURE	SOLAR RADIATION	RAINFALL	MAPE	MAE	MAPE SVR-PSO
V	V	V						0.242	4.956	0.231
V	V	V						0.247	4.811	0.262
V	V	V	V					0.265	5.544	0.277
V	V	V	V	V				0.239	4.849	0.228
V	V	V	V	V	V	V		0.235	4.773	0.224
V	V	V	V	V	V	V	V	0.232	4.903	0.224
V	V	V	V	V	V	V	V	0.238	5.031	0.276
V	V	V	V	V	V	V	V	0.239	5.055	0.222
V	V	V	V	V	V	V	V			4.911

Gambar 4.2 Contoh hasil kombinasi konsentrasi PM10 dengan faktor meteorologi

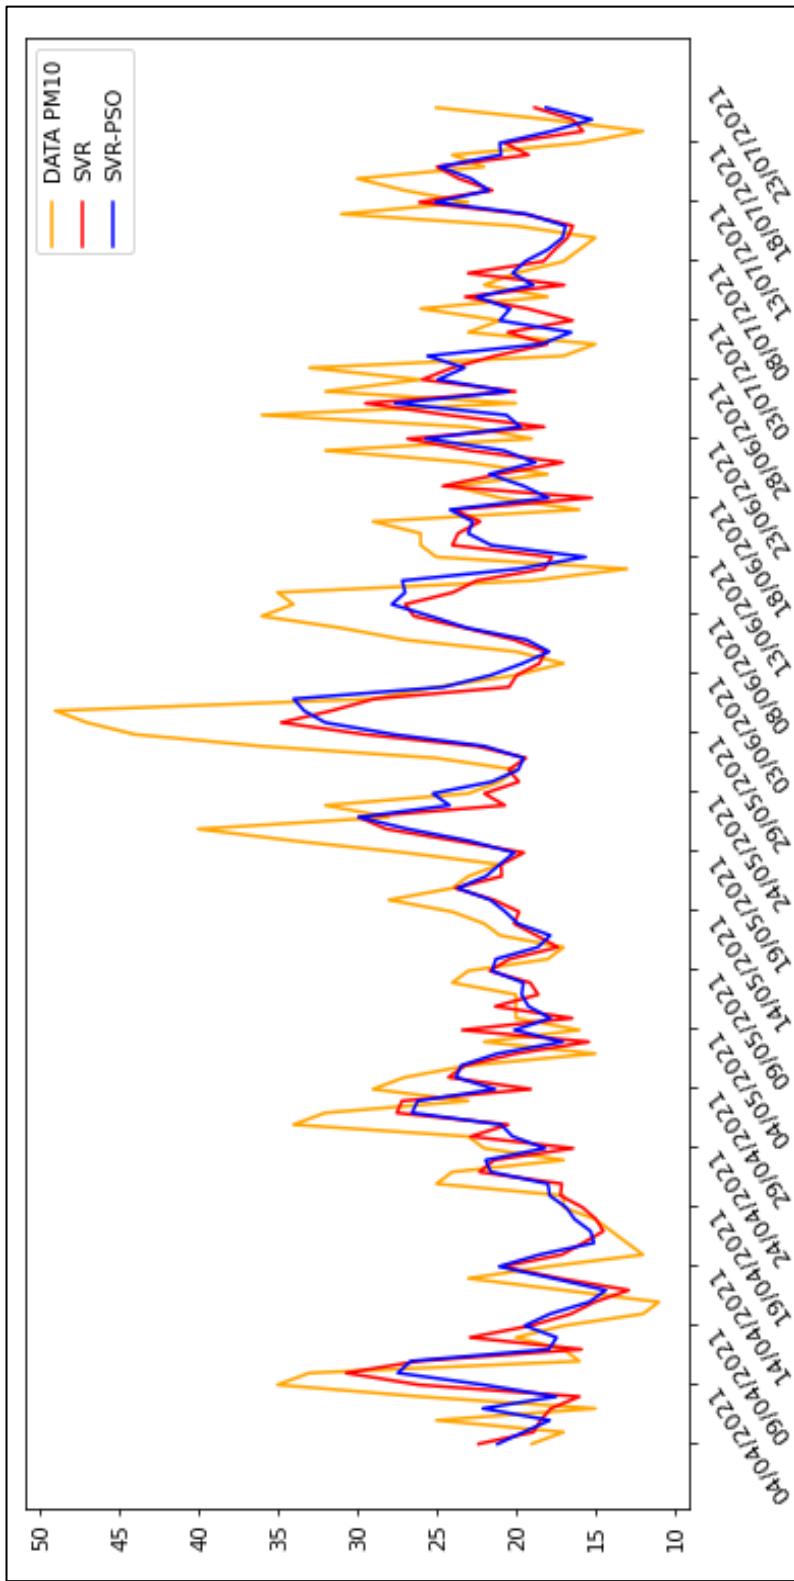
O ₃	WIND SPEED	WIND DIRECTION	HUMIDITY	TEMPERATURE	AIR PRESSURE	SOLAR RADIATION	RAINFALL	MAPE	MAE	MAPE SVR-RPSO
V	V	V	V	V	V	V	V	0.48	33.854	0.431
V	V	V	V	V	V	V	V	0.522	33.805	0.486
V	V	V	V	V	V	V	V	0.532	34.294	0.693
V	V	V	V	V	V	V	V	0.618	35.827	0.512
V	V	V	V	V	V	V	V	0.584	36.587	0.459
V	V	V	V	V	V	V	V	0.583	36.255	0.576
V	V	V	V	V	V	V	V	0.549	36.397	0.489
V	V	V	V	V	V	V	V	0.536	36.304	0.476

Gambar 4.5 Contoh hasil kombinasi konsentrasi O₃ dengan faktor meteorologi

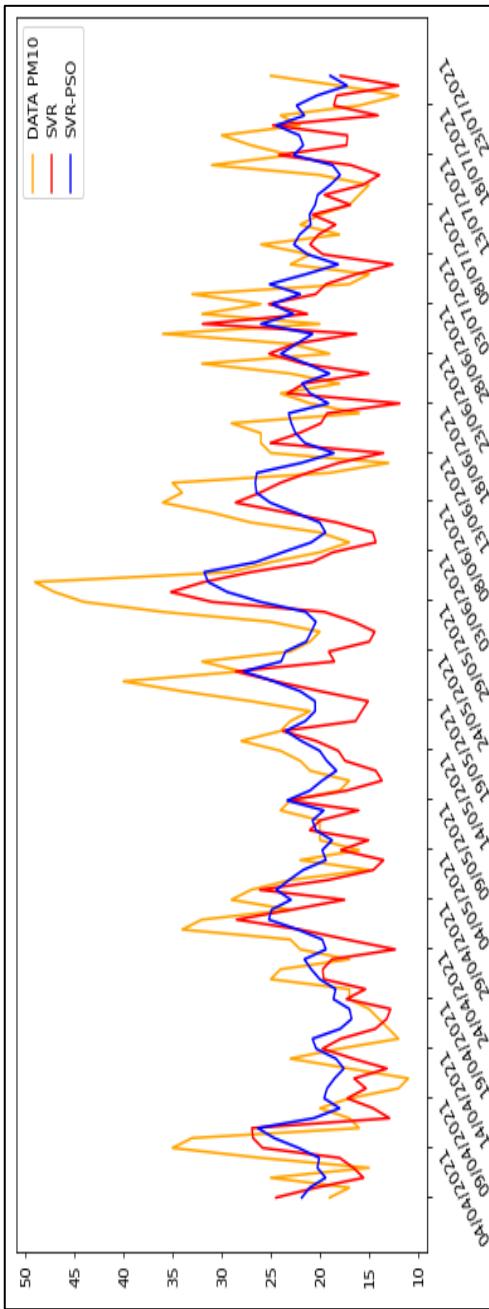
SO ₂	WIND SPEED	WIND DIRECTION	HUMIDITY	TEMPERATURE	AIR PRESSURE	SOLAR RADIATION	RAINFALL	MAPE	MAE	MAPE SVR-RPSO
V	V	V	V	V	V	V	V	0.174	3.102	0.233
V	V	V	V	V	V	V	V	0.17	3.069	0.233
V	V	V	V	V	V	V	V	0.171	3.112	0.233
V	V	V	V	V	V	V	V	0.166	3.136	0.233
V	V	V	V	V	V	V	V	0.169	3.179	0.233
V	V	V	V	V	V	V	V	0.166	3.137	0.233
V	V	V	V	V	V	V	V	0.162	3.076	0.143
V	V	V	V	V	V	V	V	0.162	3.067	0.148

Gambar 4.4 Contoh hasil kombinasi konsentrasi SO₂ dengan faktor meteorologi

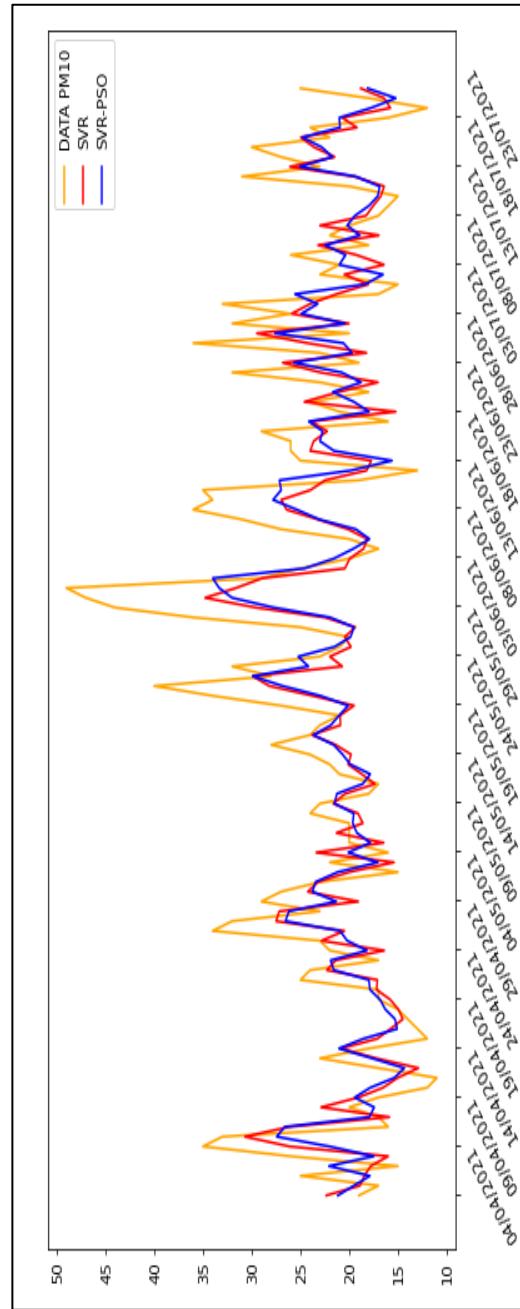
Contoh perbandingan hasil yang tidak menggunakan parameter faktor meteorologi (kombinasi 1 dan 9) dapat dilihat pada Gambar 4.6 dan 4.7. Kemudian, hasil dengan kombinasi dengan parameter faktor meteorologi dapat dilihat pada Gambar 4.8. Gambar tersebut menunjukkan grafik/*plot* tiga warna, plot berwarna orange yang menandakan data aktual konsentrasi polutan, *plot* berwarna merah merupakan prediksi menggunakan *support vector regression* dan *plot* berwarna biru merupakan prediksi *support vector regression* yang dioptimaskan dengan *particle swarm optimization*.



Gambar 4.6 Contoh hasil optimasi parameter kombinasi 1



Gambar 4.7 Contoh hasil optimasi parameter kombinasi 2



Gambar 4.8 Contoh hasil optimasi parameter kombinasi 9

4.3 Pembahasan

Pada penelitian *support vector regression* (SVR) dengan optimasi parameter menggunakan *particle swarm optimization* (PSO) untuk prediksi polutan udara kota Yogyakarta yang didapatkan dengan cara mengunduh dan meminta langsung data konsentrasi polutan kota Yogyakarta dan data faktor meteorologi kota Yogyakarta dari dinas lingkungan hidup dan kehutanan (DLHK) kota Yogyakarta dan *website* lingkunganhidup.jogjakota.go.id yang bersifat data terbuka. Kemudian, data tersebut di proses untuk prediksi menggunakan SVR dengan melihat hasil korelasi data konsentrasi polutan udara dengan faktor meteorologi. Hasil proses menunjukkan bahwa parameter yang paling berpengaruh kepada konsentrasi polutan udara yaitu tekanan udara untuk parameter CO, SO₂, O₃ dan arah angin untuk parameter PM10.

Pada Tabel 4.1 konsentrasi PM10 parameter faktor meteorologi yang berbanding lurus dengan PM10 adalah suhu, tekanan dan tekanan udara. Sebaliknya, kecepatan angin, arah angin, kelembapan, radiasi solar dan curah hujan berbanding terbalik dengan PM10. Kemudian pada konsentrasi CO, kelembaban, suhu, tekanan udara dan curah hujan berbanding lurus dengan CO, sedangkan kecepatan angin, arah angin dan radiasi solar berbanding terbalik dengan CO. Lalu, pada konsentrasi SO₂, kelembapan , suh, tekanan udara dan curah hujan berbanding lurus dengan konsentrasi polutan SO₂ dan pada konsentrasi O₃, arah angin, kelembapan, dan solat radiasi merupakan berbanding lurus dengan konsentrasi polutan O₃, dan sisanya merupakan nilai yang berbanding terbalik pada faktor meteorologi.

Berdasarkan pengujian yang telah dilakukan menggunakan data dari 1 Januari 2020 sampai dengan 26 Juli 2021, prediksi polutan udara yang menggunakan SVR dan SVR-PSO dengan kernel RBF memperoleh nilai terbaik MAPE 0.202 pada kombinasi ke-2 untuk konsenetrasi PM10 dan MAPE 0.343 pada kombinasi ke-9 untuk CO. Kemudian nilai MAE sebesar 4.87 pada kombinasi ke-2 untuk konsentrasi PM10 dan MAE 2.60 pada kombinasi ke-9 untuk konsentrasi CO.

Kekurangan yang ada pada metode SVR dan SVR-PSO yang diperoleh pada penelitian ini adalah ketidak konsistenan parameter kernel. Hal ini disebabkan nilai gamma, complexity, dan epsilon diinisiasi awal secara random. Kemudian kekurangan lainnya merupakan hasil dari prediksi belum terlalu akurat dikarenakan datanya masih kurang banyak.

BAB IV

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil percobaan pada penelitian yang telah dilakukan, dapat disimpulkan bahwa prediksi polutan udara tanpa faktor meteorologi menggunakan metode *support vector regression* (SVR) tanpa optimasi memperoleh MAPE sebesar 0.218 dan MAE sebesar 5.32 untuk PM10, MAPE sebesar 0.38 dan MAE sebesar 2.76 untuk CO. Sedangkan SVR dengan optimasi *particle swarm optimization* (PSO) memperoleh MAPE 0.209 dan MAE 4.99 untuk PM10 pada optimasi parameter $\gamma = 0.101$, $complexity = 9.354$ dan $\epsilon = 0.323$ dan MAPE sebesar 0.34 dan MAE sebesar 2.60 untuk CO pada optimasi parameter $\gamma = 0.143$, $complexity = 9.940$ dan $\epsilon = 0.1$.

Kemudian prediksi polutan udara dengan faktor meteorologi menggunakan SVR tanpa optimasi mendapatkan hasil terbaik MAPE sebesar 0.20 dan MAE sebesar 4.99 untuk PM10, MAPE sebesar 0.49 dan MAE sebesar 3.54 untuk CO. Sedangkan SVR dengan optimasi PSO mendapatkan hasil MAPE sebesar 2.02 dan MAE sebesar 4.87 untuk PM10 pada optimasi parameter $\gamma = 0.255$, $complexity = 5.612$ dan $\epsilon = 0.1$ dan MAPE sebesar 3.50 dan MAE sebesar 2.86 untuk CO pada optimasi parameter $\gamma = 0.022$, $complexity = 7.086$ dan $\epsilon = 0.1$.

Terbukti bahwa faktor meteorologi dan optimasi parameter dapat mempengaruhi hasil dari prediksi konsentrasi polutan udara sebagaimana hasil dari penelitian ini yang telah dilakukan menggunakan perhitungan nilai MAPE dan MAE.

5.2 Saran

Berdasarkan keterbatasan penelitian ini, disarankan untuk menambahkan data *training* dan *testing*. Kemudian penentuan nilai parameter kernel supaya hasil prediksi lebih konsisten.

DAFTAR PUSTAKA

- Aeni, U. N., Prasati, A. L., & Kallista, M. (2020). *Grafik Jumlah Penumpang 2018*. 7(2), 4919–4926.
- Agmalaro, M. A., Sitanggang, I. S., Hasibuan, L. S., & Ramadhan, M. M. (2019). Model Spasial untuk Prediksi Konsentrasi Polutan Kabut Asap Kebakaran Lahan Gambut Menggunakan Support Vector Regression. *Jurnal Ilmu Komputer Dan Agri-Informatika*, 5(2), 119. <https://doi.org/10.29244/jika.5.2.119-127>
- Arampongsanuwat, S., & Meesad, P. (2012). PM10 prediction model by support vector regression based on particle swarm optimization. *Advanced Materials Research*, 403–408, 3693–3698. <https://doi.org/10.4028/www.scientific.net/AMR.403-408.3693>
- Bai, Y., Li, Y., Wang, X., Xie, J., & Li, C. (2016). Air pollutants concentrations forecasting using back propagation neural network based on wavelet decomposition with meteorological conditions. *Atmospheric Pollution Research*, 7(3), 557–566. <https://doi.org/10.1016/j.apr.2016.01.004>
- Budiyono, A. (2010). Indeks Kualitas Udara. *Berita Dirgantara*, 3(1), 1–14.
- Chiu, D. Y., & Chen, P. J. (2009). Dynamically exploring internal mechanism of stock market by fuzzy-based support vector machines with high dimension input space and genetic algorithm. *Expert Systems with Applications*, 36(2 PART 1), 1240–1248. <https://doi.org/10.1016/j.eswa.2007.11.022>
- Chuentawat, R., Kerdprasop, N., & Kerdprasop, K. (2017). The Forecast of PM10 Pollutant by Using a Hybrid Model. *International Journal of Future Computer and Communication*, 6(3), 128–132. <https://doi.org/10.18178/ijfcc.2017.6.3.504>
- Fajarita, L., & Hati, E. N. (2018). Penerapan Forecasting Straight Line Method Dalam Pengadaan Stok Barang Mendatang. *Prosiding SINTAK 2018*, 310–317.
- Feng, X., Li, Q., Zhu, Y., Hou, J., Jin, L., & Wang, J. (2015). Artificial neural networks forecasting of PM2.5 pollution using air mass trajectory based geographic model and wavelet transformation. *Atmospheric Environment*, 107, 118–128. <https://doi.org/10.1016/j.atmosenv.2015.02.030>
- Ganesh, S. S., ArulmozhiVarman, P., & Tatavarti, R. (2021). Forecasting air quality index using an ensemble of artificial neural networks and regression models. *Journal of Intelligent Systems*, 28(5), 893–903. <https://doi.org/10.1515/jisys-2017-0277>
- Ginting, I. A. P. (2017). Analisis Pengaruh Jumlah Kendaraan Kelembaban , dan Kecepatan Angin) terhadap Konsentrasi Karbon Monoksida (CO) di Udara Ambien Roadside (Studi Kasus : Pintu Tol Amplas dan Pintu Tol Tanjung Morawa). 1–143.
- He, H. di, Lu, W. Z., & Xue, Y. (2014). Prediction of particulate matter at street level using artificial neural networks coupling with chaotic particle swarm optimization algorithm. *Building and Environment*, 78, 111–117. <https://doi.org/10.1016/j.buildenv.2014.04.011>
- Hermawan, A. (2019). *SPKU: Sistem Prediksi Kualitas Udara (Studi Kasus: Dki Jakarta)*. <http://eprints.uty.ac.id/3552/>
- Hirtl, M., Mantovani, S., Krüger, B. C., Triebnig, G., Flandorfer, C., Bottoni, M., & Cavicchi, M. (2014). Improvement of air quality forecasts with satellite and ground based particulate matter observations. *Atmospheric Environment*, 84, 20–27. <https://doi.org/10.1016/j.atmosenv.2013.11.027>
- Hsu, C., Chang, C., & Lin, C. (2016). *A Practical Guide to Support Vector Classification*. 1(1), 1–16.
- Kazem, A., Sharifi, E., Hussain, F. K., Saberi, M., & Hussain, O. K. (2013). Support vector regression with chaos-based firefly algorithm for stock market price forecasting. *Applied Soft Computing Journal*, 13(2), 947–958.

- <https://doi.org/10.1016/j.asoc.2012.09.024>
- Kennedy, J. &, & Eberhart, R. (1995). Particle Swarm Optimisation. *Studies in Computational Intelligence*, 927, 5–13. https://doi.org/10.1007/978-3-030-61111-8_2
- Kumar, A., & Goyal, P. (2011). Forecasting of daily air quality index in Delhi. *Science of the Total Environment*, 409(24), 5517–5523. <https://doi.org/10.1016/j.scitotenv.2011.08.069>
- Kusumodestoni, R. H. (2017). Prediksi Kecepatan Angin Berbasis Model Support Vector Machines (Svm). *Jurnal DISPROTEK*, 8(1), 13–22.
- Li, X., Luo, A., Li, J., & Li, Y. (2019). Air Pollutant Concentration Forecast Based on Support Vector Regression and Quantum-Behaved Particle Swarm Optimization. *Environmental Modeling and Assessment*, 24(2), 205–222. <https://doi.org/10.1007/s10666-018-9633-3>
- Lin, K. P., Pai, P. F., & Yang, S. L. (2011). Forecasting concentrations of air pollutants by logarithm support vector regression with immune algorithms. *Applied Mathematics and Computation*, 217(12), 5318–5327. <https://doi.org/10.1016/j.amc.2010.11.055>
- Liu, B. C., Binaykia, A., Chang, P. C., Tiwari, M. K., & Tsao, C. C. (2017). Urban air quality forecasting based on multidimensional collaborative Support Vector Regression (SVR): A case study of Beijing-Tianjin-Shijiazhuang. *PLoS ONE*, 12(7), 1–17. <https://doi.org/10.1371/journal.pone.0179763>
- Lu, W., Wang, W., Leung, A. Y. T., Lo, S. M., Yuen, R. K. K., Xu, Z., & Fan, H. (2002). Air pollutant parameter forecasting using support vector machines. *Proceedings of the International Joint Conference on Neural Networks*, 1(May 2014), 630–635. <https://doi.org/10.1109/ijcnn.2002.1005545>
- Lu, X., & Geng, X. (2011). Car sales volume prediction based on particle swarm optimization algorithm and support vector regression. *Proceedings - 4th International Conference on Intelligent Computation Technology and Automation, ICICTA 2011*, 1(1), 71–74. <https://doi.org/10.1109/ICICTA.2011.25>
- Luqyana, W. A., Cholissodin, I., & Perdana, R. S. (2018). Analisis Sentimen Cyberbullying Pada Komentar Instagram dengan Metode Klasifikasi Support Vector Machine. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer (J-PTIIK) Universitas Brawijaya*, 2(11), 4704–4713.
- Maharesi, R., Teknologi, F., Jurusan, I., Informatika, T., & Gunadarma, U. (2013). Penggunaan Support Vector Regression (Svr) Pada Prediksi Return Saham Syariah BEI. *Proceeding PESAT*, 5, 8–9.
- Marini, F., & Walczak, B. (2015). Particle swarm optimization (PSO). A tutorial. *Chemometrics and Intelligent Laboratory Systems*, 149, 153–165. <https://doi.org/10.1016/j.chemolab.2015.08.020>
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. (2008). Introduction to Time Series Analysis and Forecasting. *Journal of Quality Technology*, 40(4), 476–478. <https://doi.org/10.1080/00224065.2008.11917751>
- Murillo-Escobar, J., Sepulveda-Suescun, J. P., Correa, M. A., & Orrego-Metaute, D. (2019). Forecasting concentrations of air pollutants using support vector regression improved with particle swarm optimization: Case study in Aburrá Valley, Colombia. *Urban Climate*, 29(March), 100473. <https://doi.org/10.1016/j.uclim.2019.100473>
- Pai, P. F., Lin, K. P., Lin, C. S., & Chang, P. T. (2010). Time series forecasting by a seasonal support vector regression model. *Expert Systems with Applications*, 37(6), 4261–4265. <https://doi.org/10.1016/j.eswa.2009.11.076>
- Purba, L. S. L., & Harefa, N. (2020). Pengaruh Kandungan Oksigen Udara Sekolah terhadap Konsentrasi Belajar Pengaruh Kandungan Oksigen Udara Sekolah terhadap

- Konsentrasi Belajar Siswa SMA N 9 Jakarta Timur. *Jurnal EduMatSains*, 4(2), 169–182.
- Raharyani, M. P., Putri, R. R. M., & Setiawan, B. D. (2018). Implementasi Algoritme Support Vector Regression Pada Prediksi Jumlah Pengunjung Pariwisata. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 2(4), 1501–1509.
- Ratnaweera, A., Halgamuge, S. K., & Watson, H. C. (2004). Self-organizing hierarchical particle swarm optimizer with time-varying acceleration coefficients. *IEEE Transactions on Evolutionary Computation*, 8(3), 240–255. <https://doi.org/10.1109/TEVC.2004.826071>
- Rusdi, M. (2017). Komparasi Penggunaan Algoritma Support Vector Machine Dengan Particle Swarm Optimization Dalam Memprediksi Suhu Udara. *Technologia: Jurnal Ilmiah*, 8(4), 277. <https://doi.org/10.31602/tji.v8i4.1128>
- Sanchez-Torres, G., & Bolaño, I. D. (2019). Support vector regression for pm10 concentration modeling in santa marta urban area. *Engineering Letters*, 27(3), 432–440.
- Saputra, E. P., Putri, S. A., & Indriyanti, I. (2019). Prediction of Successful Elearning Based on Activity Logs with Selection of Support Vector Machine based on Particle Swarm Optimization. *Indonesian Journal of Artificial Intelligence and Data Mining*, 2(1), 10–17. <https://doi.org/10.24014/ijaidm.v2i1.6500>
- Smola, A. J., & Schölkopf, B. (2004). Identification of TRACs (T3 receptor-associating cofactors), a family of cofactors that associate with, and modulate the activity of, nuclear hormone receptors. *Molecular Endocrinology*, 10(7), 813–825. <https://doi.org/10.1210/me.10.7.813>
- Sotomayor-Olmedo, A., Aceves-Fernández, M. A., Gorrostieta-Hurtado, E., Pedraza-Ortega, C., Ramos-Arreguín, J. M., & Vargas-Soto, J. E. (2013). Forecast Urban Air Pollution in Mexico City by Using Support Vector Machines: A Kernel Performance Approach. *International Journal of Intelligence Science*, 03(03), 126–135. <https://doi.org/10.4236/ijis.2013.33014>
- Trianisa, K., Purnomo, E. P., & Kasiwi, A. N. (2020). Pengaruh Industri Batubara Terhadap Polusi Udara dalam Keseimbangan World Air Quality Index in India. *Jurnal Sains Teknologi & Lingkungan*, 6(2), 156. <https://doi.org/10.29303/jstl.v6i2.154>
- Vijayakumar, S., & Wu, S. (1999). Sequential Support Vector Classifiers and Regression. *Proceedings of International Conference on Soft Computing (SOCO '99)*, 619(October 2014), 610–619.
- Wang, P., Liu, Y., Qin, Z., & Zhang, G. (2015). A novel hybrid forecasting model for PM10 and SO2 daily concentrations. *Science of the Total Environment*, 505, 1202–1212. <https://doi.org/10.1016/j.scitotenv.2014.10.078>
- Welim, Y. Y., & Wisjnuadji, T. W. (2014). *Pemodelan sistem Pakar Berbasis Adaptive Neuro Fuzzy untuk Melakukan Prediksi Tingkat Pencemaran Udara berdasarkan ISPU (Indeks Standar Pencemar Udara) Studi Kasus : Wilayah DKI*. 1–6.
- Yasin, H., Prahatama, A., & Utami, T. W. (2014). Prediksi Harga Saham Menggunakan Support Vector Regression Dengan Algoritma Grid Search. *Media Statistika*, 7(1), 29–35. <https://doi.org/10.14710/medstat.7.1.29-35>
- Zhao, W., Tao, T., Zio, E., & Wang, W. (2016). A Novel Hybrid Method of Parameters Tuning in Support Vector Regression for Reliability Prediction: Particle Swarm Optimization Combined with Analytical Selection. *IEEE Transactions on Reliability*, 65(3), 1393–1405. <https://doi.org/10.1109/TR.2016.2515581>
- Zhu, H., & Hu, J. (2019). Air quality forecasting using SVR with quasi-linear kernel. *CITS 2019 - Proceeding of the 2019 International Conference on Computer, Information and Telecommunication Systems*, 1–5. <https://doi.org/10.1109/CITS.2019.8862114>

Zhu, S., Lian, X., Liu, H., Hu, J., Wang, Y., & Che, J. (2017). Daily air quality index forecasting with hybrid models: A case in China. *Environmental Pollution*, 231, 1232–1244. <https://doi.org/10.1016/j.envpol.2017.08.069>

LAMPIRAN

Lampiran A Tabel data konsentrasi dan faktor meteorologi

Waktu	PM10	CO	SO2	O3	Kecepatan Angin	Arah Angin	Kelembaban	Suhu	Tekanan Udara	Solar Radiation	Curah Hujan
01/01/2020	28	84	2	19	2	73	93	24	1000	10	6
02/01/2020	17	54	2	33	2	158	84	27	999	67	5
03/01/2020	12	84	2	18	2	190	85	27	997	44	7
04/01/2020	9	55	2	29	2	210	85	27	996	52	36
05/01/2020	9	79	3	0	1	173	91	26	996	37	8
06/01/2020	14	100	2	18	2	197	82	28	996	48	3
07/01/2020	9	49	3	0	2	215	88	26	996	52	32
08/01/2020	11	178	4	0	1	170	86	27	996	42	3
09/01/2020	14	81	4	5	1	148	82	28	995	51	1
10/01/2020	7	65	3	30	2	205	87	26	996	53	32
11/01/2020	8	43	2	16	2	224	83	27	997	65	17
12/01/2020	9	43	2	9	2	150	75	28	996	54	16
13/01/2020	12	41	2	8	2	195	73	29	995	58	0
14/01/2020	15	61	2	0	2	170	76	29	996	53	0
15/01/2020	21	70	2	25	1	233	79	29	997	55	0
16/01/2020	11	54	2	0	2	207	79	29	998	54	2
17/01/2020	15	70	2	0	2	153	71	29	998	65	0
18/01/2020	18	69	3	0	2	181	71	29	998	52	0
19/01/2020	16	43	2	0	2	188	71	30	998	58	0
20/01/2020	14	47	2	0	2	166	72	30	998	55	0
21/01/2020	27	60	2	11	1	159	76	29	999	40	0
22/01/2020	28	89	2	8	1	119	82	27	999	55	4
23/01/2020	28	160	2	14	1	145	85	27	997	42	12
24/01/2020	35	131	2	27	2	118	80	29	997	56	0
25/01/2020	30	46	2	25	2	122	85	28	997	49	3
26/01/2020	20	37	2	27	2	180	79	28	997	65	0
27/01/2020	30	113	2	20	1	153	84	27	997	49	1
28/01/2020	27	94	2	27	1	174	82	28	997	58	2
29/01/2020	28	82	2	30	1	137	79	29	997	54	0
30/01/2020	16	58	2	47	3	197	81	27	998	62	0
31/01/2020	23	47	1	24	2	115	80	28	997	57	0
01/02/2020	33	67	2	15	2	167	81	28	997	56	0
02/02/2020	27	66	2	26	1	137	87	26	998	41	6
03/02/2020	27	55	2	17	1	151	84	28	998	43	0
04/02/2020	16	97	2	15	2	158	84	28	997	53	2
05/02/2020	13	71	2	9	1	184	81	28	997	47	0
06/02/2020	26	83	3	20	2	190	81	28	997	50	0
07/02/2020	19	54	2	10	2	126	78	28	997	42	0
08/02/2020	31	149	1	52	1	148	85	27	998	48	1

09/02/2020	22	86	3	36	1	213	85	27	999	55	1
10/02/2020	8	59	2	14	1	201	84	27	998	38	11
11/02/2020	11	66	3	18	2	159	82	28	999	51	1
12/02/2020	28	81	3	17	1	145	86	27	999	47	2
13/02/2020	30	93	3	17	1	209	84	27	998	52	0
14/02/2020	32	100	2	26	2	164	84	27	997	53	6
15/02/2020	23	89	2	30	2	170	85	27	998	48	1
16/02/2020	17	88	2	23	2	204	82	28	998	61	1
17/02/2020	14	75	3	11	1	183	84	27	999	44	1
18/02/2020	11	36	2	0	2	114	78	28	998	55	1
19/02/2020	16	60	2	14	2	146	85	27	997	60	8
20/02/2020	2	6	2	14	0	73	95	24	997	0	31
21/02/2020	20	97	3	12	2	172	87	27	998	52	27
22/02/2020	20	101	2	47	1	171	83	28	999	54	20
23/02/2020	29	79	2	21	2	120	79	29	997	64	0
24/02/2020	44	79	2	10	2	123	86	27	997	42	5
25/02/2020	23	25	2	31	2	150	87	27	997	54	1
26/02/2020	16	25	2	0	1	173	87	27	997	43	1
27/02/2020	24	8	2	0	2	106	84	27	996	44	3
28/02/2020	21	14	2	0	1	111	82	28	996	56	1
29/02/2020	27	23	2	0	2	132	87	27	995	55	2
01/03/2020	17	20	2	0	1	130	93	25	996	32	8
02/03/2020	26	21	2	0	2	114	90	27	996	40	1
03/03/2020	27	109	3	0	1	125	88	27	997	62	1
04/03/2020	19	42	2	22	1	156	90	26	997	61	2
05/03/2020	11	154	2	0	2	184	89	25	998	57	51
06/03/2020	13	73	4	20	2	242	77	28	997	65	0
07/03/2020	11	34	2	10	2	141	84	27	998	61	5
08/03/2020	7	17	1	0	2	210	86	27	998	53	9
09/03/2020	10	42	2	11	1	184	91	25	997	52	7
10/03/2020	9	37	2	29	2	247	79	28	996	56	11
11/03/2020	32	146	2	36	1	141	87	27	997	45	13
12/03/2020	40	99	4	30	1	183	87	27	998	51	1
13/03/2020	51	29	2	32	1	147	82	29	999	62	0
14/03/2020	37	44	2	11	1	161	75	29	998	53	0
15/03/2020	32	12	2	18	2	150	74	30	997	65	0
16/03/2020	20	46	2	0	3	240	75	29	998	66	0
17/03/2020	32	34	2	0	2	155	77	29	998	50	0
18/03/2020	18	32	2	6	2	160	80	28	997	57	0
19/03/2020	17	48	2	18	2	130	86	27	998	39	4
20/03/2020	24	29	1	19	2	177	84	27	998	43	4
21/03/2020	24	39	1	15	2	181	82	28	998	62	4
22/03/2020	27	36	1	17	1	175	81	29	998	56	8
23/03/2020	21	73	1	21	1	136	91	26	998	37	41
24/03/2020	24	41	2	21	1	113	85	27	996	59	7
25/03/2020	27	137	2	18	1	116	90	26	996	44	38

26/03/2020	31	67	3	23	2	109	78	29	996	56	0
27/03/2020	33	43	1	39	1	143	82	28	997	46	0
28/03/2020	22	57	2	14	1	131	87	27	996	38	10
29/03/2020	27	22	1	17	1	127	84	27	996	41	0
30/03/2020	24	31	1	0	2	122	83	28	997	37	0
31/03/2020	14	19	1	12	2	178	86	27	997	43	4
01/04/2020	21	52	1	16	2	117	84	27	997	55	7
02/04/2020	53	61	1	20	1	163	83	28	997	52	0
03/04/2020	43	70	2	15	1	152	87	27	997	58	4
04/04/2020	31	56	1	11	1	126	88	27	997	46	3
05/04/2020	11	23	1	12	1	182	87	27	998	57	1
06/04/2020	10	30	1	0	1	141	87	27	998	59	42
07/04/2020	22	54	1	8	1	103	81	28	997	56	0
08/04/2020	21	31	1	0	2	122	82	28	998	43	3
09/04/2020	21	38	1	0	1	122	80	28	999	59	10
10/04/2020	18	35	1	0	2	135	82	28	999	55	0
11/04/2020	19	42	1	0	2	176	82	29	999	49	1
12/04/2020	24	30	1	0	2	144	77	29	997	55	0
13/04/2020	21	27	1	8	2	192	74	29	997	51	0
14/04/2020	33	46	1	6	1	146	78	28	997	50	0
15/04/2020	51	46	1	12	2	132	80	28	998	58	0
16/04/2020	66	59	2	16	1	136	81	29	997	42	1
17/04/2020	54	60	2	11	1	117	86	27	998	43	6
18/04/2020	23	61	1	17	1	122	86	26	998	43	9
19/04/2020	46	84	2	9	1	188	85	28	998	55	0
20/04/2020	53	79	2	16	1	167	84	28	997	48	0
21/04/2020	50	54	2	13	1	132	83	29	997	60	0
22/04/2020	30	38	1	11	2	145	77	30	997	50	0
23/04/2020	30	27	1	10	3	138	77	30	996	57	1
24/04/2020	16	19	1	8	2	141	78	29	997	44	8
25/04/2020	28	64	2	2	2	85	82	28	997	56	0
26/04/2020	23	33	1	6	2	122	76	29	997	59	0
27/04/2020	26	62	1	28	1	105	83	27	998	38	5
28/04/2020	27	56	1	19	1	110	81	28	997	48	0
29/04/2020	44	62	2	14	1	136	83	28	997	50	0
30/04/2020	28	32	1	14	2	147	76	29	998	57	0
01/05/2020	27	30	1	9	2	224	73	29	997	61	0
02/05/2020	12	17	1	9	2	176	75	29	996	57	0
03/05/2020	44	54	2	10	2	174	77	29	996	44	0
04/05/2020	35	39	1	11	2	188	74	30	997	47	0
05/05/2020	35	64	1	9	2	191	81	28	997	45	0
06/05/2020	36	38	2	15	2	199	81	28	997	39	0
07/05/2020	23	5	1	0	1	194	79	28	997	49	0
08/05/2020	33	53	1	10	1	185	82	28	996	49	2
09/05/2020	14	21	1	10	1	184	89	27	997	32	23
10/05/2020	11	13	1	0	2	133	82	28	997	54	9

11/05/2020	19	50	1	0	1	142	91	27	998	35	12
12/05/2020	15	38	1	9	2	141	79	28	997	56	0
13/05/2020	23	33	1	1	2	162	75	29	997	51	0
14/05/2020	18	21	1	15	3	189	76	28	997	43	0
15/05/2020	21	22	1	4	3	152	76	29	996	54	0
16/05/2020	16	10	1	4	3	180	76	29	995	62	0
17/05/2020	18	16	1	3	3	160	78	29	995	65	0
18/05/2020	21	51	1	0	2	145	85	27	996	36	4
19/05/2020	15	27	2	11	2	169	88	27	996	52	2
20/05/2020	15	15	2	0	1	123	90	27	996	41	13
21/05/2020	20	22	1	0	2	179	87	27	997	64	0
22/05/2020	20	32	1	14	1	214	80	28	997	44	0
23/05/2020	31	56	1	14	1	259	79	28	998	58	0
24/05/2020	25	29	1	0	1	261	76	29	999	52	0
25/05/2020	17	15	1	0	2	236	78	29	999	61	0
26/05/2020	8	17	1	0	1	192	92	26	999	43	0
27/05/2020	9	3	1	0	1	199	86	27	999	59	0
28/05/2020	0	0	1	0	1	199	87	27	999	43	3
29/05/2020	0	0	1	10	2	125	83	27	999	48	0
30/05/2020	0	0	1	8	2	149	81	28	999	47	0
31/05/2020	0	0	1	0	2	175	86	27	1000	53	14
01/06/2020	25	53	1	0	2	139	82	28	999	44	0
02/06/2020	31	56	1	10	2	127	83	28	999	58	0
03/06/2020	40	49	1	12	3	159	76	28	998	43	0
04/06/2020	26	25	1	9	4	153	76	28	998	48	0
05/06/2020	18	47	1	0	2	138	85	26	999	56	0
06/06/2020	13	17	1	6	3	167	80	27	999	51	0
07/06/2020	13	17	1	0	2	157	79	28	997	47	0
08/06/2020	13	19	1	0	3	180	79	28	998	56	0
09/06/2020	18	38	1	7	2	181	80	27	998	58	0
10/06/2020	17	33	1	6	2	152	77	28	998	63	0
11/06/2020	20	28	2	8	2	195	78	28	997	60	0
12/06/2020	21	37	2	0	2	220	78	27	997	54	0
13/06/2020	20	36	1	8	2	121	76	28	997	47	0
14/06/2020	17	31	1	7	2	144	81	28	998	63	0
15/06/2020	25	62	1	12	2	173	81	28	998	45	0
16/06/2020	25	44	1	12	3	200	77	29	997	55	0
17/06/2020	22	30	1	15	3	143	78	28	998	42	0
18/06/2020	24	23	1	0	2	189	78	28	998	55	0
19/06/2020	18	23	1	5	3	223	77	28	999	57	0
20/06/2020	20	34	1	10	3	148	76	27	998	50	0
21/06/2020	19	22	1	3	3	100	78	27	997	41	0
22/06/2020	18	28	1	0	2	162	78	28	997	57	0
23/06/2020	16	32	1	0	3	156	75	27	998	55	0
24/06/2020	12	25	1	8	3	176	74	28	998	53	0
25/06/2020	21	46	1	13	3	144	73	27	997	68	0

26/06/2020	21	35	1	7	2	136	76	26	998	56	0
27/06/2020	27	39	1	7	2	164	74	27	998	62	0
28/06/2020	29	27	1	9	2	160	75	27	999	57	0
29/06/2020	19	29	1	11	2	154	76	27	998	64	0
30/06/2020	18	32	1	9	2	139	76	27	998	47	0
01/07/2020	16	31	1	6	2	174	78	27	998	54	0
02/07/2020	23	37	1	6	1	141	77	27	998	54	0
03/07/2020	20	29	1	10	2	168	75	27	999	49	0
04/07/2020	26	44	1	11	1	137	73	27	998	36	0
05/07/2020	32	53	1	15	2	184	75	27	997	57	0
06/07/2020	25	33	1	10	3	151	78	27	998	47	0
07/07/2020	20	39	0	10	2	174	78	27	998	53	1
08/07/2020	18	27	1	10	3	182	76	27	998	60	0
09/07/2020	31	14	1	6	3	199	75	27	997	61	0
10/07/2020	19	27	1	11	2	133	77	27	998	60	0
11/07/2020	17	27	1	3	2	149	75	27	998	56	0
12/07/2020	20	25	1	10	2	173	76	27	998	68	0
13/07/2020	26	36	1	15	2	143	77	27	997	66	0
14/07/2020	21	30	1	11	2	231	75	28	997	61	0
15/07/2020	28	37	1	11	3	147	75	28	997	52	0
16/07/2020	26	33	1	12	1	166	73	29	996	55	0
17/07/2020	32	29	1	20	2	156	79	27	997	51	0
18/07/2020	15	24	0	11	3	207	75	27	998	58	0
19/07/2020	19	19	1	7	3	178	77	27	997	55	0
20/07/2020	12	19	0	4	2	187	74	28	997	46	0
21/07/2020	19	29	1	11	2	177	76	28	997	62	0
22/07/2020	21	37	1	36	2	182	77	27	997	46	0
23/07/2020	19	15	0	23	2	250	72	27	997	54	0
24/07/2020	15	61	0	22	2	157	70	27	998	72	0
25/07/2020	15	11	2	0	4	142	68	26	999	54	0
26/07/2020	29	15	1	8	2	119	65	26	998	43	0
27/07/2020	27	18	1	12	3	128	70	26	998	40	0
28/07/2020	16	4	1	7	3	155	73	26	998	58	0
29/07/2020	14	2	1	11	3	165	72	26	999	54	0
30/07/2020	22	18	1	7	2	177	69	25	999	50	0
31/07/2020	19	4	1	7	3	123	72	25	999	51	0
01/08/2020	6	0	1	0	2	51	84	22	999	0	0
02/08/2020	20	3	1	0	2	179	73	25	998	53	0
03/08/2020	18	17	1	5	2	185	74	26	997	56	0
04/08/2020	22	7	1	0	2	178	74	27	997	70	0
05/08/2020	26	12	1	3	2	148	77	26	998	52	0
06/08/2020	22	5	1	25	2	142	74	26	997	45	0
07/08/2020	17	8	1	57	3	173	74	26	998	60	0
08/08/2020	26	21	1	49	1	216	77	26	997	53	0
09/08/2020	40	23	0	37	2	157	78	26	998	53	0
10/08/2020	49	51	0	0	1	148	78	26	999	52	0

11/08/2020	33	19	1	6	2	191	80	27	1000	45	1
12/08/2020	17	37	1	11	2	176	85	26	1000	44	4
13/08/2020	20	9	1	9	2	157	84	27	999	55	1
14/08/2020	17	11	1	0	2	195	80	27	998	52	0
15/08/2020	21	18	4	15	1	152	79	28	400	169	0
16/08/2020	17	11	0	6	2	184	80	27	29	135	0
17/08/2020	15	16	0	10	1	219	74	28	29	162	0
18/08/2020	16	16	0	11	2	153	74	27	29	207	0
19/08/2020	16	21	0	14	2	135	73	28	29	206	0
20/08/2020	22	19	0	16	1	136	75	27	29	195	0
21/08/2020	25	20	0	19	2	177	68	28	29	248	0
22/08/2020	32	32	0	22	1	183	77	27	30	194	0
23/08/2020	36	11	0	22	2	173	76	28	30	210	0
24/08/2020	18	18	0	20	1	185	74	28	29	208	0
25/08/2020	23	16	0	22	2	188	73	27	30	229	0
26/08/2020	15	16	0	22	3	196	68	27	30	213	0
27/08/2020	22	18	1	27	2	154	70	27	29	237	0
28/08/2020	21	8	0	23	2	139	74	27	29	182	0
29/08/2020	17	9	0	21	2	172	72	28	29	144	0
30/08/2020	21	17	0	27	2	165	72	27	29	224	0
31/08/2020	22	20	0	30	1	203	74	27	29	203	0
01/09/2020	18	12	0	24	2	201	75	27	29	180	0
02/09/2020	13	11	0	20	2	195	78	27	29	132	0
03/09/2020	14	15	0	17	2	144	82	27	29	209	0
04/09/2020	17	24	0	17	1	149	81	28	29	238	0
05/09/2020	20	14	0	13	1	155	78	27	29	170	0
06/09/2020	13	8	0	16	1	218	76	27	29	187	0
07/09/2020	14	13	0	15	2	178	76	27	29	170	0
08/09/2020	21	26	0	16	1	166	73	28	30	251	0
09/09/2020	31	23	0	21	1	163	75	28	29	231	0
10/09/2020	22	14	0	18	1	193	74	27	29	198	0
11/09/2020	22	20	0	19	2	147	75	27	29	153	0
12/09/2020	17	21	0	21	2	170	75	27	30	143	0
13/09/2020	13	8	0	20	2	218	74	27	30	156	0
14/09/2020	22	23	0	19	1	240	76	27	29	187	0
15/09/2020	14	13	0	19	2	225	72	27	30	248	0
16/09/2020	14	12	0	18	2	206	73	27	30	173	0
17/09/2020	22	30	0	24	1	154	73	27	29	222	0
18/09/2020	23	25	0	24	1	138	72	28	29	239	0
19/09/2020	25	24	0	23	2	194	72	29	29	263	0
20/09/2020	21	8	0	20	2	221	75	28	29	188	0
21/09/2020	15	6	0	15	2	200	74	28	29	176	0
22/09/2020	13	31	0	13	2	212	81	27	30	146	0
23/09/2020	14	29	0	20	2	209	75	29	29	203	0
24/09/2020	16	8	0	11	2	212	74	28	30	232	0
25/09/2020	11	8	1	13	2	179	75	28	29	196	0

26/09/2020	10	5	0	12	2	219	74	28	29	157	0
27/09/2020	11	2	0	11	2	187	72	28	29	162	0
28/09/2020	12	10	0	14	2	201	74	28	30	175	0
29/09/2020	15	6	0	14	3	199	75	28	29	197	0
30/09/2020	14	11	0	17	2	215	76	28	29	156	0
01/10/2020	14	10	0	18	2	190	74	29	29	231	0
02/10/2020	15	12	0	16	2	153	76	29	29	231	0
03/10/2020	11	14	0	14	2	196	76	28	29	150	0
04/10/2020	12	2	0	16	3	189	75	28	30	195	0
05/10/2020	11	20	0	18	1	185	84	25	29	96	0
06/10/2020	14	11	0	20	3	181	76	26	29	104	0
07/10/2020	16	12	0	28	2	196	73	27	29	152	0
08/10/2020	16	12	0	23	2	177	76	27	29	153	0
09/10/2020	14	12	0	22	1	185	75	28	29	181	0
10/10/2020	20	33	0	17	1	236	86	26	29	83	1
11/10/2020	18	18	0	14	2	201	77	28	29	256	0
12/10/2020	11	20	0	17	2	183	78	28	29	177	0
13/10/2020	16	23	0	14	2	196	77	28	29	209	0
14/10/2020	18	19	0	16	1	182	77	28	29	228	0
15/10/2020	17	13	0	16	2	175	78	28	29	184	0
16/10/2020	15	15	0	15	1	187	84	26	29	39	0
17/10/2020	16	14	0	17	1	215	77	27	29	164	0
18/10/2020	16	14	0	13	1	175	79	27	29	154	0
19/10/2020	20	37	0	20	1	187	86	26	29	141	0
20/10/2020	23	29	0	20	1	133	80	28	29	266	0
21/10/2020	13	35	0	19	1	149	85	27	29	181	1
22/10/2020	28	51	0	22	1	171	81	28	29	145	0
23/10/2020	17	27	0	16	1	195	81	28	29	149	0
24/10/2020	18	32	0	13	1	212	80	28	29	190	0
25/10/2020	14	20	0	11	1	177	86	27	29	158	1
26/10/2020	8	26	0	16	1	201	87	27	29	183	0
27/10/2020	5	22	0	13	1	182	90	25	29	76	0
28/10/2020	0	26	5	14	1	180	87	26	29	155	0
29/10/2020	0	28	1	6	2	180	78	29	29	259	0
30/10/2020	0	29	0	11	1	189	82	28	29	206	1
31/10/2020	0	32	0	23	2	207	88	26	29	187	1
01/11/2020	19	27	0	33	1	161	84	27	29	212	0
02/11/2020	8	25	0	20	1	228	84	27	29	235	0
03/11/2020	11	30	0	19	1	267	84	27	29	178	0
04/11/2020	17	33	5	30	1	182	83	27	29	204	0
05/11/2020	15	26	0	27	1	204	81	28	29	221	0
06/11/2020	14	26	0	25	1	196	78	29	29	241	0
07/11/2020	13	23	0	25	2	158	75	29	29	245	0
08/11/2020	17	23	0	24	1	175	76	29	29	232	0
09/11/2020	14	23	0	21	2	162	77	29	29	164	0
10/11/2020	13	23	0	22	2	149	76	29	29	246	0

11/11/2020	13	24	0	22	3	142	77	29	29	187	0
12/11/2020	21	27	0	21	2	156	76	29	29	243	0
13/11/2020	23	25	0	26	2	179	77	29	29	260	0
14/11/2020	19	28	0	34	2	205	83	27	29	195	0
15/11/2020	15	29	0	36	1	188	87	26	29	206	0
16/11/2020	12	25	0	30	2	181	81	28	29	262	0
17/11/2020	11	20	0	29	3	148	77	29	29	187	0
18/11/2020	11	22	0	31	2	151	75	29	29	222	0
19/11/2020	14	26	0	31	2	185	82	28	29	235	1
20/11/2020	13	25	0	35	1	154	85	27	29	185	0
21/11/2020	23	33	0	31	1	144	86	27	29	159	0
22/11/2020	10	22	0	27	2	218	85	26	29	177	1
23/11/2020	16	26	0	25	1	212	85	27	29	133	0
24/11/2020	12	25	0	28	1	219	84	27	29	179	0
25/11/2020	14	35	0	34	1	282	89	25	29	66	0
26/11/2020	19	33	6	37	1	202	81	27	29	199	0
27/11/2020	18	29	1	29	1	224	81	27	29	194	0
28/11/2020	13	25	0	28	1	244	81	27	29	196	0
29/11/2020	6	26	0	26	1	244	93	24	29	93	0
30/11/2020	13	28	0	28	1	169	83	27	29	217	0
01/12/2020	17	29	0	26	1	177	81	27	29	200	0
02/12/2020	16	30	0	31	1	161	84	27	29	185	0
03/12/2020	15	30	0	38	1	210	86	27	29	170	0
04/12/2020	15	29	0	44	2	175	86	27	29	279	0
05/12/2020	22	35	0	0	3	165	82	28	29	420	0
06/12/2020	22	35	0	0	3	165	82	28	29	420	0
07/12/2020	22	35	0	0	3	165	82	28	29	420	0
08/12/2020	22	35	0	0	3	165	82	28	29	420	0
09/12/2020	22	35	0	0	3	165	82	28	29	420	0
10/12/2020	22	35	0	0	3	165	82	28	29	420	0
11/12/2020	19	34	0	74	2	200	83	28	29	275	0
12/12/2020	8	24	0	55	1	268	88	26	29	173	1
13/12/2020	9	24	1	63	1	150	89	26	29	125	0
14/12/2020	10	26	0	59	1	217	90	25	29	112	1
15/12/2020	12	26	2	51	1	225	86	26	29	125	0
16/12/2020	12	23	0	61	1	226	82	27	29	203	0
17/12/2020	8	21	0	61	1	259	93	25	29	80	1
18/12/2020	7	26	0	74	1	288	92	24	29	124	0
19/12/2020	11	24	1	68	1	227	86	26	29	202	0
20/12/2020	9	18	0	78	2	238	76	28	29	282	0
21/12/2020	26	22	1	71	1	178	78	27	29	215	0
22/12/2020	17	20	0	81	2	215	80	28	29	198	0
23/12/2020	17	22	0	16	1	216	78	28	29	233	0
24/12/2020	22	24	4	13	1	247	78	28	29	245	0
25/12/2020	19	23	2	5	1	235	84	27	29	172	0
26/12/2020	13	26	2	1	0	239	90	26	29	167	1

27/12/2020	12	26	1	0	1	198	86	27	29	223	0
28/12/2020	9	20	0	2	1	199	83	27	29	214	0
29/12/2020	8	20	0	20	1	246	84	27	29	195	0
30/12/2020	6	23	0	10	1	248	93	25	29	91	1
31/12/2020	6	21	0	20	1	233	88	26	29	182	1
01/01/2021	13	26	1	1	1	265	91	25	29	21	0
02/01/2021	6	21	3	7	1	174	88	25	29	94	0
03/01/2021	12	24	4	13	0	266	85	25	29	92	0
04/01/2021	9	21	2	19	1	234	82	25	29	40	0
05/01/2021	18	23	1	39	0	0	65	32	29	0	0
06/01/2021	25	27	3	65	1	130	91	25	29	88	0
07/01/2021	21	29	3	17	0	116	92	25	29	101	0
08/01/2021	18	27	5	20	0	43	92	25	29	53	0
09/01/2021	13	22	2	5	0	263	90	25	29	95	0
10/01/2021	7	24	3	10	0	210	95	24	29	65	1
11/01/2021	11	27	8	23	0	135	95	24	29	71	0
12/01/2021	8	25	20	25	1	202	85	27	29	169	0
13/01/2021	6	19	21	62	1	264	82	27	29	154	0
14/01/2021	8	23	21	84	1	263	82	27	29	154	0
15/01/2021	18	26	24	65	1	263	80	28	29	172	0
16/01/2021	13	21	21	90	1	283	77	27	29	171	0
17/01/2021	22	27	27	45	1	214	79	28	29	187	0
18/01/2021	14	23	29	35	1	195	82	27	29	171	0
19/01/2021	22	25	26	110	1	135	88	26	29	180	0
20/01/2021	25	27	25	61	1	162	85	27	29	220	0
21/01/2021	18	28	25	95	1	115	82	27	29	191	0
22/01/2021	16	24	23	106	1	188	82	27	29	200	0
23/01/2021	32	28	24	120	1	137	78	28	29	167	0
24/01/2021	34	25	25	69	1	149	80	28	29	138	0
25/01/2021	31	25	22	63	1	168	77	28	29	217	0
26/01/2021	19	22	22	92	2	204	82	27	29	236	0
27/01/2021	6	21	21	98	1	255	89	25	29	170	1
28/01/2021	5	22	19	90	1	199	85	26	29	151	0
29/01/2021	18	31	22	98	0	190	91	25	29	111	0
30/01/2021	26	31	23	127	1	186	86	26	29	129	0
31/01/2021	21	24	19	92	1	159	84	27	29	149	0
01/02/2021	19	26	20	99	2	140	83	27	29	267	0
02/02/2021	20	24	19	88	1	173	85	27	29	172	0
03/02/2021	20	25	22	66	1	148	86	27	29	203	0
04/02/2021	16	25	21	56	2	168	85	27	29	284	0
05/02/2021	17	24	21	83	1	150	83	28	29	199	0
06/02/2021	26	23	22	67	1	176	83	28	29	139	0
07/02/2021	19	23	21	61	1	221	85	27	29	151	0
08/02/2021	15	27	25	34	1	125	90	26	29	101	1
09/02/2021	22	23	21	31	1	166	88	26	29	172	0
10/02/2021	8	33	26	47	1	181	91	25	29	107	1

11/02/2021	13	28	26	61	1	213	82	28	29	225	0
12/02/2021	9	19	20	90	1	212	84	27	29	113	0
13/02/2021	10	21	20	92	1	148	86	27	29	202	0
14/02/2021	21	25	22	89	1	167	85	27	29	137	0
15/02/2021	25	25	22	68	1	188	84	27	29	198	0
16/02/2021	26	27	23	47	1	152	85	27	29	187	0
17/02/2021	28	26	22	86	1	245	87	25	29	78	0
18/02/2021	12	28	23	121	1	182	81	27	29	243	0
19/02/2021	21	34	25	146	1	156	87	26	29	152	0
20/02/2021	30	26	21	148	1	164	85	26	29	163	0
21/02/2021	25	23	20	134	1	154	77	28	29	269	0
22/02/2021	24	25	23	103	1	234	78	28	29	209	0
23/02/2021	16	22	18	137	1	276	80	26	29	108	0
24/02/2021	12	24	19	167	1	232	83	26	29	161	0
25/02/2021	24	12	22	68	2	198	81	28	29	185	0
26/02/2021	20	9	27	25	1	178	88	26	29	140	1
27/02/2021	15	12	21	93	1	138	82	27	29	222	0
28/02/2021	12	14	19	84	1	163	83	26	29	162	0
01/03/2021	21	17	25	49	1	173	73	29	29	272	0
02/03/2021	41	15	23	25	2	154	79	27	29	155	0
03/03/2021	21	15	20	56	1	158	84	26	29	123	1
04/03/2021	23	16	25	13	1	165	79	28	29	244	0
05/03/2021	25	13	24	10	1	183	76	29	29	250	0
06/03/2021	21	11	24	23	1	222	78	28	29	199	0
07/03/2021	7	7	18	6	1	217	85	26	29	228	0
08/03/2021	11	10	22	6	1	222	87	26	29	161	0
09/03/2021	12	14	19	25	1	155	86	26	29	123	0
10/03/2021	16	22	25	18	1	178	88	25	29	205	1
11/03/2021	27	17	19	26	1	132	85	26	29	142	0
12/03/2021	28	18	22	11	1	206	81	27	29	162	0
13/03/2021	17	11	19	5	1	205	83	27	29	213	0
14/03/2021	12	8	18	3	1	269	79	28	29	257	0
15/03/2021	16	16	23	2	1	182	81	27	29	178	0
16/03/2021	22	10	22	1	1	209	78	28	29	200	0
17/03/2021	14	9	19	1	1	220	80	27	29	188	0
18/03/2021	15	15	22	5	1	178	87	26	29	162	1
19/03/2021	20	14	21	4	1	156	81	28	29	246	0
20/03/2021	12	9	18	2	1	191	84	27	29	170	0
21/03/2021	16	8	20	1	1	242	79	28	29	234	0
22/03/2021	15	9	18	7	1	242	76	28	29	166	0
23/03/2021	15	6	17	5	1	225	77	29	29	242	0
24/03/2021	18	8	20	5	1	256	75	29	29	258	0
25/03/2021	10	8	17	5	1	227	80	28	29	223	0
26/03/2021	16	7	20	6	1	256	79	29	29	232	0
27/03/2021	15	9	18	5	1	157	82	28	29	175	0
28/03/2021	18	10	16	3	1	217	81	28	29	168	0

29/03/2021	15	11	22	2	1	144	81	28	29	166	0
30/03/2021	15	15	20	12	1	161	91	26	29	98	1
31/03/2021	19	15	22	19	1	207	83	28	29	210	0
01/04/2021	13	12	19	29	1	264	86	27	29	158	1
02/04/2021	12	13	16	47	1	204	82	28	29	197	0
03/04/2021	24	21	23	43	1	226	86	27	29	127	1
04/04/2021	19	15	18	47	1	124	87	26	29	155	1
05/04/2021	17	23	23	54	1	153	85	27	29	181	0
06/04/2021	25	12	18	35	1	195	87	27	29	154	0
07/04/2021	15	23	27	42	1	240	86	27	29	165	0
08/04/2021	26	10	20	47	1	155	79	28	29	217	0
09/04/2021	35	10	15	78	1	168	79	28	29	215	0
10/04/2021	33	14	13	112	1	218	82	28	29	146	0
11/04/2021	16	8	13	51	1	163	82	28	29	201	0
12/04/2021	17	9	15	43	1	205	81	28	30	241	1
13/04/2021	20	13	19	47	1	265	82	27	29	167	0
14/04/2021	17	12	18	74	1	211	83	27	29	168	0
15/04/2021	12	9	17	65	2	213	81	28	29	219	0
16/04/2021	11	8	14	68	1	152	78	28	29	195	0
17/04/2021	17	9	15	38	2	170	75	28	29	218	0
18/04/2021	23	7	13	45	1	192	78	28	30	162	0
19/04/2021	18	9	17	44	1	208	74	29	29	258	0
20/04/2021	12	7	14	54	2	167	72	28	29	217	0
21/04/2021	13	9	16	89	2	205	71	28	29	258	0
22/04/2021	14	8	15	155	2	242	71	28	29	246	0
23/04/2021	15	10	16	121	1	229	73	28	29	156	0
24/04/2021	17	11	15	144	1	166	76	27	29	142	0
25/04/2021	17	10	16	70	1	214	78	28	29	129	0
26/04/2021	25	10	17	52	1	143	77	28	29	187	0
27/04/2021	24	10	24	39	2	233	76	29	29	226	0
28/04/2021	17	9	16	74	1	210	76	28	30	120	0
29/04/2021	22	13	18	90	1	224	75	28	29	234	0
30/04/2021	23	12	18	185	1	241	80	28	29	131	0
01/05/2021	34	9	21	120	2	160	76	29	29	212	0
02/05/2021	32	9	16	126	1	169	77	29	29	201	0
03/05/2021	23	9	14	62	1	211	76	29	29	215	0
04/05/2021	29	7	16	114	1	183	76	29	29	155	0
05/05/2021	27	11	17	189	1	146	78	29	29	138	0
06/05/2021	23	9	21	194	1	204	77	29	29	208	0
07/05/2021	15	6	23	113	1	214	78	29	29	163	0
08/05/2021	22	13	23	93	1	192	79	28	29	112	0
09/05/2021	16	7	19	90	1	229	74	28	29	214	0
10/05/2021	20	8	19	117	1	219	75	28	29	185	0
11/05/2021	20	9	20	140	1	171	77	29	29	183	0
12/05/2021	20	6	23	126	1	166	76	29	29	137	0
13/05/2021	24	7	17	133	1	230	74	29	29	164	0

14/05/2021	23	7	16	58	1	98	75	29	29	156	0
15/05/2021	18	7	20	32	1	223	75	29	29	169	0
16/05/2021	17	6	15	65	1	212	77	28	29	169	0
17/05/2021	21	5	20	26	1	246	77	28	29	120	0
18/05/2021	22	9	17	126	1	242	76	28	29	172	0
19/05/2021	24	9	14	156	1	240	78	28	29	142	0
20/05/2021	28	16	20	165	1	184	84	27	29	130	0
21/05/2021	24	12	17	108	1	173	82	28	29	157	0
22/05/2021	23	9	13	102	1	239	83	27	29	142	0
23/05/2021	21	5	12	46	1	260	81	28	29	171	0
24/05/2021	27	11	13	49	1	220	81	28	29	115	0
25/05/2021	34	13	14	75	1	220	84	27	29	107	0
26/05/2021	40	10	19	83	1	214	79	29	29	179	0
27/05/2021	28	7	22	135	1	187	74	29	29	214	0
28/05/2021	32	7	21	185	1	245	82	28	29	128	0
29/05/2021	23	12	21	151	1	273	84	28	29	132	0
30/05/2021	21	9	15	67	1	255	80	28	29	175	0
31/05/2021	20	8	21	34	1	210	81	28	29	129	0
01/06/2021	25	11	18	118	1	199	80	28	29	128	0
02/06/2021	36	12	25	46	1	210	79	29	29	169	0
03/06/2021	44	12	30	39	1	163	79	29	29	173	0
04/06/2021	47	12	32	192	1	168	80	28	29	134	0

Lampiran B Tabel Prediksi PM10

Tanggal	Actual	Prediksi	Selisih
21/02/2021	25	24	1
22/02/2021	24	22	2
23/02/2021	16	21	5
24/02/2021	12	17	5
25/02/2021	24	14	10
26/02/2021	20	20	0
27/02/2021	15	19	4
28/02/2021	12	16	4
01/03/2021	21	14	7
02/03/2021	41	18	23
03/03/2021	21	29	8
04/03/2021	23	21	2
05/03/2021	25	20	5
06/03/2021	21	21	0
07/03/2021	7	20	13
08/03/2021	11	12	1
09/03/2021	12	13	1
10/03/2021	16	14	2
11/03/2021	27	16	11
12/03/2021	28	22	6
13/03/2021	17	23	6
14/03/2021	12	18	6

15/03/2021	16	14	2
16/03/2021	22	16	6
17/03/2021	14	19	5
18/03/2021	15	16	1
19/03/2021	20	16	4
20/03/2021	12	18	6
21/03/2021	16	15	1
22/03/2021	15	16	1
23/03/2021	15	16	1
24/03/2021	18	16	2
25/03/2021	10	17	7
26/03/2021	16	14	2
27/03/2021	15	16	1
28/03/2021	18	16	2
29/03/2021	15	17	2
30/03/2021	15	16	1
31/03/2021	19	16	3
01/04/2021	13	18	5
02/04/2021	12	15	3
03/04/2021	24	14	10
04/04/2021	19	20	1
05/04/2021	17	19	2
06/04/2021	25	17	8
07/04/2021	15	21	6
08/04/2021	26	17	9
09/04/2021	35	21	14
10/04/2021	33	27	6
11/04/2021	16	26	10
12/04/2021	17	18	1
13/04/2021	20	17	3
14/04/2021	17	18	1
15/04/2021	12	17	5
16/04/2021	11	14	3
17/04/2021	17	13	4
18/04/2021	23	16	7
19/04/2021	18	20	2
20/04/2021	12	18	6
21/04/2021	13	14	1
22/04/2021	14	14	0
23/04/2021	15	15	0
24/04/2021	17	16	1
25/04/2021	17	17	0
26/04/2021	25	17	8
27/04/2021	24	21	3
28/04/2021	17	21	4
29/04/2021	22	17	5
30/04/2021	23	19	4
01/05/2021	34	20	14
02/05/2021	32	26	6
03/05/2021	23	26	3

04/05/2021	29	21	8
05/05/2021	27	23	4
06/05/2021	23	23	0
07/05/2021	15	21	6
08/05/2021	22	16	6
09/05/2021	16	19	3
10/05/2021	20	17	3
11/05/2021	20	18	2
12/05/2021	20	19	1
13/05/2021	24	19	5
14/05/2021	23	21	2
15/05/2021	18	21	3
16/05/2021	17	18	1
17/05/2021	21	17	4
18/05/2021	22	19	3
19/05/2021	24	20	4
20/05/2021	28	21	7
21/05/2021	24	23	1
22/05/2021	23	21	2
23/05/2021	21	20	1
24/05/2021	27	19	8
25/05/2021	34	22	12
26/05/2021	40	26	14
27/05/2021	28	30	2
28/05/2021	32	24	8
29/05/2021	23	25	2
30/05/2021	21	21	0
31/05/2021	20	19	1
01/06/2021	25	19	6
02/06/2021	36	21	15
03/06/2021	44	27	17
04/06/2021	47	32	15

Lampiran C Tabel Prediksi CO

Tanggal	Actual	Prediksi	Selisih
21/02/2021	23	28	5
22/02/2021	25	25	0
23/02/2021	22	25	3
24/02/2021	24	23	1
25/02/2021	12	25	3
26/02/2021	9	17	-8
27/02/2021	12	15	3
28/02/2021	14	12	2
01/03/2021	17	12	5
02/03/2021	15	15	0
03/03/2021	15	15	0
04/03/2021	16	16	0
05/03/2021	13	16	3

06/03/2021	11	14	3
07/03/2021	7	13	6
08/03/2021	10	10	0
09/03/2021	14	10	4
10/03/2021	22	12	10
11/03/2021	17	18	1
12/03/2021	18	17	1
13/03/2021	11	20	9
14/03/2021	8	14	6
15/03/2021	16	12	4
16/03/2021	10	14	4
17/03/2021	9	10	1
18/03/2021	15	11	4
19/03/2021	14	13	1
20/03/2021	9	13	4
21/03/2021	8	11	3
22/03/2021	9	10	1
23/03/2021	6	9	3
24/03/2021	8	8	0
25/03/2021	8	9	1
26/03/2021	7	8	1
27/03/2021	9	8	1
28/03/2021	10	9	1
29/03/2021	11	9	2
30/03/2021	15	10	5
31/03/2021	15	13	2
01/04/2021	12	14	2
02/04/2021	13	13	0
03/04/2021	21	14	7
04/04/2021	15	18	3
05/04/2021	23	15	8
06/04/2021	12	23	11
07/04/2021	23	14	9
08/04/2021	10	23	13
09/04/2021	10	12	2
10/04/2021	14	15	1
11/04/2021	8	12	4
12/04/2021	9	10	1
13/04/2021	13	11	2
14/04/2021	12	11	1
15/04/2021	9	11	2
16/04/2021	8	11	3
17/04/2021	9	10	1
18/04/2021	7	9	2
19/04/2021	9	8	1
20/04/2021	7	9	2

21/04/2021	9	8	1
22/04/2021	8	9	1
23/04/2021	10	9	1
24/04/2021	11	10	1
25/04/2021	10	10	0
26/04/2021	10	10	0
27/04/2021	10	10	0
28/04/2021	9	10	1
29/04/2021	13	10	3
30/04/2021	12	12	0
01/05/2021	9	11	2
02/05/2021	9	11	2
03/05/2021	9	10	1
04/05/2021	7	9	2
05/05/2021	11	8	3
06/05/2021	9	10	1
07/05/2021	6	9	3
08/05/2021	13	9	4
09/05/2021	7	11	4
10/05/2021	8	9	1
11/05/2021	9	10	1
12/05/2021	6	9	3
13/05/2021	7	8	1
14/05/2021	7	8	1
15/05/2021	7	8	1
16/05/2021	6	8	2
17/05/2021	5	8	3
18/05/2021	9	8	1
19/05/2021	9	9	0
20/05/2021	16	9	7
21/05/2021	12	13	1
22/05/2021	9	12	3
23/05/2021	5	12	7
24/05/2021	11	8	3
25/05/2021	13	10	3
26/05/2021	10	11	1
27/05/2021	7	11	4
28/05/2021	7	9	2
29/05/2021	12	9	3
30/05/2021	9	10	1
31/05/2021	8	9	1
01/06/2021	11	10	1
02/06/2021	12	10	2
03/06/2021	12	11	1
04/06/2021	12	12	0

Lampiran D Tabel Prediksi SO₂

Tanggal	Actual	Prediksi	Selisih
21/02/2021	20	17	3
22/02/2021	23	18	5
23/02/2021	18	18	0
24/02/2021	19	19	0
25/02/2021	22	18	4
26/02/2021	27	20	7
27/02/2021	21	19	2
28/02/2021	19	19	0
01/03/2021	25	15	10
02/03/2021	23	19	4
03/03/2021	20	20	0
04/03/2021	25	18	7
05/03/2021	24	17	7
06/03/2021	24	19	5
07/03/2021	18	20	2
08/03/2021	22	19	3
09/03/2021	19	20	1
10/03/2021	25	18	7
11/03/2021	19	19	0
12/03/2021	22	20	2
13/03/2021	19	20	1
14/03/2021	18	16	2
15/03/2021	23	20	3
16/03/2021	22	19	3
17/03/2021	19	20	1
18/03/2021	22	20	2
19/03/2021	21	19	2
20/03/2021	18	21	3
21/03/2021	20	18	2
22/03/2021	18	18	0
23/03/2021	17	16	1
24/03/2021	20	15	5
25/03/2021	17	19	2
26/03/2021	20	16	4
27/03/2021	18	19	1
28/03/2021	16	19	3
29/03/2021	22	18	4
30/03/2021	20	19	1
31/03/2021	22	19	3
01/04/2021	19	19	0
02/04/2021	16	19	3
03/04/2021	23	19	4
04/04/2021	18	18	0
05/04/2021	23	19	4
06/04/2021	18	21	3
07/04/2021	27	18	9
08/04/2021	20	19	1

09/04/2021	15	18	3
10/04/2021	13	18	5
11/04/2021	13	17	4
12/04/2021	15	16	1
13/04/2021	19	16	3
14/04/2021	18	19	1
15/04/2021	17	17	0
16/04/2021	14	18	4
17/04/2021	15	15	0
18/04/2021	13	17	4
19/04/2021	17	14	3
20/04/2021	14	14	0
21/04/2021	16	13	3
22/04/2021	15	14	1
23/04/2021	16	15	1
24/04/2021	15	17	2
25/04/2021	16	17	1
26/04/2021	17	16	1
27/04/2021	24	14	10
28/04/2021	16	18	2
29/04/2021	18	16	2
30/04/2021	18	18	0
01/05/2021	21	15	6
02/05/2021	16	17	1
03/05/2021	14	16	2
04/05/2021	16	16	0
05/05/2021	17	16	1
06/05/2021	21	16	5
07/05/2021	23	17	6
08/05/2021	23	19	4
09/05/2021	19	18	1
10/05/2021	19	18	1
11/05/2021	20	17	3
12/05/2021	23	17	6
13/05/2021	17	17	0
14/05/2021	16	14	2
15/05/2021	20	16	4
16/05/2021	15	18	3
17/05/2021	20	16	4
18/05/2021	17	17	0
19/05/2021	14	18	4
20/05/2021	20	19	1
21/05/2021	17	19	2
22/05/2021	13	18	5
23/05/2021	12	16	4
24/05/2021	13	16	3
25/05/2021	14	17	3
26/05/2021	19	15	4
27/05/2021	22	15	7
28/05/2021	21	18	3

29/05/2021	21	17	4
30/05/2021	15	18	3
31/05/2021	21	18	3
01/06/2021	18	19	1
02/06/2021	25	17	8
03/06/2021	30	18	12
04/06/2021	32	19	13

Lampiran D Tabel Prediksi O₃

Tanggal	Actual	Prediksi	Selisih
19/03/2021	4	4	0
20/03/2021	2	3	1
21/03/2021	1	3	2
22/03/2021	7	2	5
23/03/2021	5	6	1
24/03/2021	5	4	1
25/03/2021	5	5	0
26/03/2021	6	4	2
27/03/2021	5	5	0
28/03/2021	3	4	1
29/03/2021	2	3	1
30/03/2021	12	3	9
31/03/2021	19	9	10
01/04/2021	29	19	10
02/04/2021	47	26	21
03/04/2021	43	38	5
04/04/2021	47	32	15
05/04/2021	54	41	13
06/04/2021	35	49	14
07/04/2021	42	31	11
08/04/2021	47	41	6
09/04/2021	78	38	40
10/04/2021	112	62	50
11/04/2021	51	67	16
12/04/2021	43	47	4
13/04/2021	47	55	8
14/04/2021	74	42	32
15/04/2021	65	61	4
16/04/2021	68	61	7
17/04/2021	38	64	26
18/04/2021	45	39	6
19/04/2021	44	50	6
20/04/2021	54	37	17
21/04/2021	89	48	41
22/04/2021	155	68	87
23/04/2021	121	50	71
24/04/2021	144	50	94
25/04/2021	70	52	18
26/04/2021	52	49	3
27/04/2021	39	52	13

28/04/2021	74	46	28
29/04/2021	90	56	34
30/04/2021	185	64	121
01/05/2021	120	49	71
02/05/2021	126	49	77
03/05/2021	62	49	13
04/05/2021	114	53	61
05/05/2021	189	52	137
06/05/2021	194	49	145
07/05/2021	113	49	64
08/05/2021	93	49	44
09/05/2021	90	49	41
10/05/2021	117	66	51
11/05/2021	140	66	74
12/05/2021	126	64	62
13/05/2021	133	54	79
14/05/2021	58	57	1
15/05/2021	32	50	18
16/05/2021	65	50	15
17/05/2021	26	47	21
18/05/2021	126	26	100
19/05/2021	156	51	105
20/05/2021	165	49	116
21/05/2021	108	55	53
22/05/2021	102	51	51
23/05/2021	46	50	4
24/05/2021	49	49	0
25/05/2021	75	58	17
26/05/2021	83	63	20
27/05/2021	135	71	64
28/05/2021	185	54	131
29/05/2021	151	51	100
30/05/2021	67	50	17
31/05/2021	34	49	15
01/06/2021	118	54	64
02/06/2021	46	53	-7
03/06/2021	39	55	16
04/06/2021	192	52	140