

**PREDIKSI NILAI IMPOR MIGAS DI INDONESIA MENGGUNAKAN
METODE *SUPPORT VECTOR REGRESSION***

SKRIPSI

Oleh :
MOCHAMAD THORIQ KHOIR
NIM. 210605110153



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

**PREDIKSI NILAI IMPOR MIGAS DI INDONESIA MENGGUNAKAN
METODE *SUPPORT VECTOR REGRESSION***

SKRIPSI

Diajukan kepada:
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Sarjana Komputer (S.Kom)

Oleh :
MOCHAMAD THORIQ KHOIR
NIM. 210605110153

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2025**

HALAMAN PERSETUJUAN

**PREDIKSI NILAI IMPOR MIGAS DI INDONESIA MENGGUNAKAN
METODE *SUPPORT VECTOR REGRESSION***

SKRIPSI

**Oleh :
MOCHAMAD THORIQ KHOIR
NIM. 210605110153**

Telah Diperiksa dan Disetujui untuk Diuji:
Tanggal: 29 April 2025

Pembimbing I,



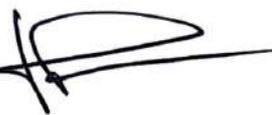
Prof. Dr. Muhammad Faisal, M.T
NIP. 19740510 200501 1 007

Pembimbing II,



Dr. Ir. Yunifa Miftachul Arif, M.T
NIP. 19830616 201101 1 004

Mengetahui,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang



Dr. Ir. Fachrul Kurniawan, M.MT., IPU
NIP. 19771020 200912 1 001

HALAMAN PENGESAHAN

PREDIKSI NILAI IMPOR MIGAS DI INDONESIA MENGGUNAKAN METODE *SUPPORT VECTOR REGRESSION*

SKRIPSI

Oleh :
MOCHAMAD THORIQ KHOIR
NIM. 210605110153

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 26 Mei 2025

Susunan Dewan Penguji

Ketua Penguji : Dr. Ir. Fachrul Kurniawan, M.MT., IPU
NIP. 19771020 200912 1 001

Anggota Penguji I : Fajar Rohman Hariri, M.Kom
NIP. 19890515 201801 1 001

Anggota Penguji II : Prof. Dr. Muhammad Faisal, M.T
NIP. 19740510 200501 1 007

Anggota Penguji III : Dr. Ir. Yunifa Miftachul Arif, M.T
NIP. 19830616 201101 1 004

()
()
()
()

Mengetahui,
Ketua Program Studi Teknik Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang




Dr. Ir. Fachrul Kurniawan, M.MT., IPU
NIP. 19771020 200912 1 001

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Mochamad Thoriq Khoir
NIM : 210605110153
Fakultas / Program Studi : Sains dan Teknologi / Teknik Informatika
Judul Skripsi : Prediksi Nilai Impor Migas Di Indonesia
Menggunakan Metode *Support Vector Regression*

Menyatakan dengan sebenarnya bahwa Skripsi yang saya tulis ini benar-benar merupakan hasil karya saya sendiri, bukan merupakan pengambil alihan data, tulisan, atau pikiran orang lain yang saya akui sebagai hasil tulisan atau pikiran saya sendiri, kecuali dengan mencantumkan sumber cuplikan pada daftar pustaka.

Apabila dikemudian hari terbukti atau dapat dibuktikan skripsi ini merupakan hasil jiplakan, maka saya bersedia menerima sanksi atas perbuatan tersebut.

Malang,
Yang membuat pernyataan,



Mochamad Thoriq Khoir
NIM. 210605110153

MOTO

“Urip iku urup (hidup itu menghidupi).”

HALAMAN PERSEMBAHAN

Dengan penuh rasa syukur kepada Allah SWT, skripsi ini penulis persembahkan untuk ibu saya Nurlayla dan ayah saya Hadi Mustofa, atas doa, kasih sayang, dan dukungan yang tak pernah putus. Untuk kakak perempuan saya Nurul Hidayati, yang menjadi penyemangat dan pemberi dorongan mental dalam setiap langkah. Untuk kakak laki-laki saya Muhammad Rosyid Ridho yang menjadi sumber pendukung materi. Untuk keluarga dan saudara-saudara yang selalu mendoakan dan memberi semangat. Untuk seluruh dosen yang telah membimbing dan berbagi ilmu selama masa studi. Untuk sahabat dan teman-teman seperjuangan yang hadir dalam suka dan duka. Dan untuk diri saya sendiri, sebagai bentuk penghargaan atas usaha, ketekunan, dan semangat yang tak pernah padam.

KATA PENGANTAR

Assalamualaikum Warahmatullahi Wabarakatuh.

Segala puji dan syukur penulis panjatkan ke hadirat Allah Subhanahu wa Ta'ala atas limpahan rahmat dan karunia-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul “Prediksi nilai impor migas di Indonesia menggunakan metode *support vector regression*.” Shalawat dan salam semoga senantiasa tercurah kepada Nabi Muhammad SAW, sebagai teladan utama umat manusia.

Dengan penuh rasa syukur dan kerendahan hati, penulis menyampaikan terima kasih yang sebesar-besarnya kepada semua pihak yang telah memberikan dukungan, doa, motivasi, serta bantuan dalam proses penyusunan skripsi ini. Ucapan terima kasih khusus penulis sampaikan kepada:

1. Prof. Dr. H. M. Zainuddin, M.A., selaku rektor Universitas Islam Negeri Maulana Malik Ibrahim Malang.
2. Prof. Dr. Hj. Sri Hariani, M.Si., selaku dekan Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang.
3. Dr. Ir. Fachrul Kurniawan, M.MT., IPU selaku Ketua Program Studi Teknik Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang.
4. Prof. Dr. Muhammad Faisal, M.T., selaku Dosen Pembimbing 1 dan Dr. Ir. Yunifa Miftachul Arif, M. T., selaku Dosen Pembimbing 2 yang telah memberikan bimbingan, arahan, masukan, dan motivasi dalam proses penyusunan skripsi ini.

5. Dr. Ir. Fachrul Kurniawan, M.MT., IPU., selaku penguji I dan Fajar Rohman Hariri, M.Kom., selaku penguji II yang telah memberikan masukan berharga demi kesempurnaan karya ini.
6. Seluruh Dosen, Admin, Laboran dan Civitas Akademik Program Studi Teknik Informatika yang telah membekali penulis dengan ilmu dan pengalaman selama masa perkuliahan.
7. Kedua orang tua tercinta, Ibu Nurlayla dan Bapak Hadi Mustofa, yang dengan penuh cinta, doa, dan dukungan moral maupun material senantiasa menjadi kekuatan utama penulis. Juga kepada kakak penulis, Nurul Hidayati dan Muhammad Rosyid Ridho, atas dorongan semangat, material dan motivasinya sehingga penulis mampu menyelesaikan masa studi.
8. Andini Ferdiana yang telah menjadi teman, sahabat, dan sekaligus sosok istimewa yang selalu memberikan motivasi dan afirmasi positif yang tidak pernah berhenti.
9. Muchammad Alif Zaidan, Imam Tobroni, Ibni Akbar Habibi dan semua sahabat seperjuangan yang telah memberikan semangat dan kebersamaan selama masa studi.
10. Ariana Grande yang melalui karya-karyanya telah menjadi teman setia dalam setiap proses penulisan skripsi ini.
11. Diri saya sendiri atas ketekunan, kesabaran, dan semangat yang tak pernah padam, meski sering dihadapkan pada rasa lelah, keraguan, dan berbagai tantangan. Terima kasih telah memilih untuk terus melangkah.

12. Dan semua pihak yang tidak dapat disebutkan satu per satu tanpa mengurangi rasa hormat, yang telah berkontribusi dalam proses penyusunan skripsi ini.

Akhir kata, penulis menyadari bahwa skripsi ini masih jauh dari sempurna. Semoga skripsi ini dapat memberikan manfaat dan menjadi amal jariyah di sisi Allah SWT. Penulis berharap, skripsi ini dapat memberikan kontribusi positif dalam pengembangan ilmu pengetahuan dan praktik di bidang terkait.

Wassalamualaikum Warahmatullahi Wabarakatuh.

Malang, 30 April 2025

Penulis

DAFTAR ISI

HALAMAN JUDUL	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN	iv
PERNYATAAN KEASLIAN TULISAN	v
MOTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR	viii
DAFTAR ISI	xi
DAFTAR GAMBAR	xiii
ABSTRAK	xviii
ABSTRACT	xix
مستخلص البحث	xx
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	6
1.3 Batasan Masalah	6
1.4 Tujuan Penelitian	6
1.5 Manfaat Penelitian	6
BAB II STUDI PUSTAKA	7
2.1 Penelitian Terkait	7
2.2 <i>Forecasting</i> (Peramalan)	12
2.3 Data Deret waktu	12
2.4 Normalisasi Data	13
2.5 <i>Support Vector Regression</i>	14
2.6 <i>Sequential Minimal Optimization</i>	18
2.7 <i>Feature Engineering</i>	18
2.8 MAPE	19
2.9 Fungsi <i>Kernel</i>	20
BAB III DESAIN DAN IMPLEMENTASI	22
3.1 Metodologi Penelitian	22
3.2 Studi Literatur	22
3.3 Pengumpulan Data	23
3.4 Perancangan Desain Sistem	23
3.5 Implementasi Metode <i>Support Vector Regression</i>	25
3.5.1 Persiapan Data	26
3.5.2 Pra-proses data	27
3.5.3 <i>Feature engineering</i>	28
3.5.4 Normalisasi Data	28
3.5.5 Membagi data menjadi <i>training</i> dan <i>testing</i>	29
3.5.6 Perhitungan data <i>training</i> dengan <i>kernel Radial Basis Function</i>	29
3.5.7 Mendapatkan nilai <i>alpha</i> (α) dan bias (<i>b</i>)	29
3.5.8 Perhitungan prediksi nilai impor migas	33
3.5.9 Pengukuran <i>error</i> prediksi dengan MAPE	33
3.5.10 Contoh Perhitungan Manual	34
3.6 Skenario Uji Coba	42
BAB IV HASIL DAN PEMBAHASAN	44

4.1 Skenario Uji Coba.....	44
4.2 Hasil Uji Coba	46
4.2.1 Hasil dari uji coba Skenario ke-1	47
4.2.2 Hasil dari uji coba Skenario ke-2	49
4.2.3 Hasil dari uji coba Skenario ke-3	50
4.2.4 Hasil dari uji coba Skenario ke-4	52
4.2.5 Hasil dari uji coba Skenario ke-5	54
4.2.6 Hasil dari uji coba Skenario ke-6	56
4.2.7 Hasil dari uji coba Skenario ke-7	58
4.2.8 Hasil dari uji coba Skenario ke-8	60
4.2.9 Hasil dari uji coba Skenario ke-9	62
4.2.10 Hasil dari uji coba Skenario ke-10.....	64
4.2.11 Hasil dari uji coba Skenario ke-11.....	66
4.2.12 Hasil dari uji coba Skenario ke-12.....	68
4.2.13 Hasil dari uji coba Skenario ke-13.....	70
4.2.14 Hasil dari uji coba Skenario ke-14.....	72
4.2.15 Hasil dari uji coba Skenario ke-15.....	74
4.2.16 Hasil dari uji coba Skenario ke-16.....	76
4.2.17 Hasil dari uji coba Skenario ke-17.....	78
4.2.18 Hasil dari uji coba Skenario ke-18.....	80
4.2.19 Hasil dari uji coba Skenario ke-19.....	82
4.2.20 Hasil dari uji coba Skenario ke-20.....	84
4.2.21 Hasil dari uji coba Skenario ke-21.....	86
4.2.22 Hasil dari uji coba Skenario ke-22.....	88
4.2.23 Hasil dari uji coba Skenario ke-23.....	90
4.2.24 Hasil dari uji coba Skenario ke-24.....	92
4.2.25 Hasil dari uji coba Skenario ke-25.....	94
4.2.26 Hasil dari uji coba Skenario ke-26.....	96
4.2.27 Hasil dari uji coba Skenario ke-27.....	98
4.3 Pembahasan	100
4.4 Integrasi Islam	113
4.4.1 Muamalah Ma'a Allah	113
4.4.2 Muamalah Ma'a al-Alam	114
4.4.3 Muamalah Ma'a an-Nas.....	114
BAB V KESIMPULAN DAN SARAN.....	116
5.1 Kesimpulan.....	116
5.2 Saran.....	117
DAFTAR PUSTAKA	
LAMPIRAN	

DAFTAR GAMBAR

Gambar 3. 1 Metodologi Penelitian.....	22
Gambar 3. 2 Grafik data setiap bulan 2015-2024.....	23
Gambar 3. 3 Desain sistem	24
Gambar 3. 4 Cara Kerja SVR (Sethi 2020).....	26
Gambar 3. 5 <i>Flowchart</i> Algoritma SMO	30
Gambar 3. 6 Skenario Pengujian.....	42
Gambar 4. 1 Visualisasi Skenario 1.....	48
Gambar 4. 2 Visualisasi Skenario 2.....	50
Gambar 4. 3 Visualisasi Skenario 3.....	52
Gambar 4. 4 Visualisasi Skenario 4.....	54
Gambar 4. 5 Visualisasi Skenario 5.....	56
Gambar 4. 6 Visualisasi Skenario 6.....	58
Gambar 4. 7 Visualisasi Skenario 7.....	60
Gambar 4. 8 Visualisasi Skenario 8.....	62
Gambar 4. 9 Visualisasi Skenario 9.....	64
Gambar 4. 10 Visualisasi Skenario 10.....	66
Gambar 4. 11 Visualisasi Skenario 11.....	68
Gambar 4. 12 Visualisasi Skenario 12.....	70
Gambar 4. 13 Visualisasi Skenario 13.....	72
Gambar 4. 14 Visualisasi Skenario 14.....	74
Gambar 4. 15 Visualisasi Skenario 15.....	76
Gambar 4. 16 Visualisasi Skenario 16.....	78
Gambar 4. 17 Visualisasi Skenario 17.....	80
Gambar 4. 18 Visualisasi Skenario 18.....	82
Gambar 4. 19 Visualisasi Skenario 19.....	84
Gambar 4. 20 Visualisasi Skenario 20.....	86
Gambar 4. 21 Visualisasi Skenario 21.....	88
Gambar 4. 22 Visualisasi Skenario 22.....	90
Gambar 4. 23 Visualisasi Skenario 23.....	92
Gambar 4. 24 Visualisasi Skenario 24.....	94
Gambar 4. 25 Visualisasi Skenario 25.....	96
Gambar 4. 26 Visualisasi Skenario 26.....	98
Gambar 4. 27 Visualisasi Skenario 27.....	100
Gambar 4. 28 Rata-rata MAPE Berdasarkan Nilai C pada Rasio 80:20.....	104
Gambar 4. 29 Rata-rata MAPE Berdasarkan Nilai Epsilon pada Rasio 90:10....	105
Gambar 4. 30 Rata-rata MAPE Berdasarkan Nilai Epsilon pada Rasio 80:20....	107
Gambar 4. 31 Rata-rata MAPE Berdasarkan Nilai Epsilon pada Rasio 90:10	108
Gambar 4. 32 Rata-rata MAPE Berdasarkan Nilai Gamma pada Rasio 80:20 ...	109
Gambar 4. 33 Rata-rata MAPE Berdasarkan Nilai Gamma pada Rasio 80:20 ...	110
Gambar 4. 34 Visualisasi sebaran MAPE skenario 80:20.....	111

Gambar 4. 35 Visualisasi sebaran MAPE skenario 90:10.....112

DAFTAR TABEL

Tabel 2. 1 Penelitian Terdahulu.....	10
Tabel 2. 2 <i>Range</i> Nilai MAPE.....	20
Tabel 2. 3 Fungsi <i>Kernel</i>	20
Tabel 3. 1 Data Nilai Impor Migas (\$juta)	26
Tabel 3. 2 Data input perhitungan manual	34
Tabel 3. 3 Data dengan <i>feature lag</i>	35
Tabel 3. 4 Data setelah dinormalisasi	36
Tabel 3. 5 Nilai alpha disetiap titik data.....	40
Tabel 3. 6 Data hasil prediksi dengan SVR.....	41
Tabel 3. 7 Nilai Setiap Parameter	43
Tabel 4. 1 Skenario <i>Hyperparameter</i>	45
Tabel 4. 2 Parameter Skenario 1.....	47
Tabel 4. 3 Hasil Skenario 1	47
Tabel 4. 4 Nilai Keakuratan Skenario 1	48
Tabel 4. 5 Parameter Skenario 2.....	49
Tabel 4. 6 Hasil Skenario 2	49
Tabel 4. 7 Nilai Keakuratan Skenario 2	50
Tabel 4. 8 Parameter Skenario 3.....	51
Tabel 4. 9 Hasil Skenario 3	51
Tabel 4. 10 Nilai Keakuratan Skenario 3	51
Tabel 4. 11 Parameter Skenario 4.....	52
Tabel 4. 12 Hasil Skenario 4	53
Tabel 4. 13 Nilai Keakuratan Skenario 4	53
Tabel 4. 14 Parameter Skenario 5.....	54
Tabel 4. 15 Hasil Skenario 5	55
Tabel 4. 16 Nilai Keakuratan Skenario 5	55
Tabel 4. 17 Parameter Skenario 6.....	56
Tabel 4. 18 Hasil Skenario 6	56
Tabel 4. 19 Nilai Keakuratan Skenario 6	57
Tabel 4. 20 Parameter Skenario 7.....	58
Tabel 4. 21 Hasil Skenario 7	58
Tabel 4. 22 Nilai Keakuratan Skenario 7	59
Tabel 4. 23 Parameter Skenario 8.....	60
Tabel 4. 24 Hasil Skenario 8	60
Tabel 4. 25 Nilai Keakuratan Skenario 8	61
Tabel 4. 26 Parameter Skenario 9.....	62
Tabel 4. 27 Hasil Skenario 9	62
Tabel 4. 28 Nilai Keakuratan Skenario 9	63
Tabel 4. 29 Parameter Skenario 10	64
Tabel 4. 30 Hasil Skenario 10	64
Tabel 4. 31 Nilai Keakuratan Skenario 10	65
Tabel 4. 32 Parameter Skenario 11	66
Tabel 4. 33 Hasil Skenario 11	67

Tabel 4. 34 Nilai Keakuratan Skenario 11	67
Tabel 4. 35 Parameter Skenario 12	68
Tabel 4. 36 Hasil Skenario 12	68
Tabel 4. 37 Nilai Keakuratan Skenario 12	69
Tabel 4. 38 Parameter Skenario 13	70
Tabel 4. 39 Hasil Skenario 13	70
Tabel 4. 40 Nilai Keakuratan Skenario 13	71
Tabel 4. 41 Parameter Skenario 14	72
Tabel 4. 42 Hasil Skenario 14	72
Tabel 4. 43 Nilai Keakuratan Skenario 14	73
Tabel 4. 44 Parameter Skenario 15	74
Tabel 4. 45 Hasil Skenario 15	74
Tabel 4. 46 Nilai Keakuratan Skenario 15	75
Tabel 4. 47 Parameter Skenario 16	76
Tabel 4. 48 Hasil Skenario 16	76
Tabel 4. 49 Nilai Keakuratan Skenario 16	77
Tabel 4. 50 Parameter Skenario 17	78
Tabel 4. 51 Hasil Skenario 17	78
Tabel 4. 52 Nilai Keakuratan Skenario 17	79
Tabel 4. 53 Parameter Skenario 18	80
Tabel 4. 54 Hasil Skenario 18	80
Tabel 4. 55 Nilai keakuratan skenario 18.....	81
Tabel 4. 56 Parameter Skenario 19	82
Tabel 4. 57 Hasil Skenario 19	82
Tabel 4. 58 Nilai Keakuratan Skenario 19	83
Tabel 4. 59 Parameter Skenario 20	84
Tabel 4. 60 Hasil Skenario 20	84
Tabel 4. 61 Nilai keakuratan skenario 20.....	85
Tabel 4. 62 Parameter Skenario 21	86
Tabel 4. 63 Hasil Skenario 21	86
Tabel 4. 64 Nilai Keakuratan Skenario 21	87
Tabel 4. 65 Parameter Skenario 22	88
Tabel 4. 66 Hasil Skenario 22	88
Tabel 4. 67 Nilai Keakuratan Skenario 22	89
Tabel 4. 68 Parameter Skenario 23	90
Tabel 4. 69 Hasil Skenario 23	90
Tabel 4. 70 Nilai Keakuratan Skenario 23	91
Tabel 4. 71 Parameter Skenario 24	92
Tabel 4. 72 Hasil Skenario 24	92
Tabel 4. 73 Nilai Keakuratan Skenario 24	93
Tabel 4. 74 Parameter Skenario 25	94
Tabel 4. 75 Hasil Skenario 25	94
Tabel 4. 76 Nilai Keakuratan Skenario 25	95
Tabel 4. 77 Parameter Skenario 26	96
Tabel 4. 78 Hasil Skenario 26	96
Tabel 4. 79 Nilai Keakuratan Skenario 26	97

Tabel 4. 80 Parameter Skenario 27	98
Tabel 4. 81 Hasil Skenario 27	98
Tabel 4. 82 Nilai keakuratan skenario 27	99
Tabel 4. 83 Hasil MAPE setiap Skenario 80:20	100
Tabel 4. 84 Hasil MAPE setiap skenario 90:10	102
Tabel 4. 85 Rata-rata MAPE Berdasarkan Nilai C pada Rasio 80:20	104
Tabel 4. 86 Rata-rata MAPE Berdasarkan Nilai C pada Rasio 90:10	104
Tabel 4. 87 Rata-rata MAPE Berdasarkan Nilai Epsilon pada Rasio 80:20 ...	106
Tabel 4. 88 Rata-rata MAPE Berdasarkan Nilai Epsilon pada Rasio 90:10 ...	107
Tabel 4. 89 Rata-rata MAPE Berdasarkan Nilai Gamma pada Rasio 80:20 ...	109
Tabel 4. 90 Rata-rata MAPE Berdasarkan Nilai Gamma pada Rasio 90:10 ...	110

ABSTRAK

Khoir, Mochamad Thoriq. 2025. **Prediksi Nilai Impor Migas Di Indonesia Menggunakan Metode *Support Vector Regression***. Skripsi. Jurusan Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Prof. Dr. Muhammad Faisal, M.T (II) Dr. Ir. Yunifa Miftachul Arif, M. T.

Kata kunci: Prediksi, Nilai Impor Migas, Indonesia, *Support Vector Regression*, *Kernel RBF*, MAPE.

Fluktuasi nilai impor minyak dan gas (migas) di Indonesia mendorong perlunya prediksi yang akurat guna mendukung perencanaan ekonomi nasional. Penelitian ini bertujuan untuk mengukur dan menganalisis tingkat *error* prediksi nilai impor migas menggunakan metode *Support Vector Regression* (SVR) dengan *kernel Radial Basis Function* (RBF). Data yang digunakan merupakan data impor migas bulanan periode 2015–2024 dari Badan Pusat Statistik (BPS), yang kemudian diolah melalui tahapan interpolasi, normalisasi, serta perekayasaan fitur dengan *rolling mean*, *rolling standard deviation*, *differencing*, dan *seasonal lag*. Model SVR diuji pada dua skenario pembagian data latih-uji, yaitu 80:20 dan 90:10, masing-masing dengan 27 kombinasi *hyperparameter* (C , epsilon, dan gamma). Hasil penelitian menunjukkan bahwa skenario terbaik pada rasio 80:20 diperoleh saat $C = 1$, epsilon = 0.001, dan gamma = 0.01 dengan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 4.38%, sedangkan pada rasio 90:10, konfigurasi optimal adalah $C = 10$, epsilon = 0.001, dan gamma = 0.001 dengan MAPE 4.36%. Temuan ini menunjukkan bahwa model SVR dengan *tuning hyperparameter* yang tepat mampu memberikan akurasi prediksi yang sangat baik (MAPE < 10%), sehingga dapat menjadi alat bantu yang andal bagi pengambilan keputusan dalam kebijakan perdagangan dan perencanaan energi nasional.

ABSTRACT

Khoir, Mochamad Thoriq. 2025. **Prediction of Oil and Gas Import Values in Indonesia Using the Support Vector Regression Method.** Thesis. Jurusan Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Prof. Dr. Muhammad Faisal, M.T (II) Dr. Ir. Yunifa Miftachul Arif, M. T.

Fluctuations in Indonesia's oil and gas (O&G) import values highlight the need for accurate forecasting to support national economic planning. This study aims to measure and analyze the prediction error of O&G import values using the Support Vector Regression (SVR) method with a Radial Basis Function (RBF) kernel. The dataset consists of monthly O&G import data from 2015 to 2024, sourced from Statistics Indonesia (BPS), and is processed through interpolation, normalization, and feature engineering using rolling mean, rolling standard deviation, differencing, and seasonal lag techniques. The SVR model is evaluated under two training-testing split scenarios, 80:20 and 90:10, each with 27 combinations of hyperparameters (C , ϵ , and γ). Results indicate that the best performance for the 80:20 scenario is achieved with $C = 1$, $\epsilon = 0.001$, and $\gamma = 0.01$, yielding a Mean Absolute Percentage Error (MAPE) of 4.38%. For the 90:10 scenario, the optimal configuration is $C = 10$, $\epsilon = 0.001$, and $\gamma = 0.001$, with a MAPE of 4.36%. These findings demonstrate that SVR, when properly tuned, can deliver highly accurate forecasts ($\text{MAPE} < 10\%$) and serve as a reliable decision-support tool for trade policy and energy planning.

Key words: Prediction, Oil and Gas Import Value, Indonesia, Support Vector Regression, RBF Kernel, MAPE.

مستخلص البحث

خير، محمد طارق. 2025. تنبؤ قيمة واردات الطاقة في إندونيسيا باستخدام طريقة الانحدار المتجه الداعم. البحث الجامعي. قسم الهندسة المعلوماتية، كلية العلوم والتكنولوجيا بجامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانج. المشرف الأول: أ. د. محمد فيصل، الماجستير؛ المشرف الثاني: د. يونيفا مفتاح العارف، الماجستير.

الكلمات الرئيسية: تنبؤ، قيمة واردات طاقة، إندونيسيا، انحدار متجه داعم، نواة دالة أساس شعاعي، متوسط خطأ نسبي مطلق.

تقلبات قيمة واردات النفط والغاز المعروفة بـ "ميغاز" في إندونيسيا تدفع إلى الحاجة إلى تنبؤات دقيقة لدعم التخطيط الاقتصادي الوطني. هدف هذا البحث إلى قياس وتحليل مستوى خطأ التنبؤ بقيمة واردات "ميغاز" باستخدام طريقة الانحدار المتجه الداعم (SVR) مع نواة دالة الأساس الشعاعي (RBF). البيانات المستخدمة هي بيانات واردات "ميغاز" الشهرية للفترة 2015-2024 من مكتب الإحصاء المركزي (BPS)، والتي تم معالجتها من خلال مراحل التداخل، والتطبيع، وهندسة الميزات مع المتوسط المتحرك، والانحراف المعياري المتحرك، والفرق، والتأخير الموسمي. تم اختبار نموذج SVR في سيناريوهين لتقسيم بيانات التدريب والاختبار، وهما 80:20 و 90:10، مع 27 تركيبة من الهايبر بارامتر (ج، إفسلون، ألفا). أظهرت نتائج البحث أن السيناريو الأفضل بالنسبة 80:20 تم الحصول عليه عندما كانت ج=1، إفسلون=0.001، و ألفا=0.01 مع قيمة متوسط الخطأ النسبي المطلق (MAPE) بنسبة 4.38%، بينما بالنسبة 90:10، كانت التكوينات المثلى هي ج=10، إفسلون=0.001، وألفا=0.001 مع قيمة متوسط الخطأ النسبي المطلق (MAPE) بنسبة 4.36%. أشارت هذه النتيجة إلى أن نموذج SVR مع ضبط صحيح للمعلمات الفائقة قادر على تقديم دقة تنبؤ ممتازة (MAPE > 10%)، مما يجعله أداة موثوقة لدعم اتخاذ القرار في السياسات التجارية والتخطيط للطاقة الوطنية.

BAB I

PENDAHULUAN

1.1 Latar Belakang

Sektor minyak dan gas bumi (migas) merupakan salah satu sumber utama devisa negara Indonesia yang mendukung kelangsungan pembangunan nasional. Oleh karena itu, pemerintah dituntut untuk mengelola migas dengan baik. Apalagi minyak bumi dan gas sudah menjadi barang yang sangat dibutuhkan oleh manusia. Bahkan hampir semua fasilitas yang dinikmati manusia, khususnya di Indonesia sekarang ini harus menggunakan minyak bumi dan gas alam, seperti kebutuhan rumah tangga, transportasi, listrik, maupun kebutuhan industri atau usaha (Annuri, 2017).

Nilai impor suatu negara tergolong sebagai permintaan dari suatu negara ke negara lain untuk memenuhi kebutuhan negara tersebut. Indonesia salah satu negara yang memiliki nilai impor yang naik turun atau mengalami fluktuasi, terutama pada impor migas (Ferryan dkk., 2022). Dalam perkembangan nilai impor migas di Indonesia Pada tahun 2019, nilai impor migas Indonesia mencapai USD 21.885,3 juta, mengalami penurunan sebesar 26,72% dibandingkan dengan tahun sebelumnya yang mencapai USD 29.868,8 juta. Penurunan ini berlanjut pada tahun 2020, di mana nilai impor migas turun sebesar 34,86%, menjadi USD 14.256,8 juta. Pada tahun 2021, impor migas kembali meningkat sebesar 79,11%, mencapai USD 25.529,1 juta. Kenaikan ini berlanjut pada tahun 2022, dengan impor migas mencapai USD 40.416,4 juta, atau naik sebesar 58,33% dibandingkan tahun sebelumnya. Namun, pada tahun 2023, nilai impor migas sedikit menurun sebesar

11,34% menjadi USD 35.830,5 juta (BPS Indonesia,2024). Data tersebut menunjukkan bahwa impor migas Indonesia mengalami fluktuasi yang signifikan dari tahun ke tahun.

Fluktuasi nilai impor migas dapat berdampak langsung terhadap kondisi masyarakat dan pertumbuhan ekonomi nasional. Nilai impor yang tinggi mengindikasikan besarnya aliran pembayaran dari dalam negeri ke luar negeri, yang dapat menekan pertumbuhan ekonomi dan mengganggu stabilitas fiskal negara. Oleh karena itu, diperlukan upaya untuk memprediksi nilai impor migas di masa depan, agar pemerintah dapat menjaga kebutuhan serta kestabilan ekonomi untuk mendukung perkembangan ekonomi Indonesia. Peramalan (*Forecasting*) adalah suatu proses yang digunakan untuk memprediksi sesuatu yang kemungkinan besar akan terjadi dimasa mendatang sehingga dapat mengambil tindakan yang tepat dilakukan. Peramalan memerlukan data runtun waktu yang dikumpulkan, dicatat atau diobservasi kemudian dianalisis dengan menggunakan model *Time Series* (Wei, 2006).

Al-Qur'an memberikan panduan penting mengenai pentingnya perencanaan yang bijaksana dan memanfaatkan pengetahuan dengan sebaik-baiknya. Ayat yang relevan adalah surat Al-Anfal ayat 60:

وَأَعِدُّوا لَهُمْ مَا اسْتَطَعْتُمْ مِنْ قُوَّةٍ وَمِنْ رِبَاطِ الْخَيْلِ تُرْهَبُونَ بِهِ ۗ عَدُوَّ اللَّهِ وَعَدُوَّكُمْ وَأَخْرِينَ مِنْ دُونِهِمْ لَا تَعْلَمُونَهُمُ
اللَّهُ يَعْلَمُهُمْ ۗ وَمَا تُنْفِقُوا مِنْ شَيْءٍ فِي سَبِيلِ اللَّهِ يُوَفَّ إِلَيْكُمْ وَأَنْتُمْ لَا تُظْلَمُونَ

"Persiapkanlah untuk (menghadapi) mereka apa yang kamu mampu, berupa kekuatan (yang kamu miliki) dan pasukan berkuda. Dengannya (persiapan itu) kamu membuat gentar musuh Allah, musuh kamu dan orang-orang selain mereka yang kamu tidak mengetahuinya, (tetapi) Allah mengetahuinya. Apa pun yang kamu infakkan di jalan Allah niscaya akan dibalas secara penuh kepadamu, sedangkan kamu tidak akan dizalimi." (Q.S. Al-Anfal : 60).

Menurut (Ahmad Mustofa Al-Maraghi, 1974) menafsirkan dalam kitab tafsirnya bahwa persiapan itu bisa dilakukan dengan mempersiapkan kekuatan yang disesuaikan dengan perbedaan zaman dan tempat. Seperti membuat senjata, pesawat tempur, bom, dan tank baja; membuat kapal-kapal perang dan kapal selam, dalam menjaga dan mengantisipasi serangan dari pihak luar. Selain itu, mempelajari berbagai keahlian dan industri lainnya yang mendukung tercapainya tujuan dari sebuah organisasi atau individu, selain itu Al-Maraghi lebih menekankan kepada aspek keilmuan yang disesuaikan dengan perkembangan zaman. Sehingga, konsep persiapan atau perencanaan dan ilmu pengetahuan menjadi sangat penting, terutama untuk menghadapi tantangan global yang semakin kompleks, seperti krisis energi dan ketidakpastian ekonomi. Oleh karena itu, prediksi nilai impor migas untuk merencanakan kebijakan dimasa mendatang menjadi sangat relevan.

Salah satu metode untuk menangani kompleksitas dalam memprediksi adalah metode *Support Vector Regression* (SVR). SVR merupakan penerapan *Support Vector Machine* (SVM) untuk kasus regresi. Dalam kasus regresi, *output* yang digunakan adalah bilangan nyata atau kontinu (Mustakim dkk., 2016). Penelitian terdahulu oleh Rais & Ahmar, (2024) menerapkan algoritma *Support Vector Regression* (SVR) untuk memprediksi laju inflasi di Kota Makassar menggunakan data *time series* berdasarkan Indeks Harga Konsumen (IHK) dari Januari 2014 hingga Desember 2022. Penelitian ini menunjukkan bahwa prediksi inflasi sangat penting untuk menjaga stabilitas ekonomi. Hasil awal menunjukkan nilai *Root Mean Squared Error* (RMSE) yang diperoleh sebesar 0,0136, yang

kemudian diperbaiki menjadi 0,0131 setelah optimasi parameter menggunakan *Grid Search*. Kesimpulan dari penelitian ini adalah bahwa SVR, dengan parameter yang di optimasi, efektif dalam memprediksi inflasi, dengan peningkatan akurasi yang signifikan dibandingkan model tanpa optimasi.

Menurut Asyiva, (2019) yang menerapkan metode *Support Vector Regression* (SVR) dengan *kernel Radial Basis Function* untuk memprediksi laju inflasi di Indonesia menggunakan data Indeks Harga Konsumen (IHK) dari Januari 2010 hingga Desember 2018. Penelitian ini menekankan pentingnya prediksi inflasi sebagai indikator ekonomi yang dapat membantu pemerintah dalam merencanakan strategi ekonomi yang stabil. Hasil penelitian menunjukkan nilai *Root Mean Squared Error* (RMSE) sebesar 0.00000177 dengan parameter optimal tertentu setelah menggunakan *Grid Search Optimization*. Kesimpulan dari penelitian ini adalah bahwa SVR, dengan parameter yang di optimasi, efektif dalam memprediksi inflasi, dengan hasil yang mendekati nilai aktual selama periode yang diteliti.

Menurut penelitian yang dilakukan Purnama & Hendarsin, (2020), metode *Support Vector Regression* (SVR) dengan *kernel Radial Basis Function* (RBF) diterapkan untuk memprediksi jumlah penumpang udara di Sulawesi Tengah menggunakan data dari Badan Pusat Statistik dari Januari 2006 hingga November 2019, dengan pengecualian bulan Agustus dan November 2018. Penelitian ini menekankan pentingnya prediksi jumlah penumpang sebagai dukungan bagi kegiatan pariwisata dan ekonomi di wilayah tersebut. Hasil penelitian menunjukkan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 7,28% untuk data pelatihan dan 18,67% untuk data pengujian, yang menunjukkan akurasi yang tinggi dan dapat

diterima. Kesimpulan dari penelitian ini adalah bahwa model SVR secara efektif memprediksi jumlah penumpang udara di Sulawesi Tengah, menunjukkan potensi untuk prediksi yang akurat dalam data deret waktu.

Dalam penerapannya, efektivitas metode SVR dalam prediksi sangat dipengaruhi oleh seberapa rendah tingkat *error* yang dihasilkan. Beberapa metrik evaluasi untuk mengukur tingkat *error* pada SVR antara lain *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). Metrik-metrik ini berfungsi untuk mengetahui seberapa besar penyimpangan hasil prediksi terhadap data aktual, untuk menjadi dasar dalam menilai efektivitas suatu model prediksi. Nilai *error* yang rendah menunjukkan bahwa model mampu memetakan pola data dengan baik dan menghasilkan prediksi yang akurat. Sebaliknya, nilai *error* yang tinggi mengindikasikan bahwa model kurang efektif dalam menangkap pola dari data yang digunakan (Irwati & Ade Nurul Hidayat, 2023). Oleh karena itu, pengukuran dan analisis terhadap besarnya *error* menjadi aspek krusial dalam proses evaluasi model prediksi.

Berdasarkan berbagai penelitian tersebut, SVR terbukti mampu memberikan hasil prediksi yang akurat dalam berbagai konteks ekonomi. Namun, hingga saat ini masih belum banyak penelitian yang secara khusus mengevaluasi *error* SVR dalam konteks prediksi impor migas di Indonesia. SVR dipilih karena kemampuannya dalam menangani data non-linear serta memberikan hasil prediksi yang akurat meskipun terdapat fluktuasi atau ketidakpastian di pasar energi global. Dengan menggunakan metode ini, penelitian ini bertujuan untuk mengevaluasi tingkat *error* yang dihasilkan oleh SVR dalam memprediksi nilai impor migas di

Indonesia. Diharapkan, hasil prediksi yang diperoleh dari metode ini dapat meningkatkan akurasi dalam perencanaan energi nasional dengan menyediakan data yang lebih andal dan antisipatif, serta turut mendukung pembangunan ekonomi yang berkelanjutan.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diberikan maka perumusan masalah dalam penelitian ini sebagai berikut: Seberapa besar *error* yang dihasilkan metode *Support Vector Regression* untuk memprediksi nilai impor migas di Indonesia.

1.3 Batasan Masalah

Batasan masalah pada penelitian ini adalah data uji perhitungan pada penelitian yang digunakan yaitu data nilai impor migas di Indonesia setiap bulan pada tahun 2015-2024.

1.4 Tujuan Penelitian

Berdasarkan perumusan masalah di atas, maka tujuan penelitian ini adalah untuk mengukur dan menganalisis *error* yang dihasilkan dalam prediksi nilai impor migas di Indonesia dengan metode *Support Vector Regression*.

1.5 Manfaat Penelitian

Manfaat dari penelitian ini adalah diharapkan mampu dan mempermudah pihak pemerintah khususnya kementerian perdagangan dalam perencanaan anggaran dan kebijakan energi serta memungkinkan pelaku industri untuk menyesuaikan strategi bisnis mereka.

BAB II

STUDI PUSTAKA

2.1 Penelitian Terkait

Penelitian penerapan metode *Support Vector Regression* (SVR) dengan kernel *Gaussian Radial Basis Function* (RBF) untuk peramalan Indeks Harga Konsumen (CPI) pada komoditas pangan di Surabaya. Data yang digunakan mencakup periode dari Januari 2016 hingga Desember 2018 dengan 34 atribut *input* terkait harga pangan. Hasil penelitian menunjukkan bahwa SVR dapat memprediksi CPI dengan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 0,1716%, yang jauh di bawah target tingkat kesalahan 10%. *Kernel Gaussian* RBF terbukti menjadi yang paling efektif dibandingkan dengan *kernel* lainnya, seperti *Polynomial*, *Linear*, dan *SPLine*, yang masing-masing memiliki MAPE yang jauh lebih tinggi, yaitu 22,2239%, 317,54%, dan 3529,7%. Penelitian ini menekankan pentingnya prediksi yang akurat untuk menjaga stabilitas harga pangan (Cahyono dkk., 2019).

Penelitian berikutnya oleh Ramdhani & Mubarok (2019) menerapkan algoritma *Support Vector Machine* (SVM) untuk memprediksi harga saham PT Aneka Tambang Tbk (PT Antm) dilakukan dengan menggunakan data *time series* dan teknik *data mining*. Penelitian ini menunjukkan bahwa prediksi harga saham penting bagi investor dalam pengambilan keputusan investasi. Hasil awal menunjukkan nilai *Root Mean Squared Error* (RMSE) sebesar 22,662, yang kemudian diperbaiki menjadi 10,495 setelah optimasi parameter menggunakan algoritma genetika. Kesimpulan dari penelitian ini adalah bahwa SVM, terutama

dengan parameter yang di optimasi, efektif dalam memprediksi harga saham, dengan peningkatan akurasi yang signifikan dibandingkan SVM tanpa optimasi.

Penelitian selanjutnya yang dilakukan Thanh Ngoc dkk., (2021) menerapkan metode *Support Vector Regression* (SVR) dengan pendekatan *Grid Search* untuk peramalan beban. menggunakan data permintaan beban dari Tasmania, Australia, dan Ho Chi Minh City, Vietnam. Penelitian ini berfokus pada pengoptimalan *hyperparameter*, termasuk fungsi *kernel*, parameter *kernel*, dan konstanta regularisasi, serta karakteristik data *input* seperti jumlah observasi *lag* dan urutan *differencing*. Hasil penelitian menunjukkan bahwa model optimal yang dihasilkan memiliki nilai evaluasi yang lebih rendah (RMSE, MAPE, SMAPE, MAE) dibandingkan dengan nilai rata-rata dan maksimum dari model lainnya, menandakan efektivitas metode SVR *Grid Search* dalam meningkatkan akurasi peramalan beban. Meskipun model optimal tidak selalu menjamin hasil pengujian terbaik, kinerjanya secara keseluruhan menunjukkan bahwa metodologi ini cocok untuk aplikasi peramalan beban.

Penelitian penerapan model *Support Vector Regression* (SVR) untuk peramalan kasus COVID-19 di India dilakukan pada periode 1 Maret hingga 30 April 2020. Model ini memprediksi total kematian, jumlah pemulihan, kasus terkonfirmasi kumulatif, dan kasus baru harian. Hasil penelitian menunjukkan akurasi tinggi, dengan lebih dari 97% untuk prediksi kematian dan pemulihan, serta 87% untuk kasus baru harian. Penulis mencatat tantangan dalam memprediksi kasus harian akibat lonjakan data. Penelitian ini menekankan pentingnya langkah-

langkah pengendalian untuk mengurangi penyebaran dan meningkatkan keandalan prediksi. (Parbat & Chakraborty, 2020).

Penelitian ini mengimplementasikan metode *Support Vector Regression* (SVR) untuk peramalan harga saham perusahaan pertambangan di Indonesia penulis dhanukresna (2020), yaitu PT Adaro Energy Tbk, PT Bukit Asam Tbk, dan PT Indo Tambangraya Megah Tbk, menggunakan data dari Januari 2015 hingga Desember 2019. Berdasarkan hasil penelitian, diperoleh bahwa model SVR memberikan performa yang baik dalam memprediksi harga saham. Nilai akurasi prediksi harga saham ADRO dengan *kernel* RBF memiliki *R-square* sebesar 74,1% dan MAPE 3,733, sementara dengan *kernel* linear memiliki *R-square* 76,1% dan MAPE 3,561. Pada saham PTBA, nilai *R-square* sebesar 97,9% dengan MAPE masing-masing sebesar 2,465 (RBF) dan 2,480 (linear). Sedangkan pada saham ITMG, nilai *R-square* mencapai 94,3% dengan MAPE sebesar 5,874 pada *kernel* RBF dan 5,875 pada *kernel* linear. Hasil ini menunjukkan bahwa metode SVR sangat baik digunakan untuk peramalan harga saham (Yudhawan, 2020).

Penelitian yang dilakukan oleh Muhammad Arif Abdul Syukur dan Muhammad Faishal, (2023) menggunakan model regresi linear untuk estimasi harga mobil bekas berdasarkan beberapa atribut seperti tahun produksi dan konsumsi bahan bakar, menunjukkan bahwa regresi linear dapat memberikan estimasi yang baik dalam konteks data pasar yang dinamis. Meskipun penelitian tersebut menggunakan regresi linear, prinsip dasar pemodelan hubungan variabel *input* terhadap *output* prediktif tetap relevan dalam konteks SVR yang merupakan pengembangan dari pendekatan regresi dengan pendekatan margin dan *kernel*.

Metode SVR telah banyak digunakan dalam prediksi data *time series* di berbagai bidang, seperti prediksi inflasi, penumpang transportasi, hingga harga komoditas. Dalam studi oleh Muhammad Sahi, Muhammad Faisal, Yunifa Miftachul Arif, dan Cahyo Crysodian, (2023) SVR dibandingkan dengan ANN dalam konteks prediksi harga *Bitcoin*, di mana ANN menunjukkan akurasi lebih tinggi, namun SVR tetap relevan karena kemampuannya menangani data non-linier secara efektif.

Tabel 2. 1 Penelitian Terdahulu

No	Nama Peneliti	Judul Penelitian	Metode	Hasil Penelitian
1	(Cahyono dkk., 2019)	Analisis Kinerja Metode Support Vector Regression (SVR) dalam Memprediksi Indeks Harga Konsumen (IHK)	Penelitian ini menggunakan metode Support Vector Regression (SVR)	Hasil penelitian menunjukkan bahwa SVR dapat memprediksi IHK dengan nilai MAPE sebesar 0,1716%, yang jauh di bawah target tingkat kesalahan 10%. Kernel Gaussian RBF terbukti menjadi yang paling efektif dibandingkan dengan kernel lainnya, yang memiliki MAPE yang jauh lebih tinggi
2	(Ramdhani & Mubarak, 2019)	Analisis Time Series Prediksi Penutupan Harga Saham Antm.Jk Dengan Algoritma SVM model regresi	Penelitian ini menggunakan algoritma Support Vector Machine (SVM) model regresi	Hasil awal menunjukkan nilai Root Mean Squared Error (RMSE) sebesar 22,662, yang kemudian diperbaiki menjadi 10,495 setelah optimasi parameter menggunakan algoritma genetika. Penelitian ini menyimpulkan bahwa SVM dengan parameter yang dioptimasi efektif dalam memprediksi harga saham, menunjukkan peningkatan akurasi yang signifikan
3	(Thanh Ngoc dkk., 2021)	Support Vector Regression based on Grid Search method of Hyperparameters for Load Forecasting	Penelitian ini menggunakan metode Support Vector Regression (SVR) dengan	Hasil penelitian menunjukkan bahwa model optimal yang dihasilkan memiliki nilai evaluasi yang lebih rendah dibandingkan

No	Nama Peneliti	Judul Penelitian	Metode	Hasil Penelitian
			pendekatan Grid Search	dengan nilai rata-rata dan maksimum dari model lainnya, menandakan efektivitas metode SVR Grid Search dalam meningkatkan akurasi peramalan beban. Meskipun model optimal tidak selalu menjamin hasil pengujian terbaik, kinerjanya secara keseluruhan menunjukkan bahwa metodologi ini cocok untuk aplikasi peramalan beban
4	(Parbat & Chakraborty, 2020)	A Python Based Support Vector Regression Model for Prediction of COVID19 Cases in India	Penelitian ini menggunakan model Support Vector Regression (SVR) yang diimplementasikan dalam Python	Model SVR menunjukkan akurasi tinggi, dengan lebih dari 97% untuk prediksi kematian dan pemulihan, serta 87% untuk kasus baru harian. Penelitian ini juga mencatat tantangan dalam memprediksi kasus harian akibat lonjakan data yang menyebabkan non-stasionaritas
5	(Yudhawan, 2020)	Implementasi Support Vector Regression untuk Peramalan Harga Saham Perusahaan Pertambangan di Indonesia (Studi Kasus: PT Adaro Energy Tbk, PT Bukit Asam Tbk, dan PT Indo Tambangraya Megah Tbk)	Penelitian ini menggunakan metode Support Vector Regression (SVR) dengan kernel Radial Basis Function (RBF)	Hasil penelitian menunjukkan bahwa metode Support Vector Regression (SVR) efektif dalam memprediksi harga saham perusahaan pertambangan. Pada saham ADRO, kernel RBF menghasilkan R-square 74,1% dan MAPE 3,733, sedangkan kernel linear memberikan R-square 76,1% dan MAPE 3,561. Saham PTBA menunjukkan <i>R-square</i> 97,9% dengan MAPE 2,465 (RBF) dan 2,480 (linear). Sementara itu, saham ITMG memiliki <i>R-square</i> 94,3% dengan MAPE 5,874 (RBF) dan 5,875 (linear). Hasil ini

No	Nama Peneliti	Judul Penelitian	Metode	Hasil Penelitian
				menegaskan bahwa SVR cocok digunakan untuk peramalan harga saham dengan akurasi yang baik.

2.2 Forecasting (Peramalan)

Peramalan adalah proses memprediksi peristiwa atau nilai masa depan berdasarkan pola sejarah, yang sangat penting untuk menerapkan program pembangunan strategis untuk meningkatkan hasil sosial ekonomi dan menanggapi perubahan lingkungan (Chirkova, 2024). Dalam penelitian ini, teknik peramalan digunakan untuk memprediksi nilai impor migas di Indonesia. Peramalan yang akurat sangat penting bagi pemerintah dan industri untuk merencanakan strategi yang tepat, terutama dalam hal pengelolaan sumber daya energi. Dengan adanya prediksi yang baik, risiko terhadap fluktuasi harga dan ketersediaan migas dapat dikurangi secara signifikan.

2.3 Data Deret waktu

Data deret waktu terdiri dari titik-titik data yang dikumpulkan secara berurutan dari waktu ke waktu, di mana urutan temporal sangat penting untuk memahami dan menganalisis dinamika data (Le, 2024). Dalam penelitian ini, data deret waktu yang digunakan adalah data nilai impor migas di Indonesia setiap bulan dari tahun 2015 hingga 2024. Penggunaan data deret waktu memungkinkan untuk mengevaluasi tren jangka panjang, pola musiman, serta kejadian-kejadian tidak terduga yang dapat mempengaruhi nilai impor. Oleh karena itu, analisis deret waktu sangat berguna dalam memodelkan fluktuasi impor migas.

2.4 Normalisasi Data

Dalam penelitian ini, digunakan dua jenis normalisasi untuk memaksimalkan performa model *Support Vector Regression* (SVR), yaitu *Min-Max* untuk nilai target dan *Z-Score* untuk nilai fitur. Normalisasi dengan *Z-Score* mengubah data sehingga memiliki rata-rata 0 dan deviasi standar 1, yang membantu menjaga keseimbangan skala antar fitur. SVR, yang sensitif terhadap perbedaan skala, cenderung menghasilkan *error* yang lebih kecil saat bekerja dengan data yang telah dinormalisasi menggunakan *Z-Score*. Hal ini memungkinkan model untuk mengidentifikasi pola dengan lebih akurat dan meminimalkan bias dari fitur yang berskala besar. Penelitian oleh Syaharuddin dkk., (2022) juga menunjukkan bahwa SVR memiliki kesalahan prediksi yang lebih rendah ketika dilatih pada data yang telah dinormalisasi dengan *Z-Score*, karena model dapat lebih mudah mengungkap pola mendasar dari data. Berikut adalah rumus dari *Z-score* (Leushuis & Wetzels, 2014) :

$$Z = \frac{x - \mu}{\sigma} \quad (2.1)$$

Keterangan :

x : Nilai data yang akan dinormalisasi,

μ : Rata-rata dari dataset

σ : standar deviasi dari dataset

Sedangkan *Min-Max Scaler* digunakan untuk nilai target agar seluruh nilai berada dalam rentang yang seragam, yaitu 0, 1. Penggunaan *Min-Max Scaler* terbukti efektif dalam mengurangi waktu komputasi dan meningkatkan stabilitas model pada beberapa kasus, terutama ketika fitur memiliki rentang yang sangat bervariasi (Cabello-Solorzano dkk., 2023). Studi-studi sebelumnya menunjukkan

bahwa pemilihan metode normalisasi yang sesuai dengan karakteristik data dan algoritma dapat meningkatkan performa prediksi secara signifikan. Oleh karena itu, dalam penelitian ini kedua metode digunakan secara bersamaan sesuai kebutuhan masing-masing data.

2.5 *Support Vector Regression*

Support Vector Regression (SVR) adalah metode regresi yang merupakan pengembangan dari *Support Vector Machine* (SVM) dan digunakan dalam konteks *supervised learning* untuk memprediksi nilai variabel kontinu. SVR berfokus pada menemukan *hyperplane* yang dapat memisahkan data dengan margin tertentu, yang dikenal sebagai epsilon, untuk mencapai prediksi yang akurat (Saputra dkk., 2019). Tujuan utama SVR adalah untuk menemukan fungsi regresi yang dapat memprediksi nilai target dengan kesalahan minimal, di mana kesalahan dianggap dapat diterima jika berada dalam batas epsilon. Dengan demikian, SVR bertujuan untuk mencapai generalisasi yang baik pada data uji (Rahmawati, 2020).

Support Vector Regression memiliki beberapa parameter kunci yang mempengaruhi performa model, yaitu *Regularization Parameter* (C), *Epsilon* (ϵ), dan *kernel Parameter* (γ). Parameter C mengontrol *trade-off* antara kesalahan klasifikasi pada data pelatihan dan kompleksitas model. Nilai C yang besar memberikan penalti tinggi terhadap kesalahan, sehingga model cenderung lebih kompleks dan berisiko *overfitting*. Sebaliknya, jika C terlalu kecil, model mungkin tidak cukup fleksibel untuk menangkap pola dalam data, yang dapat menyebabkan *underfitting* (Putri dkk., 2023).

Epsilon (ϵ) menentukan margin di sekitar fungsi regresi di mana tidak ada penalti untuk kesalahan. Dengan kata lain, ϵ mendefinisikan area di sekitar prediksi di mana kesalahan dianggap dapat diterima. Nilai ϵ yang lebih besar menghasilkan model yang lebih *robust* tetapi dapat mengabaikan beberapa informasi penting dari data. Sebaliknya, nilai ϵ yang kecil dapat membuat model lebih sensitif terhadap *noise* dalam data (Saputra dkk., 2019).

Kernel Parameter (γ) berperan penting ketika menggunakan *kernel* non-linear seperti *Radial Basis Function* (RBF). Parameter ini menentukan seberapa jauh pengaruh satu titik data terhadap titik data lainnya. Nilai γ yang kecil menghasilkan keputusan yang lebih halus tetapi dapat menyebabkan *underfitting*, sementara nilai γ yang besar dapat menyebabkan model menjadi terlalu kompleks dan berisiko *overfitting* (Safira dkk., 2023).

Menurut penelitian dari Asyiva, (2019) persamaan atau rumus dari *Support Vector Regression* adalah sebagai berikut :

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(x_i, x_j) + b \quad (2.2)$$

Keterangan:

α_i dan α_i^* : *Lagrange multipliers*

$K(x_i, x)$: fungsi *kernel* RBF

b : bias

x_i : titik data yang digunakan untuk pelatihan,

n : jumlah data pelatihan.

Alur kerja dari *Support Vector Regression* (SVR) mencakup beberapa tahapan utama untuk memprediksi nilai yang optimal berdasarkan data pelatihan. Pertama, dilakukan perhitungan matriks *kernel*, di mana setiap data diubah dengan *kernel* untuk mengukur kesamaan antar titik data. Kernel yang umum digunakan adalah *kernel* linear, polynomial, dan *Radial Basis Function* (RBF), yang masing-

masing memiliki karakteristik unik dalam menangani data dengan linearitas atau kompleksitas yang berbeda (García-Florian dkk., 2018).

Setelah matriks *kernel* dihitung, SVR memerlukan algoritma optimasi untuk menghasilkan nilai parameter α dan bias yang konvergen. Salah satu algoritma yang populer dan efisien untuk optimasi ini adalah *Sequential Minimal Optimization* (SMO), yang bertujuan memperbarui nilai α secara bertahap melalui iterasi. Algoritma SMO bekerja dengan memilih dua variabel α dalam setiap iterasi, menghitung batas bawah dan atas (L dan H), serta memperbarui nilai-nilai ini hingga mencapai kondisi konvergen sesuai batas toleransi yang diinginkan (Kocaoglu, 2024).

Setelah model *Support Vector Regression* (SVR) selesai dilatih, langkah berikutnya adalah mengevaluasi kinerja prediksi menggunakan beberapa metode umum. Pertama, *Root Mean Square Error* (RMSE) mengukur kesalahan rata-rata antara nilai prediksi dan nilai aktual, memberikan nilai kesalahan dalam unit yang sama dengan data. RMSE sensitif terhadap *outlier*, sehingga sangat berguna dalam konteks di mana kesalahan besar perlu ditekankan. Dalam konteks sistem dinamis skala besar, RMSE berfungsi sebagai ukuran kritis untuk memodelkan penyimpangan rata-rata dari perilaku standar, meskipun komputasinya dapat menantang, memerlukan teknik pengurangan urutan model (Reiter & Werner, 2024). kemudian *Mean Squared Error* (MSE) menghitung rata-rata kuadrat dari kesalahan prediksi, memberlakukan penalti yang lebih besar untuk kesalahan besar. Karakteristik ini membuat MSE menjadi metrik yang banyak digunakan dalam pengoptimalan model, terutama dalam konteks seperti kecerdasan buatan dan

pemrosesan sinyal, di mana meminimalkan kesalahan besar sangat penting untuk meningkatkan kinerja model (Mahdavi, 2024).

Selanjutnya, *Mean Absolute Persentase Error* (MAPE) mengukur kesalahan sebagai persentase rata-rata kesalahan absolut relatif terhadap nilai aktual. MAPE berguna untuk memahami tingkat kesalahan dalam istilah relatif, yang membantu dalam menafsirkan seberapa jauh prediksi menyimpang dari nilai aktual dalam persentase. Sementara *Mean Absolute Error* (MAE) mengukur kesalahan absolut rata-rata antara prediksi dan nilai aktual tanpa mempertimbangkan arah penyimpangan, fokus penelitian ini terutama pada MAPE sebagai alat untuk menilai akurasi perkiraan dalam industri pewarnaan resin plastik (Irwati & Ade Nurul Hidayat, 2023).

Perbedaan utama antara SVR dan *Support Vector Machine* (SVM) terletak pada tujuan dan alur prosesnya. Pada SVM, proses pelatihan diarahkan untuk menemukan *hyperplane* yang memisahkan kelas dengan margin maksimal, menghasilkan model klasifikasi. SVM mengoptimalkan pemisahan data menjadi dua atau lebih kelas yang terdefinisi, di mana alur kerjanya berakhir setelah margin kelas optimal ditemukan. Sedangkan pada SVR, alur kerja berfokus pada membangun fungsi prediksi kontinu untuk meminimalkan *error* antara prediksi dan data aktual. SVR melakukan optimasi margin dalam regresi, tidak untuk klasifikasi, sehingga menghasilkan batas kesalahan yang optimal di sekitar nilai prediksi, tidak di antara kelas (Chopra & Khurana, 2023).

2.6 Sequential Minimal Optimization

Sequential Minimal Optimization (SMO) adalah algoritma yang dirancang untuk menyelesaikan masalah optimasi kuadratik dalam pelatihan *Support Vector Machine* (SVM) dan *Support Vector Regression* (SVR). Algoritma ini bekerja dengan memecah masalah optimasi besar menjadi serangkaian sub masalah kecil, yang masing-masing melibatkan dua variabel *lagrange*. Sub masalah tersebut dapat diselesaikan secara analitik, sehingga menghilangkan kebutuhan akan *solver* optimasi numerik. SMO mempercepat proses pelatihan secara signifikan, terutama untuk data set berukuran besar atau kompleks. Dalam penerapannya, SMO telah banyak digunakan di berbagai bidang termasuk sistem rekomendasi, pengolahan citra, dan prediksi numerik berbasis *time series* (Kocaoglu, 2024).

Kelebihan utama SMO adalah efisiensinya yang tinggi dalam pelatihan model berbasis SVM/SVR, terutama pada data set skala besar. Dengan memanfaatkan pendekatan dua variabel sekaligus, SMO tidak hanya mengurangi beban komputasi, tetapi juga meningkatkan stabilitas konvergensi dibandingkan metode optimasi lainnya. Dalam studi oleh (Zhang dkk., 2015), SMO berhasil menunjukkan performa yang kompetitif dalam prediksi data non linier untuk estimasi kedalaman erosi lokal, di mana metode ini menunjukkan akurasi tinggi dengan kesalahan prediksi yang rendah dibandingkan model lain seperti ANN dan regresi linier.

2.7 Feature Engineering

Feature Engineering adalah proses sistematis dalam pembelajaran mesin yang bertujuan untuk menciptakan atau mengubah fitur dari data mentah agar lebih

representatif terhadap pola yang ingin dipelajari oleh model. Teknik ini dapat melibatkan transformasi matematis, pembuatan *lag* dalam data deret waktu, penggabungan beberapa fitur. Dalam konteks prediksi deret waktu seperti prediksi impor migas, teknik *feature engineering* seperti *moving average*, *seasonal lag*, dan *differencing* sering digunakan untuk menyoroti pola musiman, tren, dan fluktuasi jangka pendek. *Feature engineering* tidak hanya mempersiapkan data agar sesuai untuk pelatihan model, tetapi juga meningkatkan konteks informasi yang ditangkap dari data historis (Verdonck dkk., 2024).

Keunggulan utama *feature engineering* adalah kemampuannya untuk meningkatkan akurasi dan kinerja model secara signifikan dengan mengurangi *noise* dan menambahkan informasi relevan. Dalam studi oleh (Sirocchi dkk., 2024), penggunaan *feature engineering* pada prediksi harga obat di Thailand menunjukkan bahwa pemilihan fitur yang efektif dengan teknik *gain ratio* dapat meningkatkan akurasi prediksi hingga lebih dari 92%. Studi ini menunjukkan bahwa kualitas fitur sering kali lebih penting daripada kompleksitas model itu sendiri. Dengan kata lain, fitur yang baik dapat membuat model sederhana bekerja setara dengan model kompleks.

2.8 MAPE

Teknik MAPE (*Mean Absolute Percentage Error*) menggunakan persentase kesalahan rata-rata yang absolut. Dalam MAPE dihitung perbedaan rata-rata yang absolut antara nilai yang diramalkan dengan aktual untuk periode n , MAPE dihitung dengan persamaan sebagai berikut (Wardani dkk., 2020):

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100}{n} \quad (2.3)$$

Keterangan :

y_i : data aktual periode

\hat{y}_i : data prediksi periode

n : jumlah data

Semakin rendah nilai MAPE, kemampuan dari model peramalan yang digunakan dapat dikatakan baik, dan untuk MAPE terdapat *range* nilai yang dapat dijadikan bahan pengukuran mengenai kemampuan dari suatu model peramalan, *range* nilai tersebut dapat dilihat pada tabel 2.2 (Nabillah & Ranggadara, 2020) :

Tabel 2. 2 *Range* Nilai MAPE

<i>Range MAPE</i>	Keterangan
<10 %	Kompetensi Model Prediksi Sangat Baik
10 – 20 %	Kompetensi Model Prediksi Baik
20 – 50 %	Kompetensi Model Prediksi Layak
>50 %	Kompetensi Model Prediksi Buruk

2.9 Fungsi *Kernel*

Dalam penelitian yang telah dilakukan oleh (Asyiva, 2019) Fungsi *kernel* yang biasa digunakan di SVR adalah sebagai berikut :

Tabel 2. 3 Fungsi *Kernel*

No	Tipe Kernel	Formula
1	Linear	$K(x_i . x_j) = (x_i^T - x)$
2	Polynomial	$K(x_i . x_j) = (x_i . x_j + 1)^p$
3	Fungsi Radial Basis	$K(x_i . x_j) = \exp(-\gamma x_i - x_j ^2)$

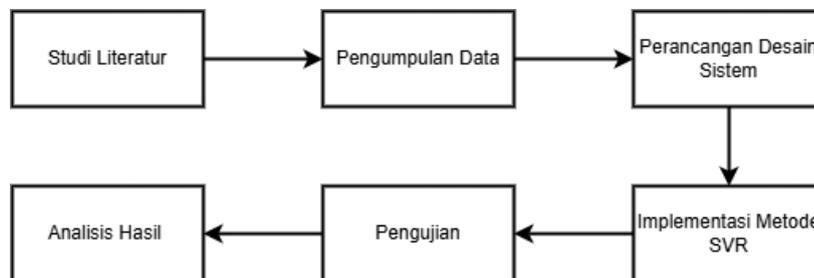
Pada Penelitian ini akan menggunakan *kernel* RBF karena cocok untuk data yang tidak linear. Menurut penelitian terdahulu *kernel* RBF merupakan fungsi *kernel* yang bisa digunakan dalam analisis ketika data tidak secara linear, serta penelitian pada umumnya *kernel* RBF telah terbukti mengungguli dari *kernel* lainnya (Yunanda & Hendrastuty, 2024). *kernel* RBF memiliki parameter γ yang digunakan untuk menentukan seberapa jauh pengaruh dari suatu sampel dalam data *training*.

BAB III

DESAIN DAN IMPLEMENTASI

3.1 Metodologi Penelitian

Metodologi penelitian adalah prosedur atau langkah-langkah yang digunakan sebagai kerangka yang jelas terhadap penelitian yang berlangsung secara terstruktur. Desain penelitian dapat dilihat pada gambar 3.1 :



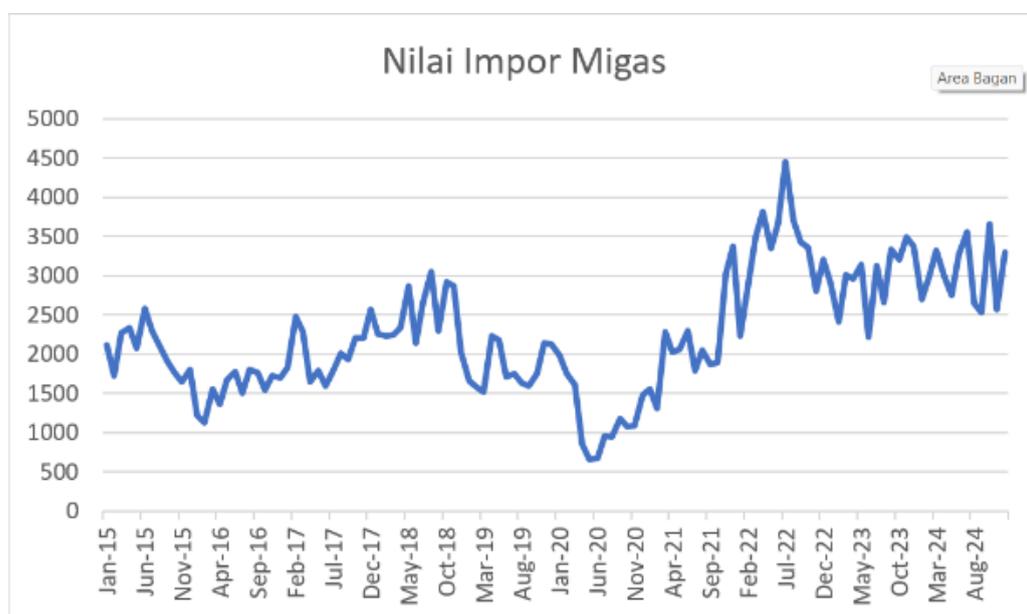
Gambar 3. 1 Metodologi Penelitian

3.2 Studi Literatur

Studi literatur dalam penelitian ini bertujuan untuk memahami konsep dan metode yang relevan dengan prediksi data *time series* menggunakan *Support Vector Regression* (SVR). Penelitian ini mengacu pada berbagai literatur yang membahas algoritma SVR dengan *kernel* RBF, teknik normalisasi data menggunakan *z-score*. Selain itu, literatur terkait peran data impor migas dalam perencanaan ekonomi juga digunakan sebagai acuan untuk memahami pentingnya akurasi prediksi dalam konteks kebijakan pemerintah.

3.3 Pengumpulan Data

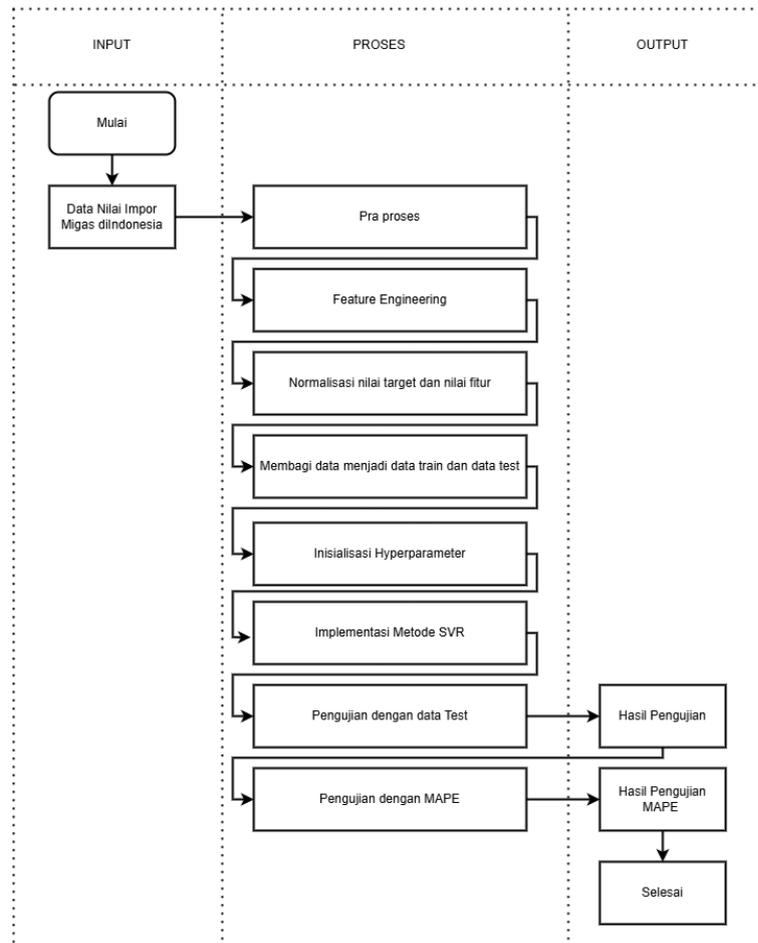
Kemudian proses penelitian selanjutnya adalah pengumpulan data. Data yang digunakan pada penelitian ini adalah data nilai impor migas pada situs web Badan Pusat Nasional (BPS). Data yang digunakan untuk uji perhitungan dalam penelitian ini meliputi data impor migas setiap bulan pada tahun 2015 sampai tahun 2024.



Gambar 3. 2 Grafik data setiap bulan 2015-2024

3.4 Perancangan Desain Sistem

Perancangan desain sistem merupakan gambaran alur sebuah sistem yang akan dirancang pada penelitian. Berikut adalah desain prediksi nilai impor migas pada gambar 3.2



Gambar 3. 3 Desain sistem

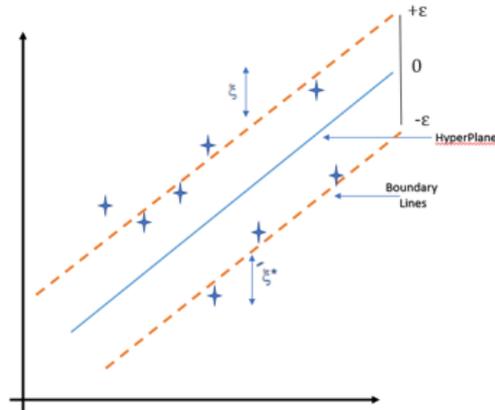
Gambar 3.2 menunjukkan alur sistem prediksi impor migas di Indonesia menggunakan metode *Support Vector Regression* (SVR). Proses diawali dengan *input* data nilai impor migas yang kemudian melalui tahap pra-proses seperti pembersihan data, dan format tanggal. Selanjutnya dilakukan *feature engineering* untuk menghasilkan fitur tambahan seperti *rolling mean*, *differencing*, *seasonal lag*, dan *rolling std*. Setelah itu, data dinormalisasi menggunakan *Min-Max Scaler* untuk target dan *StandardScaler* untuk fitur. Data kemudian dibagi menjadi data latih dan

data uji, dilanjutkan dengan inialisasi *hyperparameter* SVR dan implementasi model.

Model diuji dengan data uji, dan hasil prediksi dievaluasi menggunakan nilai *Mean Absolute Percentage Error* (MAPE) untuk mengukur akurasi model. Pada penelitian ini digunakan *kernel Radial Basis Function* karena menurut (Yunanda & Hendrastuty, 2024) *kernel* RBF merupakan fungsi *kernel* yang bisa digunakan dalam analisis ketika data tidak secara linear, serta penelitian pada umumnya *kernel* RBF telah terbukti mengungguli dari *kernel* lainnya. Langkah selanjutnya adalah melakukan prediksi model *Support Vector Regression* dengan *kernel* RBF. Kemudian menghitung akurasi dari model SVR menggunakan *Mean Absolute Percentage Error* (MAPE)

3.5 Implementasi Metode *Support Vector Regression*

Metode *Support Vector Regression* diimplementasikan pada sistem prediksi nilai impor migas di Indonesia. Gambaran umum algoritma SVR adalah melakukan percobaan untuk menemukan nilai terbaik dalam bentuk garis antara garis *hyperplane* dan garis batas (*boundary line*), seperti yang ditunjukkan pada Gambar 3.4.



Gambar 3. 4 Cara Kerja SVR (Sethi 2020)

Pada Gambar 3.3, garis yang memisahkan dua garis kelas data atas dan bawah dikenal sebagai *hyperplane*. Garis ini akan membantu nilai prediksi pada SVR, sementara rumus persamaan berada pada *hyperplane* 3.1:

$$y = W x + b \tag{3.1}$$

Keterangan:

y : nilai prediksi

W : bobot atau *weight*

x : variabel dependen

b : bias

3.5.1 Persiapan Data

Data yang digunakan adalah data nilai impor migas setiap bulan dari tahun 2015 sampai dengan tahun 2024. Data diambil dari situs resmi Badan Pusat Statistik Indonesia.

Tabel 3. 1 Data Nilai Impor Migas (\$juta)

Periode		Nilai Impor Migas	Periode		Nilai Impor Migas
Tahun	Bulan			Tahun	Bulan	
2015	Januari	2115.1		2023	Januari	2906.1
	Februari	1719.6			Februari	2406.5

	Maret	2268		Maret	3014.8		
	April	2336.3		April	2955		
	Mei	2080.5		Mei	3135.1		
	Juni	2577.5		Juni	2222.3		
	Juli	2294.3		Juli	3132.1		
	Agustus	2108		Agustus	2662		
	September	1912.4		September	3328.6		
	Oktober	1763		Oktober	3206.8		
	November	1640.4		November	3488.7		
	Desember	1798		Desember	3372.4		
	2016	Januari		1221.5	2024	Januari	2698.3
		Februari		1122.9		Februari	2979.6
Maret		1552.4	Maret	3326.5			
April		1362.1	April	2984.3			
Mei		1668.5	Mei	2748.2			
Juni		1772.2	Juni	3270.5			
Juli		1506.4	Juli	3557.7			
Agustus		1795.9	Agustus	2648.4			
September		1766.4	September	2528.5			
Oktober		1545.1	Oktober	3665.9			
November		1724.1	November	2570.3			
Desember		1701.9	Desember	3296.8			

Tabel 3.1 menunjukkan data nilai impor migas di Indonesia setiap bulan dari tahun 2015 – 2024. Jika dilihat dengan seksama data tersebut merupakan data non-linear.

3.5.2 Pra-proses data

Tahap selanjutnya adalah pra-proses data yang bertujuan untuk membersihkan dan mempersiapkan data sebelum pemodelan. Proses ini mencakup penghapusan data tidak valid dan mengubah format tanggal menjadi format *datetime*. Frekuensi data disesuaikan menjadi bulanan agar konsisten. Jika terdapat data yang hilang, maka diisi menggunakan metode interpolasi linear.

3.5.3 Feature engineering

Feature engineering dilakukan untuk menambahkan informasi penting yang dapat meningkatkan performa model prediksi. Beberapa fitur diturunkan dari data asli, seperti rata-rata bergulir (*rolling mean*), standar deviasi bergulir, perbedaan nilai (*differencing*), dan *lag* musiman. Fitur-fitur ini bertujuan untuk menangkap pola musiman, tren jangka pendek, serta fluktuasi data. Setelah fitur ditambahkan, dilakukan penanganan nilai kosong agar data siap digunakan.

3.5.4 Normalisasi Data

Tahap selanjutnya adalah normalisasi data. Normalisasi ini dilakukan menggunakan dua metode, yaitu *Z-Score* dan *Min-Max Scaler*. Metode *Min-Max Scaler* digunakan untuk menormalisasi nilai target agar berada dalam rentang nol dan satu. Hal ini penting agar algoritma SVR dapat bekerja dengan lebih optimal. Menggunakan perhitungan sebagai berikut.

$$x = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (3.2)$$

Keterangan :

x = Nilai data yang akan dinormalisasi,

x_{min} = nilai terkecil

x_{max} = nilai terbesar

Sementara itu, fitur-fitur hasil rekayasa dinormalisasi menggunakan *Z-Score* agar berada dalam rentang skala yang seragam, antara rata-rata 0 dan standar deviasi 1, sehingga memudahkan algoritma SVR dalam melakukan proses pembelajaran secara lebih optimal.

3.5.5 Membagi data menjadi *training* dan *testing*

Setelah data dinormalisasi, data set dibagi menjadi dua bagian: data pelatihan (*train*) dan data pengujian (*test*). Data dibagi dengan rasio 80% data awal untuk pelatihan dan 20% data akhir digunakan untuk pengujian.

3.5.6 Perhitungan data *training* dengan *kernel Radial Basis Function*

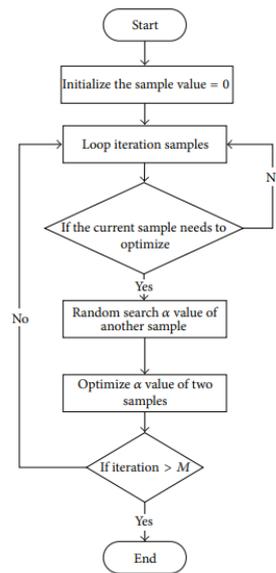
Langkah selanjutnya adalah perhitungan data *training* dengan *kernel Radial Basis Function* (RBF) dinyatakan sebagai berikut:

$$K(x_i . x_j) = \exp(-\gamma ||x_i - x_j ||^2) \quad (3.3)$$

Dari rumus di atas dapat dilihat bahwa $K(x_i . x_j)$ adalah hasil *kernel* antara sampel pelatihan ke-I dan ke-j dan $||x_i - x_j ||^2$ adalah kuadrat dari jarak antara dua vector X_i dan X_j .

3.5.7 Mendapatkan nilai *alpha* (α) dan bias (b)

Langkah selanjutnya yaitu menghitung nilai *alpha* pada setiap data, perhitungan nilai *alpha* perlu menggunakan algoritma optimasi. Salah satu algoritma optimasi yaitu *Sequential Minimal Optimization* (SMO). Menurut Guo dkk., (2015) , *flowchart* algoritma SMO dapat digambarkan sebagai berikut:



Gambar 3. 5 Flowchart Algoritma SMO

Ide dasarnya adalah nilai *alpha* dan bias diinisialisasi dengan 0. Selanjutnya, iterasi dilakukan hingga nilai *alpha* dan bias mencapai kondisi konvergen. Untuk langkah-langkah iterasi utama adalah sebagai berikut:

a. Inisialisasi

Inisialisasi digunakan untuk menentukan nilai pada setiap parameter dan untuk *alpha* dan bias diatur di nilai 0 untuk nilai awalnya.

b. Menentukan *error* untuk setiap data

Kemudian dilakukan prediksi dengan parameter yang diinisialisasi sebelumnya, fungsi prediksi sebagai berikut:

$$f(x) = \sum_{i=1}^m (\alpha_i - \alpha_i^*) K(x_i, x_j) + b \quad (3.4)$$

Pada tahap awal, α dan α^* adalah nol, sehingga nilai prediksi awal untuk setiap data adalah nol juga. Kita gunakan ini untuk menghitung *error* awal pada setiap data dengan rumus:

$$E_i = f(x_i) - y_i \quad (3.5)$$

$$E_j = f(x_j) - y_j \quad (3.5)$$

c. Memeriksa kondisi KKT

Untuk setiap titik data ke i , memeriksa apakah α atau α^* melanggar kondisi KKT, dengan memeriksa dua kondisi berikut:

$$y_i - E_i > \varepsilon + tol \text{ dan } \alpha_i < C \quad (3.7)$$

$$E_i - y_i > \varepsilon + tol \text{ dan } \alpha_i^* < C \quad (3.8)$$

Ketika kondisi KKT terpenuhi maka nilai *alpha* dari titik data tersebut harus diperbarui, namun ketika kondisi tidak terpenuhi maka bisa dilanjutkan ke iterasi berikutnya.

d. Menentukan batas L dan H

Untuk menghitung batas L dan H adalah sebagai berikut:

$$L = \max(0, \alpha_i - \alpha_j) \quad (3.9)$$

$$H = \min(C, C + \alpha_i - \alpha_j) \quad (3.10)$$

Eta η dihitung untuk menjadi nilai pembagi untuk memperbarui α_j , eta dihitung dengan rumus:

$$\eta = 2K[x_i - x_j] - [x_i - x_i] - [x_j - x_j] \quad (3.11)$$

e. Perbarui nilai α_j

Untuk memperbarui nilai α_j menggunakan rumus:

$$\alpha_j = \alpha_j - \frac{E_i - E_j}{\eta} = \quad (3.12)$$

Selanjutnya nilai α_j dibatasi dengan batas L dan H yang sudah didapatkan sebelumnya:

$$\alpha_j = \min(H, \max(L, \alpha_j)) \quad (3.13)$$

f. Perbarui nilai α_i

Setelah mendapatkan nilai α_j , kita dapat memperbarui α_i berdasarkan selisih dari α_j yang lama dan yang baru :

$$\alpha_i = \alpha_i + y_i \cdot y_j \cdot (\alpha_j^{new} - \alpha_j^{old}) \quad (3.14)$$

g. Menghitung bias baru

Kemudian menghitung bias dengan menggunakan dua bias sementara, $b1$ dan $b2$:

$$b_1 = b - E_i - (\alpha_i - \alpha_i^{old}) \cdot k[i, i] - (\alpha_j - \alpha_j^{old}) \cdot k[i, j] \quad (3.15)$$

$$b_2 = b - E_j - (\alpha_i - \alpha_i^{old}) \cdot k[i, j] - (\alpha_j - \alpha_j^{old}) \cdot k[j, j] \quad (3.16)$$

h. Menghitung bias akhir

Jika α_i dan α_j berada dalam rentang $(0, C)$ maka dapat memilih rata-rata dari $b1$ dan $b2$ sebagai bias baru:

$$b = \frac{b_1 - b_2}{2} = \quad (3.17)$$

Proses di atas diulang hingga nilai *alpha* dan bias mencapai konvergensi. Langkah-langkah ini dapat diterapkan pada data set untuk menentukan nilai *alpha* (α) dan bias (b).

3.5.8 Perhitungan prediksi nilai impor migas

Langkah selanjutnya adalah menghitung prediksi nilai impor migas dengan rumus:

$$f(x) = \sum_{i=1}^m (\alpha_i - \alpha_i^*) K(x_i, x_j) + b \quad (3.18)$$

setelah diperoleh hasil prediksi, langkah selanjutnya adalah mengembalikan ke skala awal dengan rumus :

$$\text{denormalisasi} = x \cdot \sigma + \mu \quad (3.19)$$

3.5.9 Pengukuran *error* prediksi dengan MAPE

Evaluasi dilakukan dengan melakukan perhitungan nilai MAPE sebagai metode untuk mengukur keakuratan relatif berdasarkan nilai absolut yang digunakan untuk mengetahui persentase kesalahan dalam prediksi dibandingkan dengan data aktual. Perhitungan MAPE dihitung dengan rumus berikut:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (3.20)$$

Keterangan :

y_i = data aktual periode

\hat{y}_i = data prediksi periode

n = jumlah data

3.5.10 Contoh Perhitungan Manual

Pada bagian ini menjelaskan langkah-langkah perhitungan manual dalam penerapan algoritma *Support Vector Regression* (SVR) menggunakan algoritma *Sequential Minimal Optimization* (SMO). Proses ini mencakup normalisasi, inisialisasi parameter, perhitungan *kernel* matriks, pembaruan nilai *alpha* berdasarkan batas yang ditentukan, perhitungan bias, serta prediksi nilai *output*. Sebagai ilustrasi, digunakan data impor migas bulanan pada tahun 2020. Pendekatan manual ini bertujuan untuk memberikan pemahaman yang lebih mendalam mengenai cara kerja algoritma SVR dalam memodelkan data *time series*.

a. Data input

Sebagai contoh perhitungan manual digunakan data dari 12 bulan pada tahun 2021.

Tabel 3. 2 Data input perhitungan manual

Bulan	Nilai Impor
Januari	1551.8
Februari	1304.3
Maret	2279.1
April	2023.4
Mei	2061.9
Juni	2297.8
Juli	1793.8
Agustus	2049.2
September	1866.8
Oktober	1898.1
November	3025
Desember	3377.8

b. Feature Lag

Digunakan empat jenis fitur pada setiap titik data untuk meningkatkan akurasi prediksi. Fitur pertama adalah *rolling mean* dengan jendela 3, yang

merepresentasikan nilai rata-rata dari tiga bulan sebelumnya sebagai indikator tren jangka pendek. Fitur kedua adalah *rolling standard deviation* (rolling std) dengan jendela 3, yang menggambarkan seberapa besar fluktuasi atau variasi nilai dalam tiga bulan terakhir. Fitur ketiga adalah *differencing* tingkat pertama (diff-1), yaitu selisih antara nilai pada bulan berjalan dan nilai pada bulan sebelumnya, yang bertujuan untuk menangkap pola perubahan dari waktu ke waktu. Terakhir, fitur keempat adalah *seasonal lag*, yakni nilai pada bulan yang sama di tahun sebelumnya, yang digunakan untuk mengakomodasi pola musiman tahunan dalam data. Keempat fitur ini dipilih karena memiliki potensi untuk merepresentasikan karakteristik temporal data secara lebih menyeluruh, serta dapat mendukung kinerja model prediksi dalam menangkap pola historis yang relevan.

Tabel 3. 3 Data dengan *feature lag*

Bulan	Impor Migas	Rolling Mean 3	Rolling Std 3	Diff 1	Seasonal Lag
1	1551.8	1215.2	188.5316596	70	1987.1
2	1304.3	1372.866667	205.5487182	-247.5	1747.6
3	2279.1	1445.966667	104.1699999	974.8	1606.5
4	2023.4	1711.733333	413.7171041	-255.7	854.3
5	2061.9	1868.933333	412.6772131	38.5	657.5
6	2297.8	2121.466667	112.5663163	235.9	677
7	1793.8	2127.7	121.3014702	-504	958.2
8	2049.2	2051.166667	205.8970671	255.4	949.8
9	1866.8	2046.933333	205.7633808	-182.4	1173
10	1898.1	1903.266667	107.4078003	31.3	1078.8
11	3025	1938.033333	79.6385306	1126.9	1085
12	3377.8	2263.3	538.7547927	352.8	1481.8

c. Normalisasi

Data impor migas atau data target dinormalisasi dengan *Min-Max Scaller* sedangkan *feature* akan dinormalisasi dengan *Z-Score*, kemudian ditentukan bahwa nilai impor adalah nilai target dan *feature* adalah nilai *feature*.

Tabel 3. 4 Data setelah dinormalisasi

Bulan	Impor Migas	Rolling Mean 3	Rolling Std 3	Diff 1	Seasonal Lag
1	0.119363395	-1.953355114	-0.25304598	-0.18952131	1.95756505
2	0	-1.459546245	-0.13387191	-0.87330558	1.37082225
3	0.47012298	-1.230598497	-0.84384859	1.759102344	1.02514623
4	0.346804919	-0.398222575	1.323975476	-0.89096552	-0.81764262
5	0.365372558	0.094124703	1.316692899	-0.25736132	-1.29977615
6	0.479141548	0.885054088	-0.7850474	0.167769433	-1.25200378
7	0.236074271	0.904576764	-0.72387326	-1.42571713	-0.56310159
8	0.359247649	0.664875884	-0.13143235	0.209765632	-0.58368046
9	0.271280444	0.651617168	-0.13236858	-0.73310289	-0.03687048
10	0.286375693	0.201656021	-0.82117358	-0.27286761	-0.26764781
11	0.829852906	0.310544531	-1.01564767	2.0866727	-0.25245864
12	1	1.329273271	2.199640945	0.419531264	0.719648

d. Inisialisasi parameter dan nilai awal *alpha*

Langkah selanjutnya adalah menentukan nilai parameter. untuk nilai awal *alpha* ditentukan dengan nilai 0, berikut adalah penentuan nilai parameter dan nilai *alpha*:

$$\begin{aligned}
 C &= 1, \\
 \varepsilon &= 0.01, \\
 \text{tol} &= 10^{-3}, \\
 \gamma &= 0.5 \\
 a &= 0 \\
 a^* &= 0 \\
 b &= 0
 \end{aligned}$$

e. Perhitungan *kernel* matriks

Perhitungan ini menggunakan *kernel* RBF antara satu titik data dengan titik yang lain dan menggunakan γ yang sudah ditentukan sebelumnya, berikut adalah hasil dari perhitungan yang menghasilkan *kernel* matriks 12 x 12 :

$$K = \begin{bmatrix} 1 & 0.585705 & 0.062726 & 0.001430 & 0.000177 & \dots & 8.71959E \\ 0.585705 & 1 & 0.022309 & 0.017940 & 0.002442 & \dots & 0.000471 \\ 0.062726 & 0.022309 & 1 & 0.000688 & 0.000353 & \dots & 0.019923 \\ 0.001430 & 0.017940 & 0.000369 & 1 & 0.645207 & \dots & 0.032688 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ 8.71959E & 0.000471 & 0.000143 & 0.019923 & 0.032668 & \dots & 1 \end{bmatrix}$$

f. Menentukan *error* untuk setiap data

Karena nilai awal α adalah 0 maka hasil prediksi setiap data juga 0, di sini x_i adalah data bulan Februari dan x_j adalah data bulan Desember :

x_i :

$$\begin{aligned} f(x_j) &= (0-0)0.585 + (0-0)1 + (0-0)0.022 + (0-0)0.017 + (0-0)0.0024 + (0-0) \\ &0.0009 + (0-0)0.006 + (0-0)0.008 + (0-0)0.039 + (0-0)0.043 + (0-0)0.0004 \\ &+ (0-0)0.00047 = 0 \end{aligned}$$

x_j :

$$\begin{aligned} f(x_j) &= (0-0)8.719 + (0-0)0.00047 + (0-0)0.00014 + (0-0)0.019 + (0-0)0.03 \\ &2 + (0-0)0.0014 + (0-0)0.0010 + (0-0)0.022 + (0-0)0.020 + (0-0) \\ &0.0026 + (0-0)0.00053 + (0-0)1 = 0 \end{aligned}$$

Kemudian dari hasil prediksi tersebut dapat dihitung *error* dengan data aktual

$$E_i = f(x_i) - y_i = 0 - (0) = 0$$

$$E_j = f(x_j) - y_j = 0 - (1) = -1$$

g. Memeriksa kondisi KKT

Karena $\varepsilon=0.01$ dan toleransi 0.001

- Kondisi untuk α_i

$$|f(x_i)-y_i|=0 < 0.01 + 0.001 = 0.101 \Rightarrow \alpha_i \text{ tidak memenuhi KKT}$$

Karena $\alpha_i=0$ tetapi prediksi berada di bawah margin, maka α_i harus diperbarui.

- Kondisi untuk α_i^*

$$|f(x_i)-y_i|=1 > 0.01 + 0.001 = 0.101 \Rightarrow \alpha_i^* \text{ tidak memenuhi KKT}$$

Karena $\alpha_i^*=0$ prediksi berada di luar margin, maka α_i^* juga harus diperbarui.

h. Menentukan batas L dan H

Batas L dan H ditentukan berdasarkan kondisi $\alpha_i + \alpha_j$ atau $\alpha_i - \alpha_j$, tergantung pada apakah target y_i dan y_j bernilai sama atau tidak. Karena dalam SVR digunakan dua variabel *Lagrange* (α dan α^*), maka perhitungannya disesuaikan.

Maka:

$$L = \max(0, \alpha_i - \alpha_j) = \max(0, 0 - 0) = 0$$

$$H = \min(C, C + \alpha_j - \alpha_i) = \min(1, 1 + 0 - 0) = 1$$

Jadi, pembaruan α_j nantinya akan dibatasi dalam rentang nilai $0 \leq \alpha_j \leq 1$.

i. Menghitung eta (η)

Eta digunakan untuk nilai pembagi saat memperbarui Secara umum, η dihitung berdasarkan *kernel* antara x_i dan x_j :

$$\eta = K(x_i, x_i) + K(x_j, x_j) - 2K(x_i, x_j)$$

Dengan menggunakan nilai dari matriks *kernel (Hessian)* yang telah dihitung:

- $K(x_i, x_i) = 1$
- $K(x_j, x_j) = 1$
- $K(x_i, x_j) = 0.000471$

Maka:

$$\eta = 1 + 1 - 2 \times (0.000471) = 1.999058$$

Karena $\eta > 0$, maka perhitungan α_j dapat dilakukan langsung menggunakan rumus pembaruan.

j. Memperbarui α_j

$$= 0 - \frac{0 - (-1)}{1.999058} = 0 + \frac{1}{1.999058} = 0.500235$$

Karena hasil dari α_j adalah 0.500235 yang berarti di dalam batas L H maka

$$\alpha_j = 0.500235$$

k. Memperbarui α_i

$$\alpha_i^{new} = \alpha_i + (\alpha_j - \alpha_j^{new}) = 0 + (0 - 0.500235) = -0.500235$$

Karena hasil dari α_i adalah -0.500235 yang berarti di luar batas L H maka

$$\alpha_i = \min(1, \max(-0.500235, 0)) = 0$$

l. Menghitung bias

Menghitung bias dapat menggunakan rumus berikut:

$$b1 = b - E_i - (\alpha_i^{new} - \alpha_i)K(x_i, x_i) - (\alpha_j^{new} - \alpha_j)K(x_i, x_j)$$

$$b2 = b - E_j - (\alpha_i^{new} - \alpha_i)K(x_j, x_i) - (\alpha_j^{new} - \alpha_j)K(x_j, x_j)$$

Sehingga :

$$b1 = 0 - (0 - 0) \times (1) - (0.500235 - 0) \times (0.00047172)$$

$$\begin{aligned}
 &= -0.000236002 \\
 b_2 &= -(-1) - (0-0) \times (0.00047172) - (0.500235-0) \times (1) \\
 &= 0.499765 \\
 b &= \frac{-0.000236002 + 0.499765}{2} = 0.249764499
 \end{aligned}$$

Proses di atas diulang hingga nilai α dan b mencapai konvergensi. Langkah-langkah ini dapat diterapkan pada data *input* untuk menentukan nilai *alpha* (α) dan bias (b). Untuk mempermudah komputasi, *Python* digunakan untuk menjalankan iterasi hingga α dan b mencapai konvergensi. Parameter yang digunakan adalah $C = 1$, $\varepsilon = 0.01$, $\gamma = 0.5$, $\text{tol} = 10^{-3}$, Hasil akhirnya adalah nilai *alpha* (α) dan bias (b) sebagai berikut:

Tabel 3. 5 Nilai alpha disetiap titik data

Alpha	Alpha*
0	0
0	0
1	0.83102955
0.5175689	0.45398223
0.9096672	1
1	0.78909602
0	0
0.6236845	0.51930812
0	0.00621426
0.8497951	1
1	0.9488629
1	1

Bias = 0.50024

m. Menghitung prediksi

Setelah didapatkan nilai α dan b , maka selanjutnya adalah menghitung prediksi dengan fungsi prediksi SVR:

$$\begin{aligned} f(x_i) = & (0 - 0) \times 1 + (0 - 0) \times 0.5857 + (1 - 0.831) \times 0.0627 + (0.517 - \\ & 0.453) \times 0.0014 + (0.909 - 1) \times 0.0001 + (1 - 0.789) \times 8.4034\text{E-}05 + (0 - \\ & 0) \times 0.00029 + (0.623 - 0.519) \times 0.0011 + (0 - 0.006) \times 0.0039 + (0.849 - \\ & 1) \times 0.0069 + (1 - 0.948) \times 0.0003 + (1 - 1) \times 8.71959\text{E-}05 + 0.50024 = - \\ & 0.479210533 \end{aligned}$$

Setelah ditemukan hasil dari prediksi pada bulan pertama untuk menganalisis hasil dibutuhkan denormalisasi agar data kembali ke skala awal.

$$\begin{aligned} x &= (x_{max} - x_{min}) + x_{min} = \\ &= 1722.670027 \end{aligned}$$

Berikut adalah hasil prediksi menggunakan metode SVR dari data 12 bulan awal di tahun 2021

Tabel 3. 6 Data hasil prediksi dengan SVR

Bulan	Data Aktual	Data Prediksi
1	1551.8	1722.670027
2	1304.3	1686.535826
3	2279.1	2277.446584
4	2023.4	1729.179871
5	2061.9	1616.191869
6	2297.8	2392.473409
7	1793.8	1716.028582
8	2049.2	2158.62605
9	1866.8	1723.402883
10	1898.1	1712.037703
11	3025	1995.903468
12	3377.8	1691.262453

n. Menghitung MAPE

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_{actual} - y_{prediction}}{y_{actual}} \right| \times 100 = 15.98\%$$

3.6 Skenario Uji Coba

Pengujian dilakukan untuk memastikan validitas hasil prediksi yang dihasilkan oleh model. Dalam penelitian ini, pengujian diterapkan dengan menggunakan kombinasi antar parameter pada algoritma *Support Vector Regression* (SVR), yaitu C , ϵ , dan γ . Untuk memprediksi nilai impor minyak dan gas (migas) di Indonesia. Skenario pengujian ini divisualisasikan pada Gambar 3.4, yang memberikan gambaran mengenai alur dan langkah-langkah pengujian yang dilaksanakan dalam penelitian.



Gambar 3. 6 Skenario Pengujian

Dari skenario pengujian di atas kombinasi parameter memerlukan nilai yang akan diuji, berikut nilai setiap parameter:

Tabel 3. 7 Nilai Setiap Parameter

Parameter	
<i>Kernel</i>	RBF
Nilai C	1, 10, 100
Nilai epsilon	0.01, 0.1, 0.2
Nilai gamma	0.01, 0.1, 0.2

Parameter yang digunakan dalam penelitian ini mencakup *kernel* RBF dengan kombinasi nilai C (1, 10, 100), epsilon (0.01, 0.1, 0.2), dan gamma (0.01, 0.1, 0.2). Dari kombinasi ketiga *hyperparameter* tersebut, terbentuk total 27 model SVR (*Support Vector Regression*) yang masing-masing model akan diuji menggunakan data yang telah disiapkan. Evaluasi kinerja setiap model dilakukan dengan menggunakan metrik *Mean Absolute Percentage Error* (MAPE), dan model dengan nilai MAPE paling rendah akan dipilih sebagai model terbaik karena dianggap memiliki akurasi prediksi tertinggi. Pemilihan rentang nilai *hyperparameter* dilakukan secara eksploratif, yakni melalui eksperimen awal untuk mengamati sensitivitas model terhadap berbagai nilai parameter, sebelum ditetapkan sebagai kombinasi akhir. Pendekatan eksploratif ini telah banyak digunakan dalam penelitian terdahulu sebagai metode *tuning hyperparameter* secara manual, salah satunya oleh (Afandi dkk., 2023) , yang secara eksploratif menguji kombinasi *hyperparameter* untuk memperoleh konfigurasi yang optimal.

BAB IV

HASIL DAN PEMBAHASAN

4.1 Skenario Uji Coba

Dalam sistem yang dibangun, tahapan evaluasi dilakukan untuk menilai kemampuan model dalam melakukan prediksi nilai impor migas di Indonesia secara akurat. Untuk mengukur seberapa baik hasil prediksi tersebut, digunakan metode evaluasi berbasis *error*. Dengan kata lain, evaluasi *error* berfungsi sebagai indikator kinerja dari hasil prediksi yang dihasilkan oleh model. Studi ini menggunakan metode *Support Vector Regression* (SVR) untuk memprediksi nilai impor migas Indonesia pada periode 2015–2024. Untuk mencapai tujuan tersebut, dilakukan beberapa langkah berikut:

1. Memperoleh data set dengan menggunakan data yang diambil dari *website* resmi badan pusat statistik Indonesia.
2. Kemudian, melakukan penyesuaian format tanggal agar sesuai untuk pemrosesan lebih lanjut.
3. Selanjutnya dilakukan normalisasi data, nilai target dinormalisasi menggunakan metode *Min-Max Scaller*, sedangkan nilai fitur dinormalisasi menggunakan *Z-Score* agar seluruh variabel berada pada skala yang sama.
4. Selanjutnya, data yang digunakan dibagi menjadi dua bagian yaitu data pelatihan dan data uji. Ada sembilan puluh enam data pelatihan dan dua puluh empat data uji.
5. Melakukan percobaan dengan berbagai kombinasi nilai *hyperparameter* utama dalam algoritma *Support Vector Regression*, Masing-masing

hyperparameter diuji dengan tiga nilai yang berbeda. Nilai-nilai tersebut adalah: $C = 1, 10, \text{ dan } 100$; $\epsilon = 0.001, 0.01, \text{ dan } 0.1$; serta $\gamma = 0.001, 0.01, \text{ dan } 0.1$. Dengan demikian, terdapat total 27 kombinasi skenario ($3 \times 3 \times 3$) yang dihasilkan dari seluruh kemungkinan kombinasi ketiga *hyperparameter* tersebut.

Tabel 4. 1 Skenario *Hyperparameter*

Skenario	C	Epsilon	Gamma
1	1	0.001	0.001
2	1	0.001	0.01
3	1	0.001	0.1
4	1	0.01	0.001
5	1	0.01	0.01
6	1	0.01	0.1
7	1	0.1	0.001
8	1	0.1	0.01
9	1	0.1	0.1
10	10	0.001	0.001
11	10	0.001	0.01
12	10	0.001	0.1
13	10	0.01	0.001
14	10	0.01	0.01
15	10	0.01	0.1
16	10	0.1	0.001
17	10	0.1	0.01
18	10	0.1	0.1
19	100	0.001	0.001
20	100	0.001	0.01
21	100	0.001	0.1
22	100	0.01	0.001
23	100	0.01	0.01
24	100	0.01	0.1
25	100	0.1	0.001
26	100	0.1	0.01
27	100	0.1	0.1

Tabel tersebut menyajikan kombinasi nilai dari setiap *hyperparameter* yang menghasilkan total 27 model SVR yang akan diuji. Setiap model akan digunakan untuk melakukan prediksi terhadap nilai impor migas, dan hasil prediksi tersebut kemudian dievaluasi secara objektif menggunakan *Mean Absolute Percentage Error* (MAPE).

6. Selanjutnya tahapan *training*, dan *testing*. Untuk tahap ini, metode SVR dengan *kernel* RBF.
7. Menguji model SVR yang telah dilatih dengan data uji untuk mengevaluasi model dalam memprediksi nilai impor migas di Indonesia. Evaluasi model menggunakan perhitungan nilai MAPE.

Library *libsvm* digunakan dalam proses *fitting* model SVR karena memiliki implementasi yang stabil dan terbukti akurat. Dalam proses optimasinya, *libsvm* menggunakan metode dekomposisi yang serupa dengan algoritma SMO (*Sequential Minimal Optimization*) untuk menyelesaikan permasalahan optimasi pada *Support Vector Regression* (Chang & Lin, 2011).

4.2 Hasil Uji Coba

Hasil evaluasi sistem yang menggunakan metode *Support Vector Regression* (SVR) akan dibahas pada subbab ini. Perbandingan antara nilai aktual dan nilai prediksi digunakan sebagai dasar untuk mengevaluasi kinerja sistem yang telah dikembangkan. Tujuan dari evaluasi ini adalah untuk mengetahui sejauh mana efektivitas metode SVR dalam memprediksi nilai impor migas di Indonesia. Penilaian difokuskan pada model dengan performa prediksi terbaik, yang

ditentukan secara objektif berdasarkan nilai *Mean Absolute Percentage Error* (MAPE) terendah.

4.2.1 Hasil dari uji coba Skenario ke-1

Pada skenario 1 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.2

Tabel 4. 2 Parameter Skenario 1

Parameter	
<i>Kernel</i>	RBF
Nilai C	1
Nilai epsilon	0.001
Nilai gamma	0.001

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 1 dapat dilihat pada tabel 4.3

Tabel 4. 3 Hasil Skenario 1

Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2335.509	1/1/2024	2698.3	2340.655
2/1/2023	2406.5	2237.818	2/1/2024	2979.6	2501.562
3/1/2023	3014.8	2567.541	3/1/2024	3326.5	2639.15
4/1/2023	2955	2415.48	4/1/2024	2984.3	2582.51
5/1/2023	3135.1	2814.109	5/1/2024	2748.2	2421.519
6/1/2023	2222.3	1965.159	6/1/2024	3270.5	2673.924
7/1/2023	3132.1	2807.46	7/1/2024	3557.7	2897.669
8/1/2023	2662	2120.15	8/1/2024	2648.4	2365.047
9/1/2023	3328.6	3111.562	9/1/2024	2528.5	2302.315
10/1/2023	3206.8	2622.776	10/1/2024	3665.9	2964.502
11/1/2023	3488.7	3124.366	11/1/2024	2570.3	2249.947
12/1/2023	3372.4	2725.903	12/1/2024	3296.8	3164.574

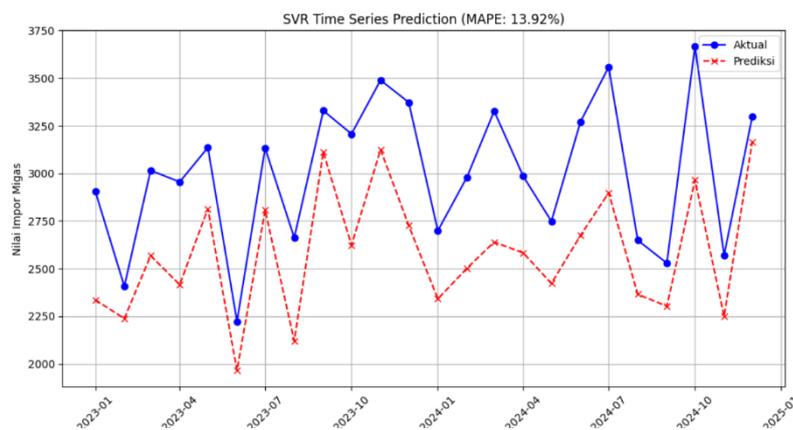
Hasil prediksi pada skenario 1 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah

mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.4.

Tabel 4. 4 Nilai Keakuratan Skenario 1

<i>Hyperparameter</i>	MAPE
C= 1, epsilon = 0.001, gamma = 0.01	13.92%

Hyperparameter yang digunakan adalah C=1 ,epsilon=0.001, dan gamma=0.001. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error (MAPE)* sebesar 13.92%.



Gambar 4. 1 Visualisasi Skenario 1

Dari gambar 4.1 dapat dijelaskan bahwa tingkat prediksi cenderung baik namun nilai C dan gamma yang kecil menyebabkan model terlalu sederhana dan kurang mampu menangkap pola data.

4.2.2 Hasil dari uji coba Skenario ke-2

Pada skenario 2 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.5

Tabel 4. 5 Parameter Skenario 2

Parameter	
<i>Kernel</i>	RBF
Nilai C	1
Nilai epsilon	0.001
Nilai gamma	0.01

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 1 dapat dilihat pada tabel 4.6

Tabel 4. 6 Hasil Skenario 2

Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2704.913	1/1/2024	2698.3	2740.597
2/1/2023	2406.5	2522.671	2/1/2024	2979.6	2992.12
3/1/2023	3014.8	2988.027	3/1/2024	3326.5	3110.421
4/1/2023	2955	2801.999	4/1/2024	2984.3	2971.408
5/1/2023	3135.1	3225.241	5/1/2024	2748.2	2858.329
6/1/2023	2222.3	2261.715	6/1/2024	3270.5	3141.885
7/1/2023	3132.1	3191.205	7/1/2024	3557.7	3375.581
8/1/2023	2662	2422.095	8/1/2024	2648.4	2664.135
9/1/2023	3328.6	3494.917	9/1/2024	2528.5	2719.61
10/1/2023	3206.8	3014.548	10/1/2024	3665.9	3359.041
11/1/2023	3488.7	3590.566	11/1/2024	2570.3	2382.904
12/1/2023	3372.4	3259.574	12/1/2024	3296.8	3583.678

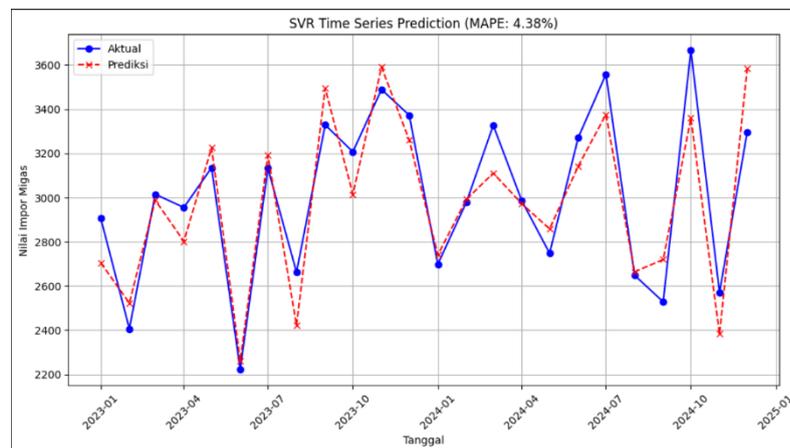
Hasil prediksi pada skenario 2 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang

mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.7.

Tabel 4.7 Nilai Keakuratan Skenario 2

<i>Hyperparameter</i>	MAPE
C= 1, epsilon = 0.001, gamma = 0.01	4.38%

Hyperparameter yang digunakan adalah C=1 ,epsilon=0.001, dan gamma=0.01. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 4.38%.



Gambar 4.2 Visualisasi Skenario 2

Dari gambar 4.2 dapat dijelaskan bahwa tingkat prediksi sangat baik. Gamma memberikan pengaruh data yang cukup luas namun tidak terlalu sempit, sementara C rendah menjaga generalisasi.

4.2.3 Hasil dari uji coba Skenario ke-3

Pada skenario 1 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.8

Tabel 4. 8 Parameter Skenario 3

Parameter	
Kernel	RBF
Nilai C	1
Nilai epsilon	0.001
Nilai gamma	0.1

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 1 dapat dilihat pada tabel 4.9

Tabel 4. 9 Hasil Skenario 3

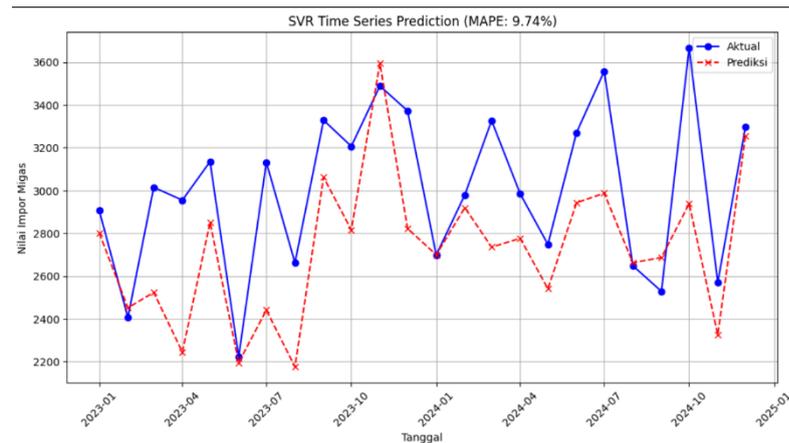
Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2801.454	1/1/2024	2698.3	2699.487
2/1/2023	2406.5	2451.676	2/1/2024	2979.6	2919.691
3/1/2023	3014.8	2523.653	3/1/2024	3326.5	2735.285
4/1/2023	2955	2244.821	4/1/2024	2984.3	2776.427
5/1/2023	3135.1	2850.624	5/1/2024	2748.2	2540.631
6/1/2023	2222.3	2195.556	6/1/2024	3270.5	2942.672
7/1/2023	3132.1	2440.855	7/1/2024	3557.7	2987.602
8/1/2023	2662	2175.903	8/1/2024	2648.4	2662.135
9/1/2023	3328.6	3062.506	9/1/2024	2528.5	2686.972
10/1/2023	3206.8	2815.59	10/1/2024	3665.9	2938.377
11/1/2023	3488.7	3594.118	11/1/2024	2570.3	2326.354
12/1/2023	3372.4	2822.192	12/1/2024	3296.8	3255.032

Hasil prediksi pada skenario 3 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.10.

Tabel 4. 10 Nilai Keakuratan Skenario 3

Hyperparameter	MAPE
C= 1, epsilon = 0.001, gamma = 0.1	9.74%

Hyperparameter yang digunakan adalah $C=1$, $\epsilon=0.001$, dan $\gamma=0.1$. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 9.74%.



Gambar 4. 3 Visualisasi Skenario 3

Dari gambar 4.3 dapat dijelaskan bahwa tingkat prediksi cenderung baik namun γ tinggi menyebabkan model terlalu sensitif terhadap data dan berpotensi *overfitting*. Ini menyebabkan akurasi menurun dibanding skenario 2.

4.2.4 Hasil dari uji coba Skenario ke-4

Pada skenario 4 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.11

Tabel 4. 11 Parameter Skenario 4

Parameter	
<i>Kernel</i>	RBF
Nilai C	1
Nilai epsilon	0.01
Nilai gamma	0.001

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 4 dapat dilihat pada tabel 4.12

Tabel 4. 12 Hasil Skenario 4

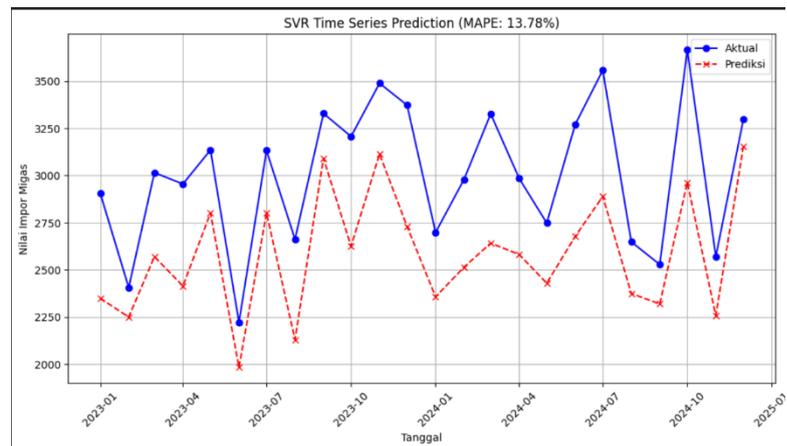
Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2349.874	1/1/2024	2698.3	2357.173
2/1/2023	2406.5	2249.979	2/1/2024	2979.6	2514.648
3/1/2023	3014.8	2570.146	3/1/2024	3326.5	2641.694
4/1/2023	2955	2414.529	4/1/2024	2984.3	2581.54
5/1/2023	3135.1	2801.689	5/1/2024	2748.2	2429.259
6/1/2023	2222.3	1984.269	6/1/2024	3270.5	2677.613
7/1/2023	3132.1	2801.125	7/1/2024	3557.7	2889.252
8/1/2023	2662	2130.894	8/1/2024	2648.4	2374.816
9/1/2023	3328.6	3091.334	9/1/2024	2528.5	2319.464
10/1/2023	3206.8	2625.104	10/1/2024	3665.9	2962.64
11/1/2023	3488.7	3113.923	11/1/2024	2570.3	2258.439
12/1/2023	3372.4	2729.67	12/1/2024	3296.8	3152.346

Hasil prediksi pada skenario 4 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.13.

Tabel 4. 13 Nilai Keakuratan Skenario 4

<i>Hyperparameter</i>	MAPE
C= 1, epsilon = 0.01, gamma = 0.001	13.78%

Hyperparameter yang digunakan adalah C=1 ,epsilon=0.1, dan gamma=0.001. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 13.78%.



Gambar 4. 4 Visualisasi Skenario 4

Dari gambar 4.4 dapat dijelaskan bahwa tingkat prediksi cenderung baik namun Epsilon lebih besar menyebabkan model lebih permisif terhadap *error*, sementara gamma kecil membuat model terlalu halus. Ini menunjukkan kombinasi yang kurang tepat.

4.2.5 Hasil dari uji coba Skenario ke-5

Pada skenario 5 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.14

Tabel 4. 14 Parameter Skenario 5

Parameter	
<i>Kernel</i>	RBF
Nilai C	1
Nilai epsilon	0.01
Nilai gamma	0.01

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 5 dapat dilihat pada tabel 4.15

Tabel 4. 15 Hasil Skenario 5

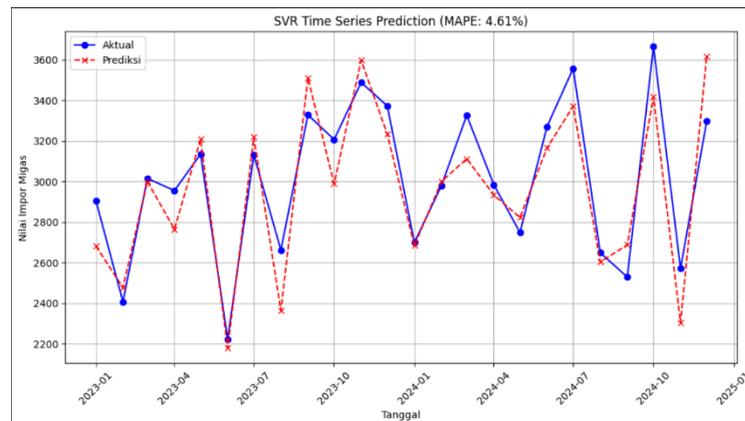
Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2681.742	1/1/2024	2698.3	2683.612
2/1/2023	2406.5	2476.053	2/1/2024	2979.6	2999.842
3/1/2023	3014.8	3000.244	3/1/2024	3326.5	3111.985
4/1/2023	2955	2764.309	4/1/2024	2984.3	2933.925
5/1/2023	3135.1	3208.79	5/1/2024	2748.2	2821.864
6/1/2023	2222.3	2178.075	6/1/2024	3270.5	3165.236
7/1/2023	3132.1	3218.488	7/1/2024	3557.7	3371.412
8/1/2023	2662	2363.388	8/1/2024	2648.4	2602.56
9/1/2023	3328.6	3510.818	9/1/2024	2528.5	2687.447
10/1/2023	3206.8	2988.336	10/1/2024	3665.9	3418.561
11/1/2023	3488.7	3597.673	11/1/2024	2570.3	2303.167
12/1/2023	3372.4	3232.93	12/1/2024	3296.8	3616.527

Hasil prediksi pada skenario 5 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.16.

Tabel 4. 16 Nilai Keakuratan Skenario 5

<i>Hyperparameter</i>	MAPE
C= 1, epsilon = 0.01, gamma = 0.01	4.61%

Hyperparameter yang digunakan adalah C=1 ,epsilon=0.01, dan gamma=0.01. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 4.61%.



Gambar 4. 5 Visualisasi Skenario 5

Dari gambar 4.5 dapat dijelaskan bahwa tingkat prediksi cenderung sangat baik. kombinasi C kecil, epsilon sedang, dan gamma sedang mampu menjaga keseimbangan antara bias dan variansi.

4.2.6 Hasil dari uji coba Skenario ke-6

Pada skenario 6 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.17

Tabel 4. 17 Parameter Skenario 6

Parameter	
Kernel	RBF
Nilai C	1
Nilai epsilon	0.01
Nilai gamma	0.1

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 1 dapat dilihat pada tabel 4.18

Tabel 4. 18 Hasil Skenario 6

Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2792.744	1/1/2024	2698.3	2742.667
2/1/2023	2406.5	2482.065	2/1/2024	2979.6	2943.855

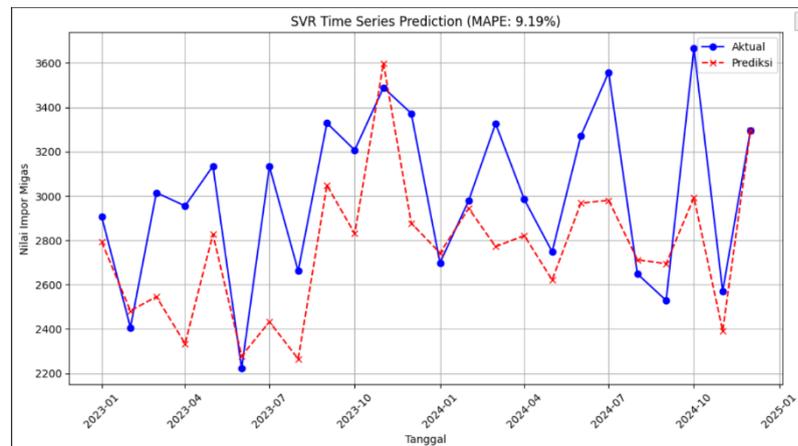
3/1/2023	3014.8	2545.568		3/1/2024	3326.5	2771.585
4/1/2023	2955	2333.726		4/1/2024	2984.3	2821.095
5/1/2023	3135.1	2827.273		5/1/2024	2748.2	2621.159
6/1/2023	2222.3	2278.248		6/1/2024	3270.5	2967.409
7/1/2023	3132.1	2432.539		7/1/2024	3557.7	2980.594
8/1/2023	2662	2264.959		8/1/2024	2648.4	2711.941
9/1/2023	3328.6	3048.075		9/1/2024	2528.5	2694.635
10/1/2023	3206.8	2830.048		10/1/2024	3665.9	2993.205
11/1/2023	3488.7	3598.98		11/1/2024	2570.3	2391.815
12/1/2023	3372.4	2877.457		12/1/2024	3296.8	3295.372

Hasil prediksi pada skenario 6 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.19.

Tabel 4. 19 Nilai Keakuratan Skenario 6

<i>Hyperparameter</i>	MAPE
C= 1, epsilon = 0.01, gamma = 0.1	9.19%

Hyperparameter yang digunakan adalah C=1 ,epsilon=0.01, dan gamma=0.1. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 9.19%.



Gambar 4. 6 Visualisasi Skenario 6

Dari gambar 4.6 dapat dijelaskan bahwa tingkat prediksi cenderung baik namun gamma tinggi mempersempit pengaruh data, dan bila dikombinasi dengan C kecil, bisa menyebabkan model tidak stabil.

4.2.7 Hasil dari uji coba Skenario ke-7

Pada skenario 7 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.20

Tabel 4. 20 Parameter Skenario 7

Parameter	
Kernel	RBF
Nilai C	1
Nilai epsilon	0.1
Nilai gamma	0.001

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 7 dapat dilihat pada tabel 4.21

Tabel 4. 21 Hasil Skenario 7

Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2314.518	1/1/2024	2698.3	2353.003
2/1/2023	2406.5	2285.755	2/1/2024	2979.6	2402.115

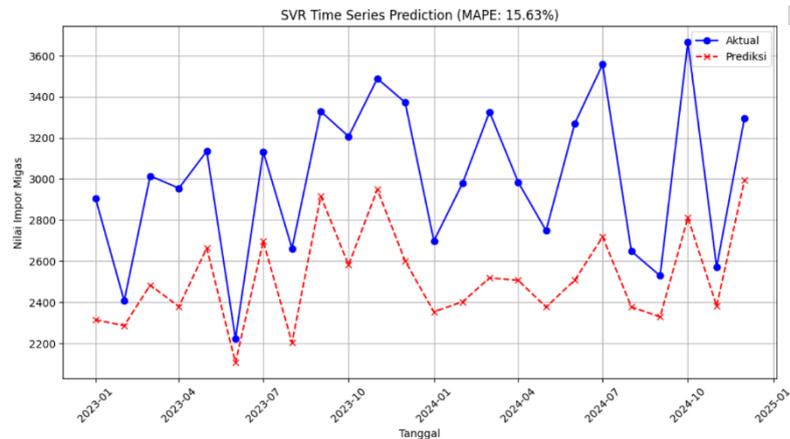
3/1/2023	3014.8	2483.197		3/1/2024	3326.5	2518.336
4/1/2023	2955	2378.74		4/1/2024	2984.3	2506.244
5/1/2023	3135.1	2663.463		5/1/2024	2748.2	2376.326
6/1/2023	2222.3	2106.331		6/1/2024	3270.5	2507.529
7/1/2023	3132.1	2696.575		7/1/2024	3557.7	2717.979
8/1/2023	2662	2203.147		8/1/2024	2648.4	2377.286
9/1/2023	3328.6	2916.359		9/1/2024	2528.5	2328.177
10/1/2023	3206.8	2580.907		10/1/2024	3665.9	2811.829
11/1/2023	3488.7	2948.666		11/1/2024	2570.3	2381.16
12/1/2023	3372.4	2600.926		12/1/2024	3296.8	2993.211

Hasil prediksi pada skenario 7 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.22.

Tabel 4. 22 Nilai Keakuratan Skenario 7

<i>Hyperparameter</i>	MAPE
C= 1, epsilon = 0.1, gamma = 0.001	15.63%

Hyperparameter yang digunakan adalah C=1 ,epsilon=0.1, dan gamma=0.001. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 15.63%.



Gambar 4. 7 Visualisasi Skenario 7

Dari gambar 4.7 dapat dijelaskan bahwa tingkat prediksi cenderung baik namun epsilon besar menyebabkan toleransi *error* terlalu tinggi, model kurang presisi, dan gamma kecil membuat model tidak cukup fleksibel.

4.2.8 Hasil dari uji coba Skenario ke-8

Pada skenario 8 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.23

Tabel 4. 23 Parameter Skenario 8

Parameter	
Kernel	RBF
Nilai C	1
Nilai epsilon	0.1
Nilai gamma	0.01

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 8 dapat dilihat pada tabel 4.24

Tabel 4. 24 Hasil Skenario 8

Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2592.852	1/1/2024	2698.3	2579.145
2/1/2023	2406.5	2412.474	2/1/2024	2979.6	2822.391

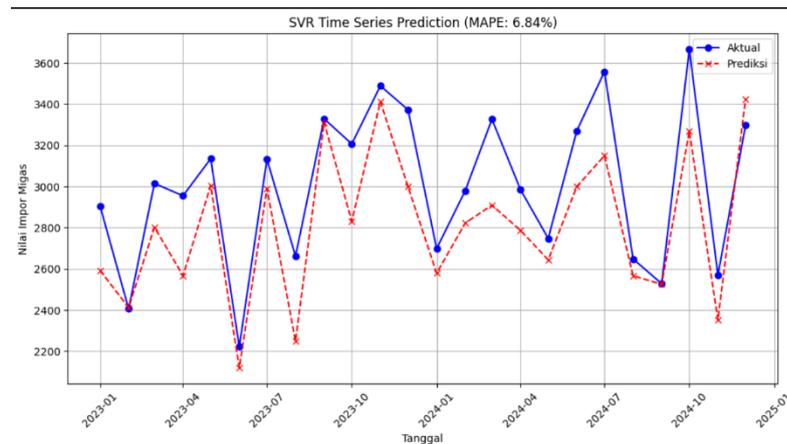
3/1/2023	3014.8	2801.985		3/1/2024	3326.5	2909.47
4/1/2023	2955	2567.711		4/1/2024	2984.3	2786.828
5/1/2023	3135.1	3004.782		5/1/2024	2748.2	2643.985
6/1/2023	2222.3	2120.098		6/1/2024	3270.5	2999.742
7/1/2023	3132.1	2990.331		7/1/2024	3557.7	3149.539
8/1/2023	2662	2249.757		8/1/2024	2648.4	2566.751
9/1/2023	3328.6	3310.863		9/1/2024	2528.5	2525.323
10/1/2023	3206.8	2831.608		10/1/2024	3665.9	3268.282
11/1/2023	3488.7	3411.989		11/1/2024	2570.3	2352.921
12/1/2023	3372.4	2999.137		12/1/2024	3296.8	3424.699

Hasil prediksi pada skenario 8 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.25.

Tabel 4. 25 Nilai Keakuratan Skenario 8

<i>Hyperparameter</i>	MAPE
C= 1, epsilon = 0.1, gamma = 0.01	6.84%

Hyperparameter yang digunakan adalah C=1 ,epsilon=0.1, dan gamma=0.01. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 6.84%.



Gambar 4. 8 Visualisasi Skenario 8

Dari gambar 4.8 dapat dijelaskan bahwa tingkat prediksi cenderung sangat baik namun epsilon besar tetap memberikan *error* toleransi besar, tapi gamma sedang membantu menyesuaikan data lebih baik.

4.2.9 Hasil dari uji coba Skenario ke-9

Pada skenario 9 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.26

Tabel 4. 26 Parameter Skenario 9

Parameter	
Kernel	RBF
Nilai C	1
Nilai epsilon	0.1
Nilai gamma	0.1

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 9 dapat dilihat pada tabel 4.27

Tabel 4. 27 Hasil Skenario 9

Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2687.713	1/1/2024	2698.3	2673.052
2/1/2023	2406.5	2482.869	2/1/2024	2979.6	2833.514

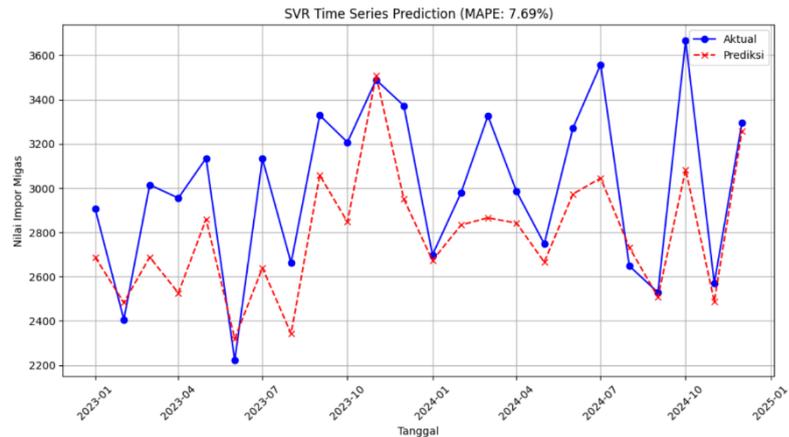
3/1/2023	3014.8	2688.182		3/1/2024	3326.5	2865.84
4/1/2023	2955	2526.167		4/1/2024	2984.3	2841.939
5/1/2023	3135.1	2859.56		5/1/2024	2748.2	2665.555
6/1/2023	2222.3	2319.861		6/1/2024	3270.5	2973.094
7/1/2023	3132.1	2639.856		7/1/2024	3557.7	3045.169
8/1/2023	2662	2342.693		8/1/2024	2648.4	2732.172
9/1/2023	3328.6	3057.99		9/1/2024	2528.5	2507.987
10/1/2023	3206.8	2847.026		10/1/2024	3665.9	3083.495
11/1/2023	3488.7	3508.041		11/1/2024	2570.3	2488.146
12/1/2023	3372.4	2950.417		12/1/2024	3296.8	3258.81

Hasil prediksi pada skenario 9 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.28.

Tabel 4. 28 Nilai Keakuratan Skenario 9

<i>Hyperparameter</i>	MAPE
C= 1, epsilon = 0.1, gamma = 0.1	7.69%

Hyperparameter yang digunakan adalah C=1 ,epsilon=0.1, dan gamma=0.1. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 7.69%.



Gambar 4. 9 Visualisasi Skenario 9

Dari gambar 4.9 dapat dijelaskan bahwa tingkat prediksi cenderung sangat baik namun kombinasi epsilon besar dan gamma tinggi menyebabkan model *overfitting* pada data *noise*.

4.2.10 Hasil dari uji coba Skenario ke-10

Pada skenario 10 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.29

Tabel 4. 29 Parameter Skenario 10

Parameter	
<i>Kernel</i>	RBF
Nilai C	10
Nilai epsilon	0.001
Nilai gamma	0.001

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 10 dapat dilihat pada tabel 4.30

Tabel 4. 30 Hasil Skenario 10

Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2683.512	1/1/2024	2698.3	2725.523
2/1/2023	2406.5	2500.754	2/1/2024	2979.6	2971.726

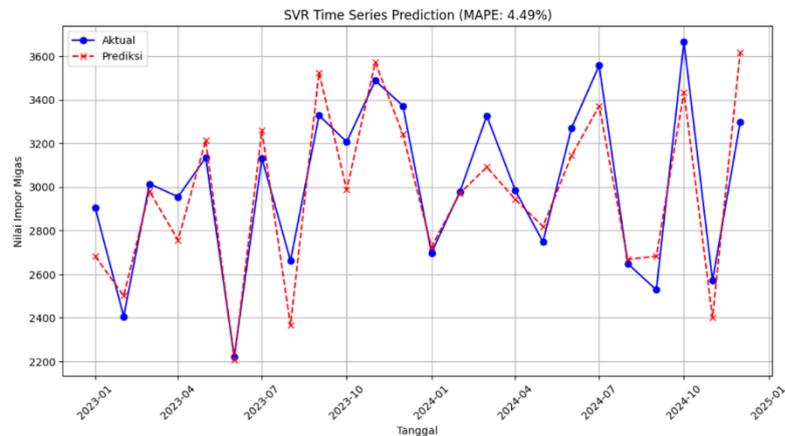
3/1/2023	3014.8	2981.22		3/1/2024	3326.5	3091.359
4/1/2023	2955	2756.304		4/1/2024	2984.3	2943.119
5/1/2023	3135.1	3214.577		5/1/2024	2748.2	2818.888
6/1/2023	2222.3	2206.313		6/1/2024	3270.5	3144.12
7/1/2023	3132.1	3259.605		7/1/2024	3557.7	3371.83
8/1/2023	2662	2366.375		8/1/2024	2648.4	2668.153
9/1/2023	3328.6	3525.575		9/1/2024	2528.5	2682.558
10/1/2023	3206.8	2987.069		10/1/2024	3665.9	3434.987
11/1/2023	3488.7	3572.773		11/1/2024	2570.3	2400.332
12/1/2023	3372.4	3240.877		12/1/2024	3296.8	3617.369

Hasil prediksi pada skenario 10 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.31.

Tabel 4. 31 Nilai Keakuratan Skenario 10

<i>Hyperparameter</i>	MAPE
C= 10, epsilon = 0.001, gamma = 0.001	4.49%

Hyperparameter yang digunakan adalah C=10 ,epsilon=0.001, dan gamma=0.001. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 4.49%.



Gambar 4. 10 Visualisasi Skenario 10

Dari gambar 4.10 dapat dijelaskan bahwa tingkat prediksi cenderung sangat baik. dengan C sedang, model dapat menyeimbangkan kompleksitas dan regularisasi. Ini menunjukkan penyesuaian model yang baik, meski epsilon cukup besar.

4.2.11 Hasil dari uji coba Skenario ke-11

Pada skenario 11 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.32

Tabel 4. 32 Parameter Skenario 11

Parameter	
Kernel	RBF
Nilai C	10
Nilai epsilon	0.001
Nilai gamma	0.01

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 11 dapat dilihat pada tabel 4.33

Tabel 4. 33 Hasil Skenario 11

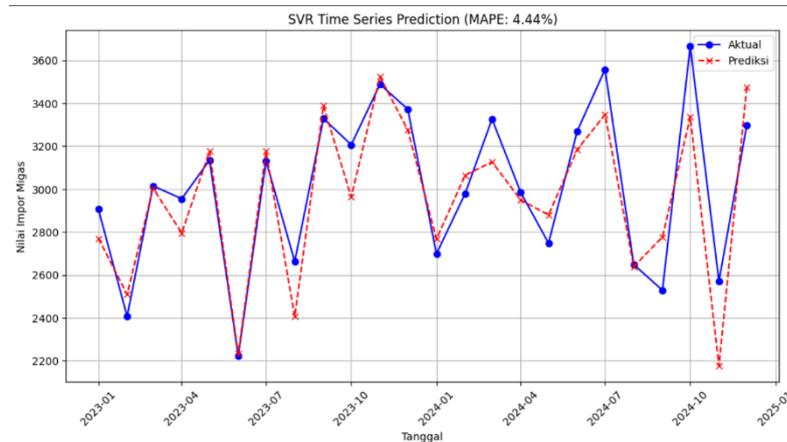
Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2770.668	1/1/2024	2698.3	2767.629
2/1/2023	2406.5	2509.263	2/1/2024	2979.6	3064.985
3/1/2023	3014.8	3004.491	3/1/2024	3326.5	3126.681
4/1/2023	2955	2795.332	4/1/2024	2984.3	2949.088
5/1/2023	3135.1	3176.75	5/1/2024	2748.2	2879.554
6/1/2023	2222.3	2232.011	6/1/2024	3270.5	3183.882
7/1/2023	3132.1	3175.63	7/1/2024	3557.7	3347.836
8/1/2023	2662	2405.918	8/1/2024	2648.4	2638.554
9/1/2023	3328.6	3388.203	9/1/2024	2528.5	2776.719
10/1/2023	3206.8	2963.225	10/1/2024	3665.9	3336.334
11/1/2023	3488.7	3523.484	11/1/2024	2570.3	2175.966
12/1/2023	3372.4	3275.953	12/1/2024	3296.8	3475.126

Hasil prediksi pada skenario 11 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.34.

Tabel 4. 34 Nilai Keakuratan Skenario 11

<i>Hyperparameter</i>	MAPE
C= 10, epsilon = 0.001, gamma = 0.01	4.44%

Hyperparameter yang digunakan adalah C=10 ,epsilon=0.001, dan gamma=0.01. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 4.44%.



Gambar 4. 11 Visualisasi Skenario 11

Dari gambar 4.11 dapat dijelaskan bahwa tingkat prediksi cenderung sangat baik. Kombinasi ini menghasilkan model yang sangat halus dengan toleransi *error* rendah, ini salah satu hasil terbaik.

4.2.12 Hasil dari uji coba Skenario ke-12

Pada skenario 12 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.35

Tabel 4. 35 Parameter Skenario 12

Parameter	
Kernel	RBF
Nilai C	10
Nilai epsilon	0.001
Nilai gamma	0.1

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 12 dapat dilihat pada tabel 4.36

Tabel 4. 36 Hasil Skenario 12

Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2966.178	1/1/2024	2698.3	2824.2
2/1/2023	2406.5	2537.583	2/1/2024	2979.6	2799.785

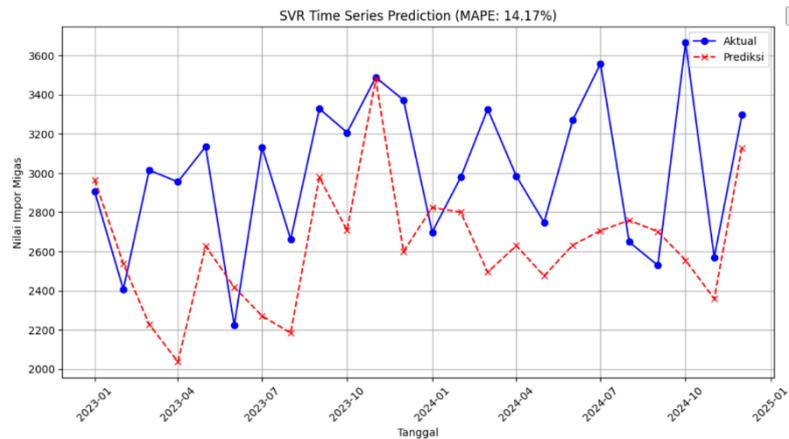
3/1/2023	3014.8	2228.414		3/1/2024	3326.5	2493.847
4/1/2023	2955	2036.858		4/1/2024	2984.3	2629.466
5/1/2023	3135.1	2627.004		5/1/2024	2748.2	2474.652
6/1/2023	2222.3	2417.242		6/1/2024	3270.5	2632.489
7/1/2023	3132.1	2271.024		7/1/2024	3557.7	2705.766
8/1/2023	2662	2183.615		8/1/2024	2648.4	2758.75
9/1/2023	3328.6	2978.8		9/1/2024	2528.5	2701.299
10/1/2023	3206.8	2706.925		10/1/2024	3665.9	2555.179
11/1/2023	3488.7	3478.507		11/1/2024	2570.3	2358.276
12/1/2023	3372.4	2599.339		12/1/2024	3296.8	3128.698

Hasil prediksi pada skenario 12 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.37.

Tabel 4. 37 Nilai Keakuratan Skenario 12

<i>Hyperparameter</i>	MAPE
C= 10, epsilon = 0.001, gamma = 0.1	14.47%

Hyperparameter yang digunakan adalah C=10 ,epsilon=0.001, dan gamma=0.1. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 14.47%.



Gambar 4. 12 Visualisasi Skenario 12

Dari gambar 4.12 dapat dijelaskan bahwa tingkat prediksi cenderung baik meskipun C dan epsilon baik, gamma sedang menyebabkan model lebih fleksibel namun cenderung *overfitting* jika tidak dikontrol.

4.2.13 Hasil dari uji coba Skenario ke-13

Pada skenario 13 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.38

Tabel 4. 38 Parameter Skenario 13

Parameter	
Kernel	RBF
Nilai C	10
Nilai epsilon	0.01
Nilai gamma	0.001

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 13 dapat dilihat pada tabel 4.39

Tabel 4. 39 Hasil Skenario 13

Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2675.794	1/1/2024	2698.3	2699.196
2/1/2023	2406.5	2481.016	2/1/2024	2979.6	2995.7

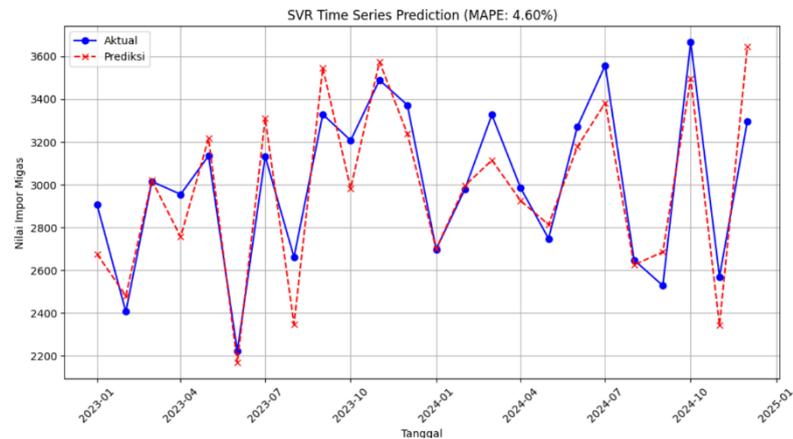
3/1/2023	3014.8	3019.841		3/1/2024	3326.5	3114.641
4/1/2023	2955	2756.274		4/1/2024	2984.3	2924.959
5/1/2023	3135.1	3216.941		5/1/2024	2748.2	2813.3
6/1/2023	2222.3	2168.825		6/1/2024	3270.5	3176.868
7/1/2023	3132.1	3310.549		7/1/2024	3557.7	3382.549
8/1/2023	2662	2349.219		8/1/2024	2648.4	2625.293
9/1/2023	3328.6	3545.734		9/1/2024	2528.5	2685.781
10/1/2023	3206.8	2981.863		10/1/2024	3665.9	3496.158
11/1/2023	3488.7	3574.391		11/1/2024	2570.3	2343.825
12/1/2023	3372.4	3238.327		12/1/2024	3296.8	3644.613

Hasil prediksi pada skenario 13 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.40.

Tabel 4. 40 Nilai Keakuratan Skenario 13

<i>Hyperparameter</i>	MAPE
C= 10, epsilon = 0.01, gamma = 0.001	4.60%

Hyperparameter yang digunakan adalah C=10 ,epsilon=0.01, dan gamma=0.001. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 4.60%.



Gambar 4.13 Visualisasi Skenario 13

Dari gambar 4.13 dapat dijelaskan bahwa tingkat prediksi cenderung sangat baik. Kombinasi ini relatif stabil dan cukup presisi, gamma kecil memberikan model yang tidak *overfitting*.

4.2.14 Hasil dari uji coba Skenario ke-14

Pada skenario 14 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.41

Tabel 4.41 Parameter Skenario 14

Parameter	
Kernel	RBF
Nilai C	10
Nilai epsilon	0.01
Nilai gamma	0.01

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 14 dapat dilihat pada tabel 4.42

Tabel 4.42 Hasil Skenario 14

Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2790.034	1/1/2024	2698.3	2797.648
2/1/2023	2406.5	2548.905	2/1/2024	2979.6	3086.055

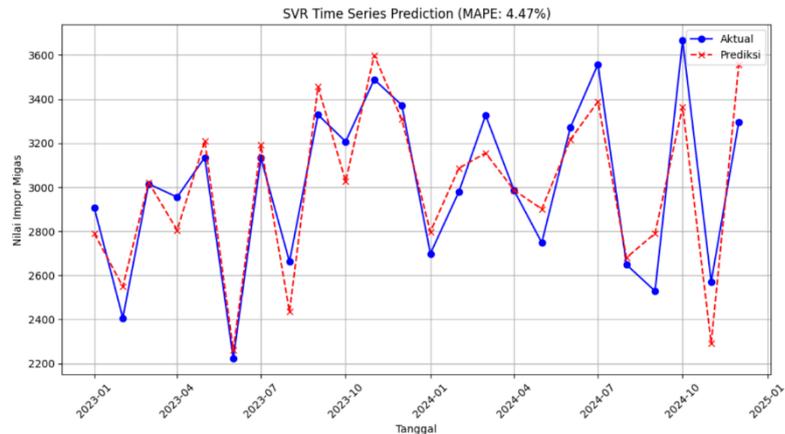
3/1/2023	3014.8	3021.785		3/1/2024	3326.5	3155.236
4/1/2023	2955	2804.844		4/1/2024	2984.3	2985.941
5/1/2023	3135.1	3209.905		5/1/2024	2748.2	2901.138
6/1/2023	2222.3	2261.765		6/1/2024	3270.5	3215.744
7/1/2023	3132.1	3190.524		7/1/2024	3557.7	3388.375
8/1/2023	2662	2435.421		8/1/2024	2648.4	2680.172
9/1/2023	3328.6	3455.941		9/1/2024	2528.5	2790.404
10/1/2023	3206.8	3026.438		10/1/2024	3665.9	3365.128
11/1/2023	3488.7	3599.411		11/1/2024	2570.3	2292.387
12/1/2023	3372.4	3307.318		12/1/2024	3296.8	3555.718

Hasil prediksi pada skenario 14 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.43.

Tabel 4. 43 Nilai Keakuratan Skenario 14

<i>Hyperparameter</i>	MAPE
C= 10, epsilon = 0.01, gamma = 0.01	4.47%

Hyperparameter yang digunakan adalah C=10 ,epsilon=0.01, dan gamma=0.01. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 4.47%.



Gambar 4. 14 Visualisasi Skenario 14

Dari gambar 4.14 dapat dijelaskan bahwa tingkat prediksi cenderung sangat baik. salah satu kombinasi paling seimbang, parameter tidak ekstrem, dan hasil sangat baik.

4.2.15 Hasil dari uji coba Skenario ke-15

Pada skenario 15 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.44

Tabel 4. 44 Parameter Skenario 15

Parameter	
<i>Kernel</i>	RBF
Nilai C	10
Nilai epsilon	0.01
Nilai gamma	0.1

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 15 dapat dilihat pada tabel 4.45

Tabel 4. 45 Hasil Skenario 15

Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2969.191	1/1/2024	2698.3	2867.583
2/1/2023	2406.5	2521.024	2/1/2024	2979.6	2835.945

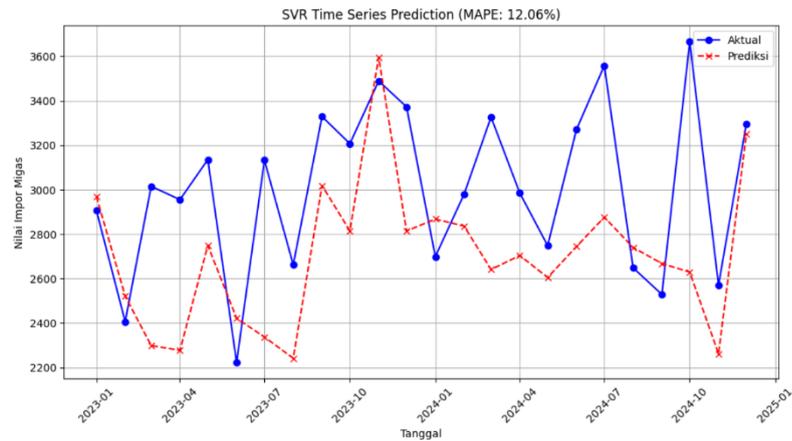
3/1/2023	3014.8	2298.523		3/1/2024	3326.5	2640.744
4/1/2023	2955	2277.321		4/1/2024	2984.3	2703.709
5/1/2023	3135.1	2748.751		5/1/2024	2748.2	2604.86
6/1/2023	2222.3	2421.386		6/1/2024	3270.5	2743.902
7/1/2023	3132.1	2336.936		7/1/2024	3557.7	2875.976
8/1/2023	2662	2241.563		8/1/2024	2648.4	2739.925
9/1/2023	3328.6	3018.086		9/1/2024	2528.5	2667.698
10/1/2023	3206.8	2814.522		10/1/2024	3665.9	2628.991
11/1/2023	3488.7	3595.155		11/1/2024	2570.3	2261.59
12/1/2023	3372.4	2814.063		12/1/2024	3296.8	3249.361

Hasil prediksi pada skenario 15 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.46.

Tabel 4. 46 Nilai Keakuratan Skenario 15

<i>Hyperparameter</i>	MAPE
C= 10, epsilon = 0.01, gamma = 0.1	12.06%

Hyperparameter yang digunakan adalah C=10 ,epsilon=0.01, dan gamma=0.1. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 12.06%.



Gambar 4. 15 Visualisasi Skenario 15

Dari gambar 4.15 dapat dijelaskan bahwa tingkat prediksi cenderung baik namun gamma tinggi menyebabkan kompleksitas model meningkat dan rentan *overfitting*.

4.2.16 Hasil dari uji coba Skenario ke-16

Pada skenario 16 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.47

Tabel 4. 47 Parameter Skenario 16

Parameter	
Kernel	RBF
Nilai C	10
Nilai epsilon	0.1
Nilai gamma	0.001

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 16 dapat dilihat pada tabel 4.48

Tabel 4. 48 Hasil Skenario 16

Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2586.374	1/1/2024	2698.3	2542.97

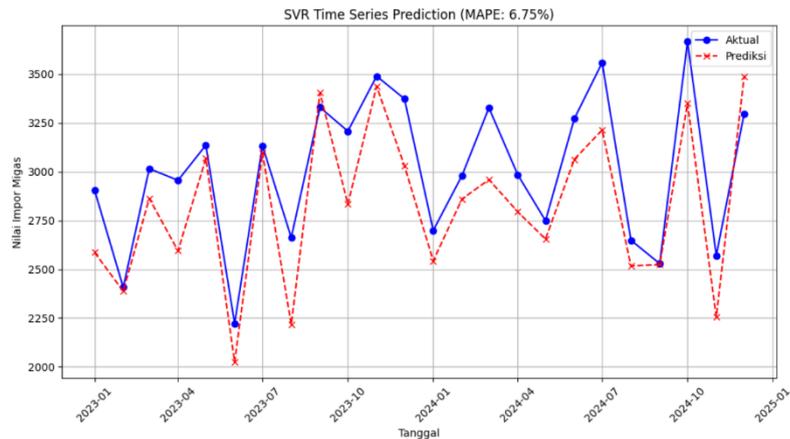
2/1/2023	2406.5	2387.016	2/1/2024	2979.6	2859.547
3/1/2023	3014.8	2862.517	3/1/2024	3326.5	2958.641
4/1/2023	2955	2594.018	4/1/2024	2984.3	2794.303
5/1/2023	3135.1	3066.811	5/1/2024	2748.2	2654.382
6/1/2023	2222.3	2024.558	6/1/2024	3270.5	3062.627
7/1/2023	3132.1	3095.394	7/1/2024	3557.7	3213.127
8/1/2023	2662	2217.816	8/1/2024	2648.4	2516.643
9/1/2023	3328.6	3403.05	9/1/2024	2528.5	2523.64
10/1/2023	3206.8	2832.438	10/1/2024	3665.9	3349.753
11/1/2023	3488.7	3436.621	11/1/2024	2570.3	2255.957
12/1/2023	3372.4	3028.938	12/1/2024	3296.8	3487.274

Hasil prediksi pada skenario 16 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.49.

Tabel 4. 49 Nilai Keakuratan Skenario 16

<i>Hyperparameter</i>	MAPE
C= 10, epsilon = 0.1, gamma = 0.001	6.75%

Hyperparameter yang digunakan adalah C=10 ,epsilon=0.1, dan gamma=0.001. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 6.75%.



Gambar 4. 16 Visualisasi Skenario 16

Dari gambar 4.16 dapat dijelaskan bahwa tingkat prediksi cenderung sangat baik namun epsilon besar membuat model tidak cukup presisi. Gamma kecil tidak bisa mengimbangnya.

4.2.17 Hasil dari uji coba Skenario ke-17

Pada skenario 17 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.50

Tabel 4. 50 Parameter Skenario 17

Parameter	
Kernel	RBF
Nilai C	10
Nilai epsilon	0.1
Nilai gamma	0.01

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 17 dapat dilihat pada tabel 4.51

Tabel 4. 51 Hasil Skenario 17

Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2595.89	1/1/2024	2698.3	2558.044

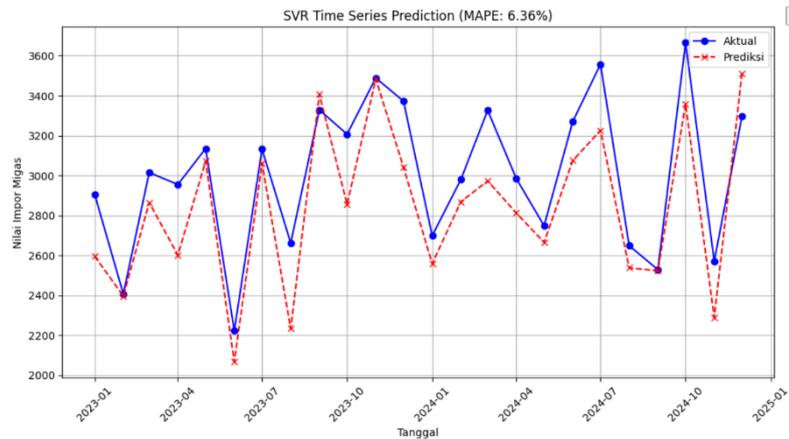
2/1/2023	2406.5	2396.02		2/1/2024	2979.6	2868.625
3/1/2023	3014.8	2864.616		3/1/2024	3326.5	2972.827
4/1/2023	2955	2601.107		4/1/2024	2984.3	2811.791
5/1/2023	3135.1	3072.409		5/1/2024	2748.2	2665.085
6/1/2023	2222.3	2066.598		6/1/2024	3270.5	3074.717
7/1/2023	3132.1	3061.59		7/1/2024	3557.7	3226.121
8/1/2023	2662	2232.907		8/1/2024	2648.4	2537.631
9/1/2023	3328.6	3406.673		9/1/2024	2528.5	2522.671
10/1/2023	3206.8	2855.293		10/1/2024	3665.9	3357.876
11/1/2023	3488.7	3483.85		11/1/2024	2570.3	2288.552
12/1/2023	3372.4	3041.58		12/1/2024	3296.8	3511.655

Hasil prediksi pada skenario 17 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.52.

Tabel 4. 52 Nilai Keakuratan Skenario 17

Hyperparameter	MAPE
C= 10, epsilon = 0.1, gamma = 0.01	6.36%

Hyperparameter yang digunakan adalah C=10 ,epsilon=0.1, dan gamma=0.01. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 6.36%.



Gambar 4. 17 Visualisasi Skenario 17

Dari gambar 4.17 dapat dijelaskan bahwa tingkat prediksi cenderung sangat baik. Gamma sedang mengimbangi epsilon besar, sehingga performa lebih baik dari skenario 16.

4.2.18 Hasil dari uji coba Skenario ke-18

Pada skenario 18 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.53

Tabel 4. 53 Parameter Skenario 18

Parameter	
Kernel	RBF
Nilai C	10
Nilai epsilon	0.1
Nilai gamma	0.1

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 18 dapat dilihat pada tabel 4.54

Tabel 4. 54 Hasil Skenario 18

Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2687.713	1/1/2024	2698.3	2673.052

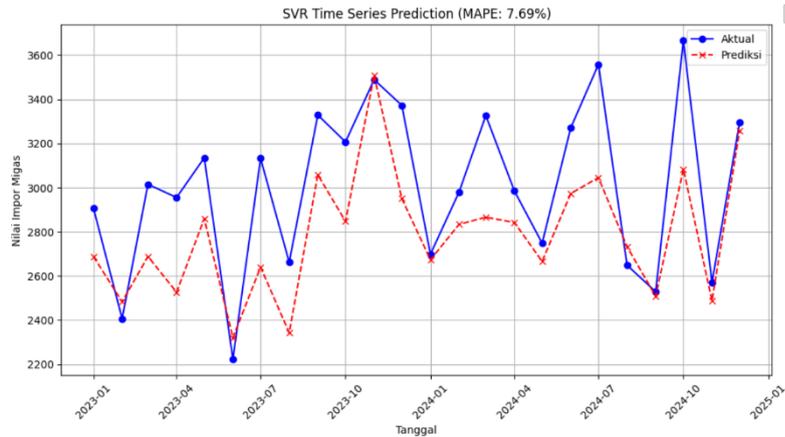
2/1/2023	2406.5	2482.869		2/1/2024	2979.6	2833.514
3/1/2023	3014.8	2688.182		3/1/2024	3326.5	2865.84
4/1/2023	2955	2526.167		4/1/2024	2984.3	2841.939
5/1/2023	3135.1	2859.56		5/1/2024	2748.2	2665.555
6/1/2023	2222.3	2319.861		6/1/2024	3270.5	2973.094
7/1/2023	3132.1	2639.856		7/1/2024	3557.7	3045.169
8/1/2023	2662	2342.693		8/1/2024	2648.4	2732.172
9/1/2023	3328.6	3057.99		9/1/2024	2528.5	2507.987
10/1/2023	3206.8	2847.026		10/1/2024	3665.9	3083.495
11/1/2023	3488.7	3508.041		11/1/2024	2570.3	2488.146
12/1/2023	3372.4	2950.417		12/1/2024	3296.8	3258.81

Hasil prediksi pada skenario 18 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.55.

Tabel 4. 55 Nilai keakuratan skenario 18

<i>Hyperparameter</i>	MAPE
C= 10, epsilon = 0.1, gamma = 0.1	7.69%

Hyperparameter yang digunakan adalah C=10 ,epsilon=0.1, dan gamma=0.1. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 7.69%.



Gambar 4. 18 Visualisasi Skenario 18

Dari gambar 4.18 dapat dijelaskan bahwa tingkat prediksi cenderung sangat baik namun kombinasi epsilon besar dan gamma tinggi memberikan toleransi besar dan model yang terlalu fleksibel.

4.2.19 Hasil dari uji coba Skenario ke-19

Pada skenario 19 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.56

Tabel 4. 56 Parameter Skenario 19

Parameter	
<i>Kernel</i>	RBF
Nilai C	100
Nilai epsilon	0.001
Nilai gamma	0.001

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 19 dapat dilihat pada tabel 4.57

Tabel 4. 57 Hasil Skenario 19

Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2727.118	1/1/2024	2698.3	2770.978
2/1/2023	2406.5	2514.899	2/1/2024	2979.6	3029.713

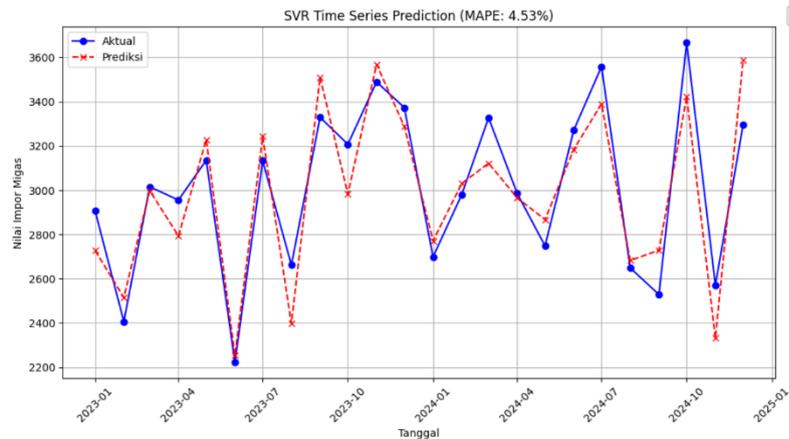
3/1/2023	3014.8	2997.543		3/1/2024	3326.5	3121.482
4/1/2023	2955	2792.84		4/1/2024	2984.3	2964.629
5/1/2023	3135.1	3227.245		5/1/2024	2748.2	2867.058
6/1/2023	2222.3	2254.249		6/1/2024	3270.5	3183.353
7/1/2023	3132.1	3242.151		7/1/2024	3557.7	3389.602
8/1/2023	2662	2397.752		8/1/2024	2648.4	2681.979
9/1/2023	3328.6	3509.627		9/1/2024	2528.5	2728.655
10/1/2023	3206.8	2981.449		10/1/2024	3665.9	3422.011
11/1/2023	3488.7	3568.122		11/1/2024	2570.3	2331.535
12/1/2023	3372.4	3287.216		12/1/2024	3296.8	3588.793

Hasil prediksi pada skenario 19 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.58.

Tabel 4. 58 Nilai Keakuratan Skenario 19

<i>Hyperparameter</i>	MAPE
C= 100, epsilon = 0.001, gamma = 0.001	4.53%

Hyperparameter yang digunakan adalah C=100 ,epsilon=0.001, dan gamma=0.001. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 4.53%.



Gambar 4. 19 Visualisasi Skenario 19

Dari gambar 4.19 dapat dijelaskan bahwa tingkat prediksi cenderung sangat baik. C besar memberikan keakuratan untuk fit data, tapi gamma dan epsilon kecil menjaga agar tidak *overfitting*.

4.2.20 Hasil dari uji coba Skenario ke-20

Pada skenario 20 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.59

Tabel 4. 59 Parameter Skenario 20

Parameter	
Kernel	RBF
Nilai C	100
Nilai epsilon	0.001
Nilai gamma	0.01

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 20 dapat dilihat pada tabel 4.60

Tabel 4. 60 Hasil Skenario 20

Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2753.697	1/1/2024	2698.3	2726.071
2/1/2023	2406.5	2462.218	2/1/2024	2979.6	3040.43

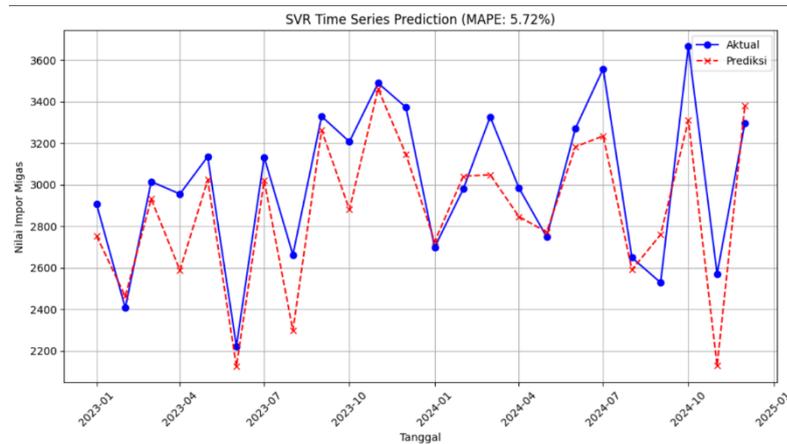
3/1/2023	3014.8	2931.025		3/1/2024	3326.5	3047.676
4/1/2023	2955	2587.956		4/1/2024	2984.3	2846.188
5/1/2023	3135.1	3023.021		5/1/2024	2748.2	2771.547
6/1/2023	2222.3	2124.917		6/1/2024	3270.5	3182.229
7/1/2023	3132.1	3019.333		7/1/2024	3557.7	3234.626
8/1/2023	2662	2298.229		8/1/2024	2648.4	2590.303
9/1/2023	3328.6	3262.041		9/1/2024	2528.5	2759.451
10/1/2023	3206.8	2880.007		10/1/2024	3665.9	3309.528
11/1/2023	3488.7	3461.12		11/1/2024	2570.3	2128.4
12/1/2023	3372.4	3145.773		12/1/2024	3296.8	3381.596

Hasil prediksi pada skenario 20 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.61.

Tabel 4. 61 Nilai keakuratan skenario 20

<i>Hyperparameter</i>	MAPE
C= 100, epsilon = 0.001, gamma = 0.01	5.72%

Hyperparameter yang digunakan adalah C=100 ,epsilon=0.001, dan gamma=0.01. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 5.72%.



Gambar 4. 20 Visualisasi Skenario 20

Dari gambar 4.20 dapat dijelaskan bahwa tingkat prediksi cenderung sangat baik. Gamma sedikit lebih besar menambah fleksibilitas sehingga performa menurun sedikit dibanding skenario 19.

4.2.21 Hasil dari uji coba Skenario ke-21

Pada skenario 21 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.62

Tabel 4. 62 Parameter Skenario 21

Parameter	
Kernel	RBF
Nilai C	100
Nilai epsilon	0.001
Nilai gamma	0.1

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 21 dapat dilihat pada tabel 4.63

Tabel 4. 63 Hasil Skenario 21

Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2977.462	1/1/2024	2698.3	2972.817
2/1/2023	2406.5	2405.608	2/1/2024	2979.6	2343.923

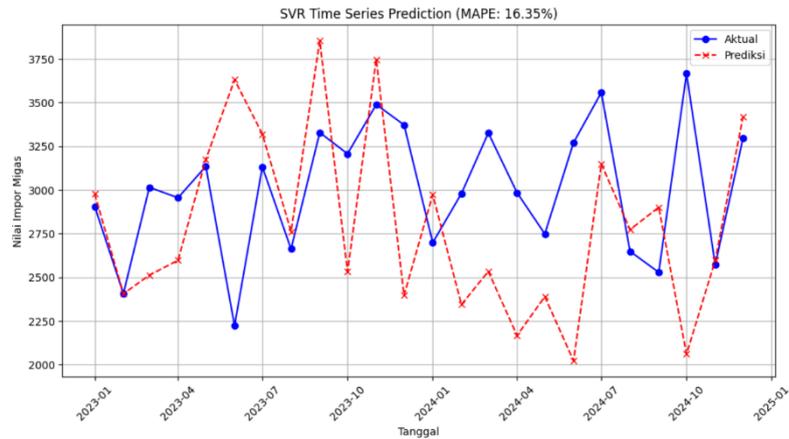
3/1/2023	3014.8	2511.986	3/1/2024	3326.5	2533.725
4/1/2023	2955	2597.401	4/1/2024	2984.3	2166.677
5/1/2023	3135.1	3175.157	5/1/2024	2748.2	2389.273
6/1/2023	2222.3	3630.625	6/1/2024	3270.5	2022.117
7/1/2023	3132.1	3320.396	7/1/2024	3557.7	3148.929
8/1/2023	2662	2761.958	8/1/2024	2648.4	2773.037
9/1/2023	3328.6	3854.207	9/1/2024	2528.5	2900.471
10/1/2023	3206.8	2531.927	10/1/2024	3665.9	2060.212
11/1/2023	3488.7	3747.946	11/1/2024	2570.3	2597.064
12/1/2023	3372.4	2396.385	12/1/2024	3296.8	3419.399

Hasil prediksi pada skenario 21 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.64.

Tabel 4. 64 Nilai Keakuratan Skenario 21

<i>Hyperparameter</i>	MAPE
C= 100, epsilon = 0.001, gamma = 0.1	16.35%

Hyperparameter yang digunakan adalah C=100 ,epsilon=0.001, dan gamma=0.1. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 16.35%.



Gambar 4. 21 Visualisasi Skenario 21

Dari gambar 4.21 dapat dijelaskan bahwa tingkat prediksi cenderung baik namun C sangat tinggi dan gamma tinggi menyebabkan *overfitting*. Ini adalah skenario terburuk.

4.2.22 Hasil dari uji coba Skenario ke-22

Pada skenario 22 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.65

Tabel 4. 65 Parameter Skenario 22

Parameter	
Kernel	RBF
Nilai C	100
Nilai epsilon	0.01
Nilai gamma	0.001

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 22 dapat dilihat pada tabel 4.66

Tabel 4. 66 Hasil Skenario 22

Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2754.864	1/1/2024	2698.3	2762.592
2/1/2023	2406.5	2519.333	2/1/2024	2979.6	3075.819

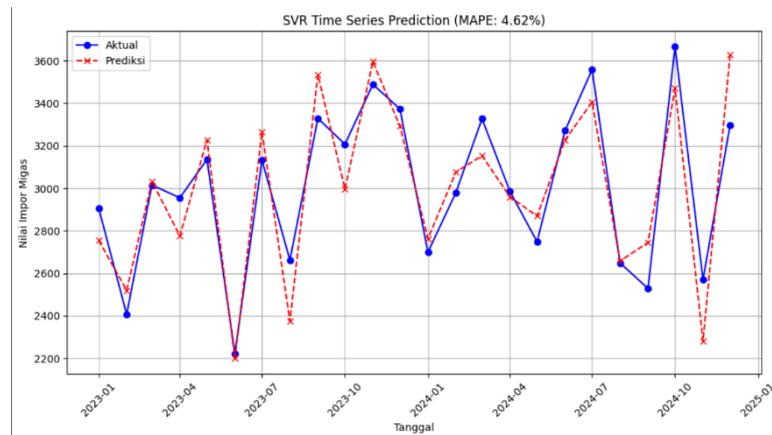
3/1/2023	3014.8	3031.867		3/1/2024	3326.5	3153.026
4/1/2023	2955	2775.808		4/1/2024	2984.3	2958.997
5/1/2023	3135.1	3227.601		5/1/2024	2748.2	2869.126
6/1/2023	2222.3	2199.737		6/1/2024	3270.5	3227.074
7/1/2023	3132.1	3265.975		7/1/2024	3557.7	3405.21
8/1/2023	2662	2374.736		8/1/2024	2648.4	2657.835
9/1/2023	3328.6	3533.69		9/1/2024	2528.5	2744.368
10/1/2023	3206.8	2995.749		10/1/2024	3665.9	3469.694
11/1/2023	3488.7	3594.957		11/1/2024	2570.3	2280.951
12/1/2023	3372.4	3291.957		12/1/2024	3296.8	3627.22

Hasil prediksi pada skenario 22 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.67.

Tabel 4. 67 Nilai Keakuratan Skenario 22

Hyperparameter	MAPE
C= 100, epsilon = 0.01, gamma = 0.001	4.62%

Hyperparameter yang digunakan adalah C=100 ,epsilon=0.01, dan gamma=0.001. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 4.62%.



Gambar 4. 22 Visualisasi Skenario 22

Dari gambar 4.22 dapat dijelaskan bahwa tingkat prediksi cenderung sangat baik. Kombinasi ini cukup stabil, gamma rendah menjaga model tetap baik.

4.2.23 Hasil dari uji coba Skenario ke-23

Pada skenario 23 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.68

Tabel 4. 68 Parameter Skenario 23

Parameter	
Kernel	RBF
Nilai C	100
Nilai epsilon	0.01
Nilai gamma	0.01

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 23 dapat dilihat pada tabel 4.69

Tabel 4. 69 Hasil Skenario 23

Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2746.125	1/1/2024	2698.3	2750.958
2/1/2023	2406.5	2480.252	2/1/2024	2979.6	3020.261
3/1/2023	3014.8	2921.186	3/1/2024	3326.5	3042.457
4/1/2023	2955	2647.407	4/1/2024	2984.3	2879.921

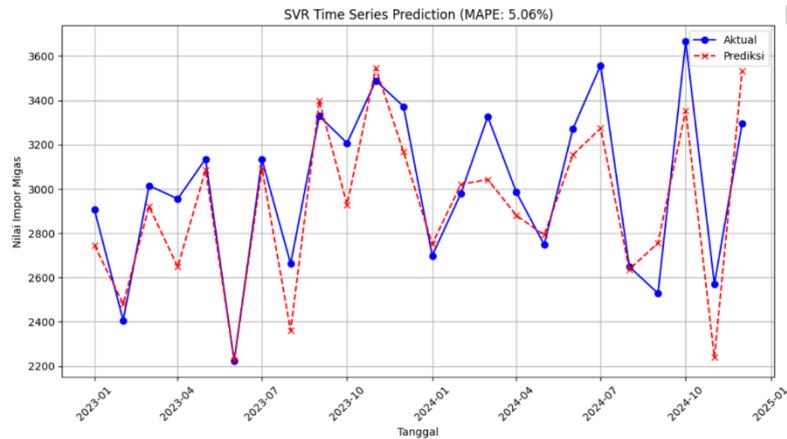
5/1/2023	3135.1	3085.702		5/1/2024	2748.2	2791.831
6/1/2023	2222.3	2226.688		6/1/2024	3270.5	3153.831
7/1/2023	3132.1	3092.652		7/1/2024	3557.7	3273.65
8/1/2023	2662	2359.917		8/1/2024	2648.4	2636.333
9/1/2023	3328.6	3398.176		9/1/2024	2528.5	2756.183
10/1/2023	3206.8	2928.444		10/1/2024	3665.9	3354.746
11/1/2023	3488.7	3545.839		11/1/2024	2570.3	2238.482
12/1/2023	3372.4	3166.75		12/1/2024	3296.8	3533.908

Hasil prediksi pada skenario 23 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.70.

Tabel 4. 70 Nilai Keakuratan Skenario 23

<i>Hyperparameter</i>	MAPE
C= 100, epsilon = 0.01, gamma = 0.01	5.06%

Hyperparameter yang digunakan adalah C=100 ,epsilon=0.01, dan gamma=0.01. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 5.06%.



Gambar 4. 23 Visualisasi Skenario 23

Dari gambar 4.23 dapat dijelaskan bahwa tingkat prediksi cenderung sangat baik namun terjadi penurunan akurasi dengan gamma sedang.

4.2.24 Hasil dari uji coba Skenario ke-24

Pada skenario 24 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.71

Tabel 4. 71 Parameter Skenario 24

Parameter	
Kernel	RBF
Nilai C	100
Nilai epsilon	0.01
Nilai gamma	0.1

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 24 dapat dilihat pada tabel 4.72

Tabel 4. 72 Hasil Skenario 24

Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	3031.181	1/1/2024	2698.3	3054.468
2/1/2023	2406.5	2458.878	2/1/2024	2979.6	2677.235
3/1/2023	3014.8	2495.817	3/1/2024	3326.5	2695.254

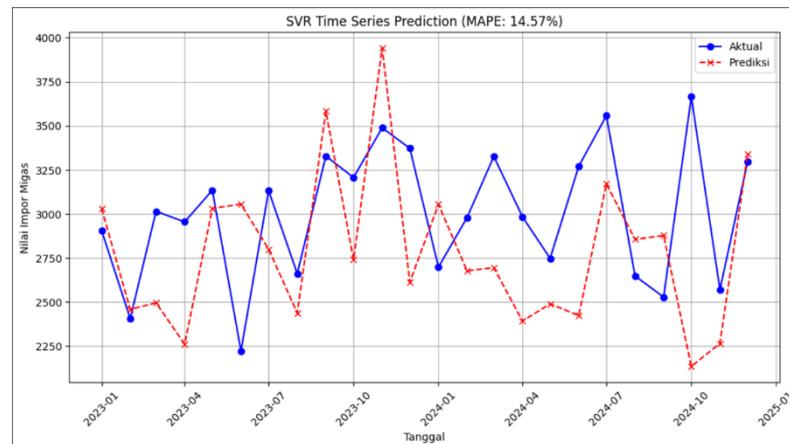
4/1/2023	2955	2261.42		4/1/2024	2984.3	2392.49
5/1/2023	3135.1	3031.801		5/1/2024	2748.2	2489.874
6/1/2023	2222.3	3055.792		6/1/2024	3270.5	2423.663
7/1/2023	3132.1	2799.799		7/1/2024	3557.7	3170.352
8/1/2023	2662	2438.214		8/1/2024	2648.4	2856.076
9/1/2023	3328.6	3583.255		9/1/2024	2528.5	2877.69
10/1/2023	3206.8	2740.294		10/1/2024	3665.9	2135.002
11/1/2023	3488.7	3941.065		11/1/2024	2570.3	2265.684
12/1/2023	3372.4	2613.224		12/1/2024	3296.8	3339.816

Hasil prediksi pada skenario 23 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.73.

Tabel 4. 73 Nilai Keakuratan Skenario 24

<i>Hyperparameter</i>	MAPE
C= 100, epsilon = 0.01, gamma = 0.1	14.57%

Hyperparameter yang digunakan adalah C=100 ,epsilon=0.01, dan gamma=0.1. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 14.57%.



Gambar 4. 24 Visualisasi Skenario 24

Dari gambar 4.24 dapat dijelaskan bahwa tingkat prediksi cenderung baik namun gamma tinggi mengacaukan kestabilan model dan menyebabkan *overfitting*. Akurasi menurun tajam.

4.2.25 Hasil dari uji coba Skenario ke-25

Pada skenario 25 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.74

Tabel 4. 74 Parameter Skenario 25

Parameter	
<i>Kernel</i>	RBF
Nilai C	100
Nilai epsilon	0.1
Nilai gamma	0.001

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 25 dapat dilihat pada tabel 4.75

Tabel 4. 75 Hasil Skenario 25

Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2584.359	1/1/2024	2698.3	2536.292
2/1/2023	2406.5	2381.184	2/1/2024	2979.6	2870.791

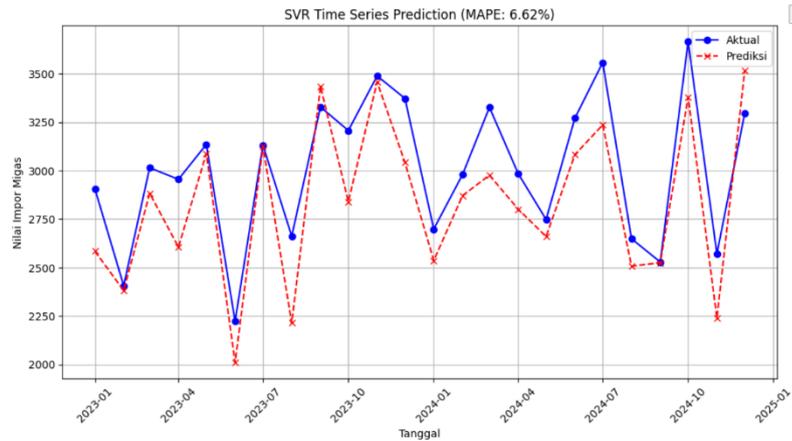
3/1/2023	3014.8	2883.017		3/1/2024	3326.5	2976.463
4/1/2023	2955	2605.423		4/1/2024	2984.3	2800.884
5/1/2023	3135.1	3088.293		5/1/2024	2748.2	2659.738
6/1/2023	2222.3	2009.727		6/1/2024	3270.5	3082.091
7/1/2023	3132.1	3125.961		7/1/2024	3557.7	3236.191
8/1/2023	2662	2213.872		8/1/2024	2648.4	2507.18
9/1/2023	3328.6	3434.818		9/1/2024	2528.5	2524.479
10/1/2023	3206.8	2840.303		10/1/2024	3665.9	3380.04
11/1/2023	3488.7	3457.81		11/1/2024	2570.3	2239.591
12/1/2023	3372.4	3041.579		12/1/2024	3296.8	3516.149

Hasil prediksi pada skenario 25 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.76.

Tabel 4. 76 Nilai Keakuratan Skenario 25

<i>Hyperparameter</i>	MAPE
C= 100, epsilon = 0.1, gamma = 0.001	6.62%

Hyperparameter yang digunakan adalah C=100 ,epsilon=0.1, dan gamma=0.001. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 6.62%.



Gambar 4. 25 Visualisasi Skenario 25

Dari gambar 4.25 dapat dijelaskan bahwa tingkat prediksi cenderung sangat baik Gamma kecil membantu, namun epsilon besar membuat model kurang presisi.

4.2.26 Hasil dari uji coba Skenario ke-26

Pada skenario 26 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.77

Tabel 4. 77 Parameter Skenario 26

Parameter	
Kernel	RBF
Nilai C	100
Nilai epsilon	0.1
Nilai gamma	0.01

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 26 dapat dilihat pada tabel 4.78

Tabel 4. 78 Hasil Skenario 26

Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2595.89	1/1/2024	2698.3	2558.044
2/1/2023	2406.5	2396.02	2/1/2024	2979.6	2868.625
3/1/2023	3014.8	2864.616	3/1/2024	3326.5	2972.827

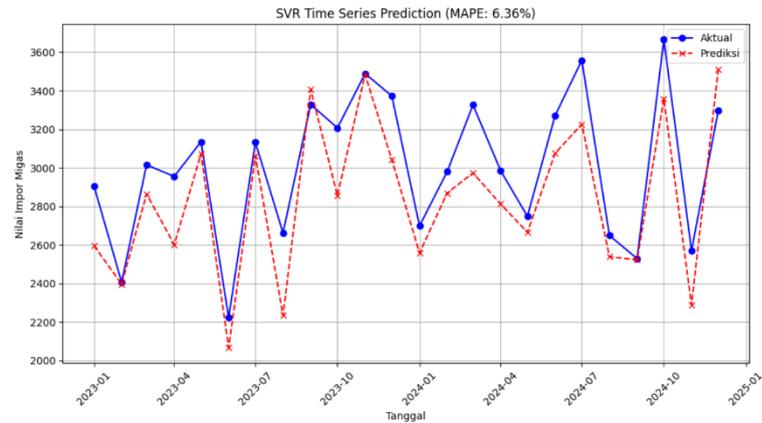
4/1/2023	2955	2601.107	4/1/2024	2984.3	2811.791
5/1/2023	3135.1	3072.409	5/1/2024	2748.2	2665.085
6/1/2023	2222.3	2066.598	6/1/2024	3270.5	3074.717
7/1/2023	3132.1	3061.59	7/1/2024	3557.7	3226.121
8/1/2023	2662	2232.907	8/1/2024	2648.4	2537.631
9/1/2023	3328.6	3406.673	9/1/2024	2528.5	2522.671
10/1/2023	3206.8	2855.293	10/1/2024	3665.9	3357.876
11/1/2023	3488.7	3483.85	11/1/2024	2570.3	2288.552
12/1/2023	3372.4	3041.58	12/1/2024	3296.8	3511.655

Hasil prediksi pada skenario 26 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.79.

Tabel 4. 79 Nilai Keakuratan Skenario 26

<i>Hyperparameter</i>	MAPE
C= 100, epsilon = 0.1, gamma = 0.01	5.06%

Hyperparameter yang digunakan adalah C=100 ,epsilon=0.1, dan gamma=0.01. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 5.06%.



Gambar 4. 26 Visualisasi Skenario 26

Dari gambar 4.26 dapat dijelaskan bahwa tingkat prediksi cenderung sangat baik namun gamma sedang memperbaiki performa, meski epsilon besar tetap membatasi presisi.

4.2.27 Hasil dari uji coba Skenario ke-27

Pada skenario 27 variabel yang ditetapkan sebagai *hyperparameter* model SVR adalah di tabel 4.80

Tabel 4. 80 Parameter Skenario 27

Parameter	
<i>Kernel</i>	RBF
Nilai C	100
Nilai epsilon	0.1
Nilai gamma	0.1

Dengan perbandingan data *training* dan data *testing* sebesar 80:20. Hasil dari skenario 27 dapat dilihat pada tabel 4.81

Tabel 4. 81 Hasil Skenario 27

Tanggal	Aktual	Prediksi	Tanggal	Aktual	Prediksi
1/1/2023	2906.1	2687.713	1/1/2024	2698.3	2673.052
2/1/2023	2406.5	2482.869	2/1/2024	2979.6	2833.514

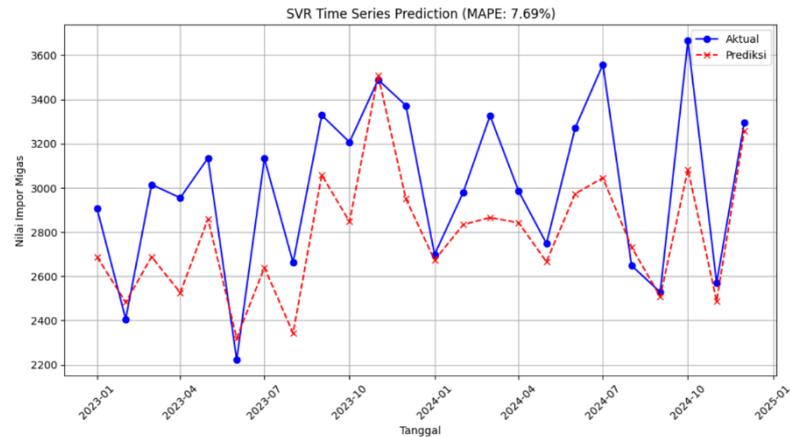
3/1/2023	3014.8	2688.182		3/1/2024	3326.5	2865.84
4/1/2023	2955	2526.167		4/1/2024	2984.3	2841.939
5/1/2023	3135.1	2859.56		5/1/2024	2748.2	2665.555
6/1/2023	2222.3	2319.861		6/1/2024	3270.5	2973.094
7/1/2023	3132.1	2639.856		7/1/2024	3557.7	3045.169
8/1/2023	2662	2342.693		8/1/2024	2648.4	2732.172
9/1/2023	3328.6	3057.99		9/1/2024	2528.5	2507.987
10/1/2023	3206.8	2847.026		10/1/2024	3665.9	3083.495
11/1/2023	3488.7	3508.041		11/1/2024	2570.3	2488.146
12/1/2023	3372.4	2950.417		12/1/2024	3296.8	3258.81

Hasil prediksi pada skenario 27 Ada sejumlah nilai positif dan negatif yang dihasilkan dari perbedaan nilai aktual dan prediksi. Langkah selanjutnya adalah mengukur akurasi prediksi metode SVR. Untuk melakukan ini, penulis menggunakan MAPE dalam bentuk persentase, dengan bagian uji coba mana yang mendapatkan nilai MAPE paling kecil. Percobaan strategi ini menghasilkan nilai keakuratan model prediksi SVR pada tabel 4.82.

Tabel 4. 82 Nilai keakuratan skenario 27

<i>Hyperparameter</i>	MAPE
C= 100, epsilon = 0.1, gamma = 0.1	7.69%

Hyperparameter yang digunakan adalah C=100 ,epsilon=0.1, dan gamma=0.1. Dengan penggunaan kombinasi ini, model SVR menghasilkan *Mean Absolute Percentage Error* (MAPE) sebesar 7.69%.



Gambar 4. 27 Visualisasi Skenario 27

Dari gambar 4.27 dapat dijelaskan bahwa tingkat prediksi cenderung sangat baik namun kombinasi dari ketiganya menghasilkan model yang terlalu kompleks.

4.3 Pembahasan

Peneliti telah melakukan 27 skenario uji coba dengan rasio pembagian data latih dan data uji sebesar 80:20 untuk menentukan skenario yang paling optimal dalam melatih model *Support Vector Regression* (SVR) untuk memprediksi nilai impor migas di Indonesia. Pada masing-masing skenario, dilakukan eksperimen dengan berbagai variasi nilai *hyperparameter* C , γ dan ϵ SVR dengan *kernel* RBF untuk mencari konfigurasi parameter yang menghasilkan performa prediksi terbaik pada data uji.

Tabel 4. 83 Hasil MAPE setiap Skenario 80:20

Skenario	<i>Hyperparameter</i>	MAPE
1	$C = 1$, $\epsilon = 0.001$, $\gamma = 0.001$	13.92%
2	$C = 1$, $\epsilon = 0.001$, $\gamma = 0.01$	4.38%
3	$C = 1$, $\epsilon = 0.001$, $\gamma = 0.1$	9.74%
4	$C = 1$, $\epsilon = 0.01$, $\gamma = 0.001$	13.78%
5	$C = 1$, $\epsilon = 0.01$, $\gamma = 0.01$	4.61%
6	$C = 1$, $\epsilon = 0.01$, $\gamma = 0.1$	9.19%

7	C =1 , epsilon =0.1 , gamma =0.001	15.63%
8	C =1 , epsilon =0.1 , gamma =0.01	6.84%
9	C =1 , epsilon =0.1 , gamma =0.1	7.69%
10	C =10 , epsilon = 0.001, gamma =0.001	4.49%
11	C =10 , epsilon = 0.001, gamma =0.01	4.44%
12	C =10 , epsilon = 0.001, gamma =0.1	14.47%
13	C =10 , epsilon = 0.01, gamma =0.001	4.60%
14	C =10 , epsilon = 0.01, gamma =0.01	4.47%
15	C =10 , epsilon = 0.01, gamma =0.1	12.06%
16	C =10 , epsilon = 0.1, gamma =0.001	6.75%
17	C =10 , epsilon = 0.1, gamma =0.01	6.36%
18	C =10 , epsilon = 0.1, gamma =0.1	7.69%
19	C =100 , epsilon =0.001 , gamma =0.001	4.53%
20	C =100 , epsilon =0.001 , gamma =0.01	5.72%
21	C =100 , epsilon =0.001 , gamma =0.1	16.35%
22	C =100 , epsilon =0.01 , gamma =0.001	4.62%
23	C =100 , epsilon =0.01 , gamma =0.01	5.06%
24	C =100 , epsilon =0.01 , gamma =0.1	14.57%
25	C =100 , epsilon =0.1 , gamma =0.001	6.62%
26	C =100 , epsilon =0.1 , gamma =0.01	5.06%
27	C =100 , epsilon =0.1 , gamma =0.1	7.69%

Berdasarkan tabel 4.83. secara keseluruhan dari 27 skenario uji coba yang telah dilakukan, dapat disimpulkan bahwa model SVR terbaik untuk melakukan prediksi nilai impor migas di Indonesia pada rasio data uji dan data latih 80:20 ini adalah menggunakan *kernel* RBF dan nilai *hyperparameter* C sebesar 1, epsilon sebesar 0.001, dan gamma sebesar 0.01 yaitu pada skenario 2. Konfigurasi parameter ini menunjukkan performa prediksi terbaik, dengan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 4.38% pada data uji. Hal ini menandakan bahwa skenario ini paling optimal dibandingkan skenario lainnya.

Selain itu, skenario pengujian juga dilakukan dengan rasio data latih dan data uji sebesar 90:10 untuk mengevaluasi pengaruh perbedaan proporsi data

terhadap hasil prediksi dan nilai *Mean Absolute Percentage Error* (MAPE). Pengujian ini bertujuan untuk membandingkan performa model ketika jumlah data pelatihan ditingkatkan. Seluruh tahapan dan konfigurasi pengujian pada skenario 90:10 dilakukan secara identik dengan skenario sebelumnya yang menggunakan rasio 80:20, baik dari segi kombinasi *hyperparameter* yang diuji maupun metode evaluasi yang digunakan.

Tabel 4. 84 Hasil MAPE setiap skenario 90:10

Skenario	<i>Hyperparameter</i>	MAPE
1	C =1 , epsilon =0.001 , gamma =0.001	7.77%
2	C =1 , epsilon =0.001 , gamma =0.01	4.77%
3	C =1 , epsilon =0.001 , gamma =0.1	7.31%
4	C =1 , epsilon =0.01 , gamma =0.001	7.32%
5	C =1 , epsilon =0.01 , gamma =0.01	4.77%
6	C =1 , epsilon =0.01 , gamma =0.1	7.15%
7	C =1 , epsilon =0.1 , gamma =0.001	10.58%
8	C =1 , epsilon =0.1 , gamma =0.01	6.22%
9	C =1 , epsilon =0.1 , gamma =0.1	5.42%
10	C =10 , epsilon = 0.001, gamma =0.001	4.36%
11	C =10 , epsilon = 0.001, gamma =0.01	5.90%
12	C =10 , epsilon = 0.001, gamma =0.1	8.77%
13	C =10 , epsilon = 0.01, gamma =0.001	4.38%
14	C =10 , epsilon = 0.01, gamma =0.01	5.79%
15	C =10 , epsilon = 0.01, gamma =0.1	7.02%
16	C =10 , epsilon = 0.1, gamma =0.001	5.83%
17	C =10 , epsilon = 0.1, gamma =0.01	5.68%
18	C =10 , epsilon = 0.1, gamma =0.1	5.42%
19	C =100 , epsilon =0.001 , gamma =0.001	5.04%
20	C =100 , epsilon =0.001 , gamma =0.01	6.40%
21	C =100 , epsilon =0.001 , gamma =0.1	15.34%
22	C =100 , epsilon =0.01 , gamma =0.001	5.17%
23	C =100 , epsilon =0.01 , gamma =0.01	6.49%
24	C =100 , epsilon =0.01 , gamma =0.1	11.68%
25	C =100 , epsilon =0.1 , gamma =0.001	5.70%
26	C =100 , epsilon =0.1 , gamma =0.01	5.68%
27	C =100 , epsilon =0.1 , gamma =0.1	5.42%

Berdasarkan tabel 4.84 secara keseluruhan dari 27 skenario uji coba yang telah dilakukan, dapat disimpulkan bahwa model SVR dengan rasio perbandingan data latih dan uji 90:10 yang terbaik untuk melakukan prediksi nilai impor migas di Indonesia ini adalah menggunakan *kernel* RBF dan nilai *hyperparameter* C sebesar 10, epsilon sebesar 0.001, dan gamma sebesar 0.001 yaitu pada skenario 10. Konfigurasi parameter ini secara konsisten menunjukkan performa prediksi tertinggi pada rasio perbandingan data latih dan data uji 90:10, dengan *Mean Absolute Percentage Error* (MAPE) 4.36% pada data yang diuji coba.

Jika dibandingkan, rata-rata MAPE dari 27 skenario pada rasio 80:20 adalah 8.20%, sedangkan pada rasio 90:10 adalah 6.72%. Secara umum, hasil ini menunjukkan bahwa peningkatan proporsi data latih dapat meningkatkan performa prediksi model. Namun, perlu diperhatikan bahwa ukuran data uji yang lebih kecil pada skenario 90:10 juga berisiko memberikan nilai MAPE yang tampak lebih rendah secara semu. Oleh karena itu, meskipun MAPE rata-rata 90:10 lebih kecil, tidak serta merta dapat disimpulkan bahwa skenario 90:10 lebih unggul secara absolut tanpa mempertimbangkan konteks ukuran dan distribusi data uji.

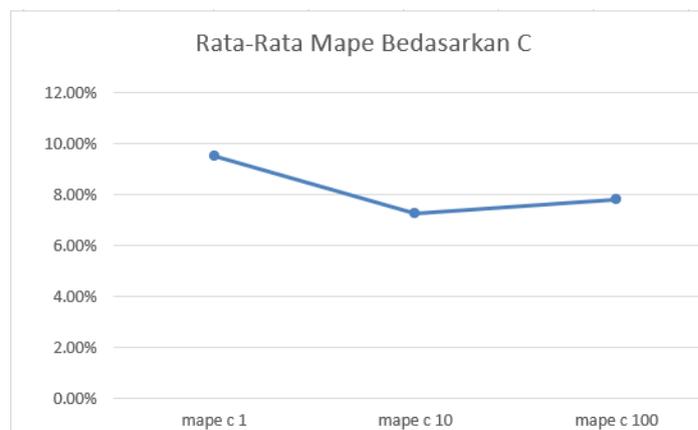
Parameter C dalam SVR (*Support Vector Regression*) merupakan parameter yang mengontrol *trade-off* antara margin dan kesalahan prediksi. Nilai C yang lebih tinggi mengizinkan margin yang lebih sempit tetapi mengurangi kesalahan prediksi, sementara nilai C yang lebih rendah mengizinkan margin yang lebih lebar tetapi meningkatkan kesalahan prediksi. Dengan demikian, nilai C yang optimal perlu ditentukan untuk mencapai keseimbangan yang tepat antara margin dan kesalahan prediksi dalam model SVR, perbandingan rata-rata MAPE setiap parameter C pada

skenario yang menggunakan rasio data latih dan data uji 80:20 dapat dilihat di tabel 4.85.

Tabel 4. 85 Rata-rata MAPE Berdasarkan Nilai C pada Rasio 80:20

No.	Hyperparameter	Rata-Rata MAPE
1	C =1	9.53%
2	C =10	7.26%
3	C =100	7.80%

Dari Tabel 4.85 dapat dilihat bahwa nilai *hyperparameter* C=10 membuat performa model SVR menjadi lebih baik, Ini menunjukkan bahwa nilai C yang terlalu kecil (*underfitting*) maupun terlalu besar (*overfitting*) dapat menurunkan performa model. Dalam penelitian ini, nilai sedang justru menjadi titik optimal yang menghasilkan prediksi terbaik.



Gambar 4. 28 Rata-rata MAPE Berdasarkan Nilai C pada Rasio 80:20

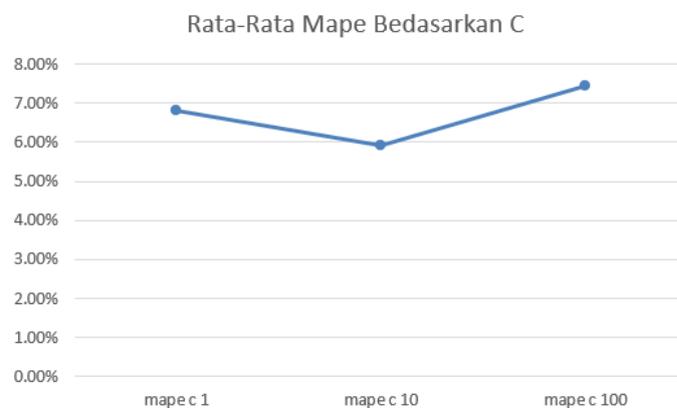
Analisis serupa dilakukan pada skenario dengan rasio 90:10, yang hasilnya ditunjukkan sebagai berikut

Tabel 4. 86 Rata-rata MAPE Berdasarkan Nilai C pada Rasio 90:10

No.	Hyperparameter	Rata-rata MAPE
1	C =1	6.81%
2	C =10	5.91%

3	C =100	7.44%
---	--------	-------

Pada rasio ini, nilai $C = 10$ kembali menunjukkan performa terbaik dengan rata-rata MAPE sebesar 5.91%. Konsistensi ini mengindikasikan bahwa pemilihan nilai $C = 10$ sebagai nilai tengah dari rentang eksplorasi cukup efektif dalam mencapai performa optimal.



Gambar 4. 29 Rata-rata MAPE Berdasarkan Nilai Epsilon pada Rasio 90:10

Berdasarkan hasil pada kedua skenario, dapat disimpulkan bahwa hipotesis awal yang menyatakan bahwa nilai C yang lebih besar akan selalu menghasilkan hasil yang lebih baik tidak sepenuhnya terbukti. Meskipun nilai C berfungsi untuk mengontrol *trade-off* antara kompleksitas model dan kesalahan prediksi, nilai C yang terlalu besar, seperti $C = 100$, justru menghasilkan performa yang lebih buruk dibandingkan $C = 10$. Hal ini disebabkan karena nilai C yang terlalu tinggi dapat membuat model menjadi terlalu kaku terhadap data latih, sehingga kehilangan kemampuan untuk melakukan prediksi yang baik terhadap data uji. Secara keseluruhan, nilai $C = 10$ menunjukkan performa paling stabil di kedua rasio data,

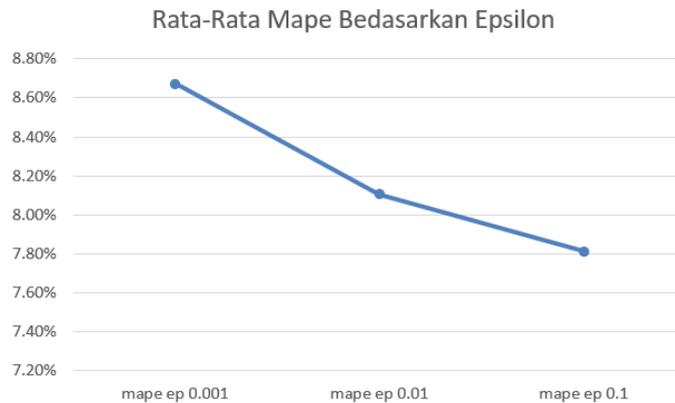
menjadikannya konfigurasi yang paling ideal dalam konteks data set ini. Nilai C yang terlalu kecil atau terlalu besar cenderung menurunkan akurasi prediksi.

Setelah dilakukan analisis terhadap nilai *hyperparameter* C , selanjutnya dianalisis pengaruh nilai epsilon (ϵ) terhadap performa model SVR. Epsilon merupakan parameter yang menentukan margin toleransi di sekitar fungsi prediksi, di mana kesalahan prediksi yang berada dalam rentang ini tidak dikenakan penalti. Nilai epsilon yang lebih besar membuat model lebih toleran terhadap kesalahan kecil, sehingga model cenderung lebih sederhana, namun berisiko mengalami *underfitting*. Sebaliknya, nilai epsilon yang lebih kecil meningkatkan sensitivitas model terhadap data, yang berpotensi memberikan hasil prediksi yang lebih akurat tetapi rentan terhadap *noise* atau *overfitting*. perbandingan rata-rata MAPE setiap parameter epsilon pada skenario yang menggunakan rasio data latih dan data uji 80:20 dapat dilihat di tabel 4.87.

Tabel 4. 87 Rata-rata MAPE Berdasarkan Nilai Epsilon pada Rasio 80:20

No.	<i>Hyperparameter</i>	MAPE
1	epsilon =0.001	8.67%
2	epsilon =0.01	8.11%
3	epsilon =0.1	7.81%

Dari Tabel 4.88 terlihat bahwa nilai epsilon sebesar 0.1 memberikan rata-rata MAPE terendah, yaitu 7.81%. Hal ini menunjukkan bahwa dengan memberikan toleransi yang lebih besar terhadap kesalahan kecil, model menjadi lebih fleksibel dalam menangkap pola data dan menghasilkan prediksi yang lebih baik.



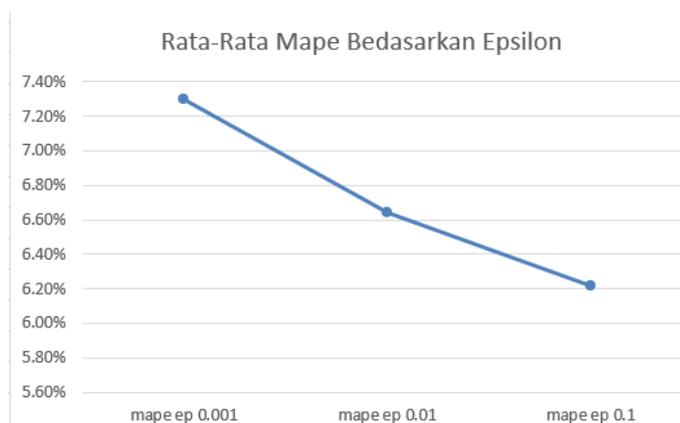
Gambar 4. 30 Rata-rata MAPE Berdasarkan Nilai Epsilon pada Rasio 80:20

Analisis serupa dilakukan untuk rasio pembagian data latih dan uji sebesar 90:10. Hasilnya ditampilkan pada Tabel 4.88:

Tabel 4. 88 Rata-rata MAPE Berdasarkan Nilai Epsilon pada Rasio 90:10

No.	<i>Hyperparameter</i>	MAPE
1	epsilon =0.001	7.30%
2	epsilon =0.01	6.64%
3	epsilon =0.1	6.22%

Seperti pada skenario sebelumnya, nilai epsilon 0.1 kembali menghasilkan nilai MAPE rata-rata paling rendah, yaitu 6.22%. Ini mengindikasikan bahwa pemberian ruang toleransi kesalahan yang sedikit lebih besar tetap memberikan hasil prediksi yang lebih baik, bahkan ketika data latih ditingkatkan.



Gambar 4. 31 Rata-rata MAPE Berdasarkan Nilai Epsilon pada Rasio 90:10

Berdasarkan kedua skenario pembagian data, dapat disimpulkan bahwa penggunaan nilai epsilon yang terlalu kecil dapat menurunkan performa model karena meningkatkan risiko *overfitting*. Meskipun nilai epsilon yang terlalu besar dapat menyebabkan *underfitting*, dalam ruang pencarian nilai epsilon yang diuji (hingga 0.1), tidak ditemukan penurunan performa. Dengan demikian, nilai epsilon sebesar 0.1 dapat dianggap sebagai nilai yang optimal untuk data pada penelitian ini karena mampu menurunkan nilai MAPE secara konsisten dalam kedua skenario pengujian.

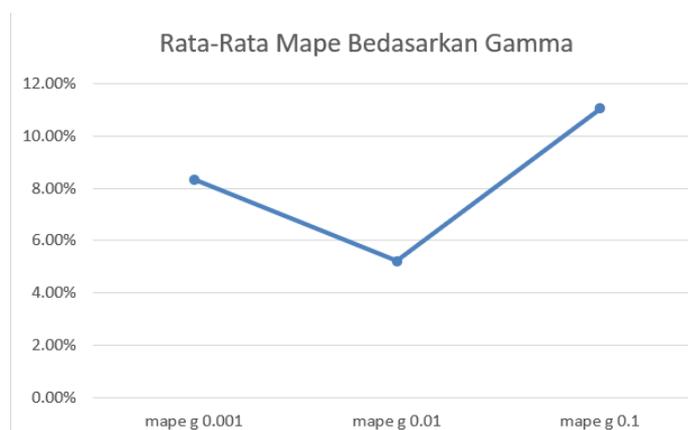
Setelah dilakukan analisis terhadap pengaruh nilai *hyperparameter* epsilon, selanjutnya dianalisis peran nilai gamma (γ) dalam model SVR. Gamma adalah parameter *kernel* RBF yang menentukan seberapa jauh pengaruh sebuah data latih menjangkau. Nilai gamma yang kecil membuat model menganggap data lebih “jauh” dari satu sama lain sehingga pengaruh tiap titik lebih luas, yang cenderung menghasilkan model yang lebih halus dan berisiko *underfitting*. Sebaliknya, gamma yang besar membuat pengaruh tiap titik terbatas pada area sempit di

sekitarnya, yang dapat membuat model terlalu kompleks dan sensitif terhadap *noise*, berisiko *overfitting*. Rata-rata nilai MAPE berdasarkan variasi gamma pada rasio data latih dan uji sebesar 80:20 disajikan pada Tabel 4.89.

Tabel 4. 89 Rata-rata MAPE Berdasarkan Nilai Gamma pada Rasio 80:20

No.	<i>Hyperparameter</i>	MAPE
1	gamma =0.001	8.33%
2	gamma =0.01	5.22%
3	gamma =0.1	11.05%

Dari Tabel 4.89 dapat dilihat bahwa nilai gamma sebesar 0.01 menghasilkan nilai MAPE paling rendah, yaitu 5.22%, yang menunjukkan performa prediksi terbaik dibandingkan nilai gamma lainnya. Hal ini mengindikasikan bahwa gamma 0.01 memberikan keseimbangan optimal antara sensitivitas model dan kemampuan generalisasi, sehingga dapat menangkap pola dalam data dengan baik tanpa berlebihan.



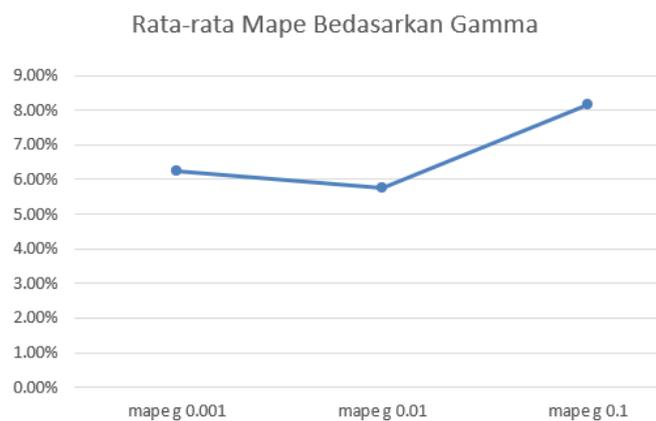
Gambar 4. 32 Rata-rata MAPE Berdasarkan Nilai Gamma pada Rasio 80:20

Analisis serupa dilakukan pada skenario rasio data latih dan uji sebesar 90:10. Hasilnya disajikan pada Tabel 4.89.

Tabel 4. 90 Rata-rata MAPE Berdasarkan Nilai Gamma pada Rasio 90:10

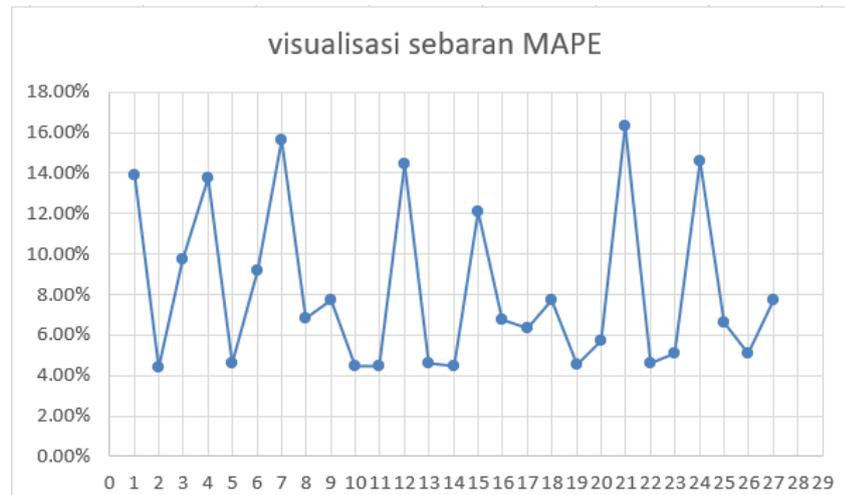
No.	<i>Hyperparameter</i>	MAPE
1	gamma =0.001	6.24%
2	gamma =0.01	5.74%
3	gamma =0.1	8.17%

Seperti pada skenario sebelumnya, gamma sebesar 0.01 kembali menunjukkan performa terbaik dengan nilai MAPE paling rendah, yakni 5.74%. Konsistensi hasil ini menunjukkan bahwa gamma 0.01 mampu menjaga kinerja model meskipun proporsi data latih meningkat.



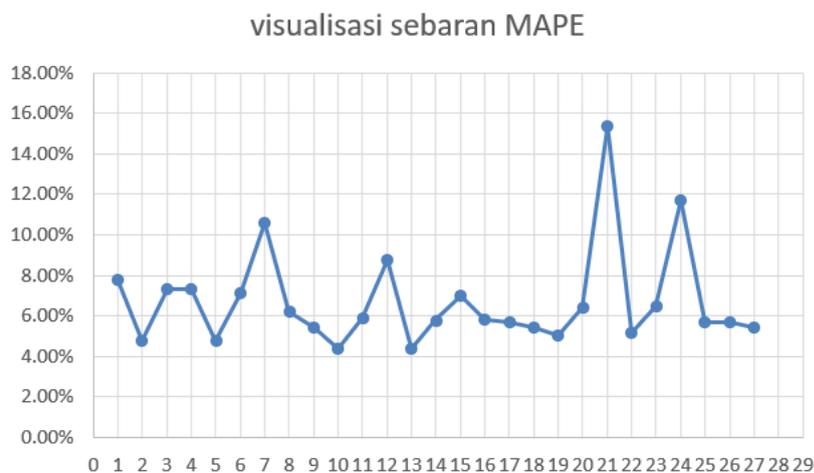
Gambar 4. 33 Rata-rata MAPE Berdasarkan Nilai Gamma pada Rasio 80:20

Berdasarkan kedua skenario, dapat disimpulkan bahwa $\gamma = 0.01$ merupakan nilai yang optimal untuk data set dalam penelitian ini. Gamma yang terlalu kecil (0.001) maupun terlalu besar (0.1) justru meningkatkan nilai MAPE, baik karena kurang fleksibel maupun terlalu sensitif. Oleh karena itu, pemilihan nilai gamma yang tepat menjadi faktor penting dalam membangun model SVR yang seimbang antara kompleksitas dan akurasi prediksi.



Gambar 4. 34 Visualisasi sebaran MAPE skenario 80:20

Berdasarkan gambar 4.34 Skenario 2 memiliki nilai *Mean Absolute Percentage Error* (MAPE) terkecil dibandingkan seluruh skenario lainnya, yaitu sebesar 4,38%. Hal ini menunjukkan bahwa kombinasi parameter yang digunakan dalam skenario tersebut merupakan konfigurasi paling optimal untuk rasio data latih-uji 80:20. Sebaliknya, Skenario 21 memiliki nilai MAPE tertinggi, yang mengindikasikan bahwa kombinasi parameter pada skenario tersebut tidak cocok untuk data yang digunakan.



Gambar 4. 35 Visualisasi sebaran MAPE skenario 90:10

Berdasarkan gambar 4.35 Skenario 10 memiliki nilai MAPE (*Mean Absolute Percentage Error*) terkecil di antara semua skenario yang dilakukan yaitu sebesar 4.36%. Kemudian juga dapat disimpulkan untuk skenario 21 yang memiliki MAPE tertinggi berarti *tunning* parameter kurang cocok untuk data yang diuji.

Rendahnya nilai *error* pada skenario terbaik membuktikan bahwa metode SVR dengan *kernel* RBF mampu memprediksi nilai impor migas di Indonesia secara andal. Nilai MAPE yang diperoleh, yaitu 4,38% pada skenario 80:20 dan 4,36% pada skenario 90:10, termasuk dalam kategori prediksi sangat baik karena $MAPE < 10\%$ menandakan prediksi berkualitas tinggi. Hal ini menunjukkan bahwa model SVR yang dilatih dengan parameter yang tepat mampu memberikan hasil prediksi yang sangat akurat.

Dengan akurasi prediksi yang tinggi, model ini dapat menjadi alat bantu penting bagi pengambil kebijakan dalam menyusun strategi impor migas, perencanaan alokasi sumber daya, serta mendukung kebijakan perdagangan

nasional. Akurasi prediksi yang baik juga berkontribusi pada perumusan strategi ekonomi yang lebih tepat sasaran dan berkelanjutan.

4.4 Integrasi Islam

Terdapat tiga muamalah yang diterapkan. Muamalah adalah suatu interaksi manusia. Tiga konsep yang digunakan dalam penelitian adalah sebagai berikut:

4.4.1 Muamalah Ma'a Allah

Pentingnya perencanaan yang baik dalam hal alokasi migas juga dikarenakan migas merupakan aset berharga yang perlu dijaga dan dikelola dengan bijak untuk kesejahteraan jangka panjang bangsa dan generasi mendatang. Allah SWT menciptakan sumber daya alam untuk dimanfaatkan oleh manusia untuk mendukung kelangsungan hidup dan menikmati kehidupan dunia, termasuk di antaranya minyak dan gas. Hal ini sesuai dengan firman-Nya dalam QS. An-Nahl ayat 13 yang berbunyi:

وَهُوَ الَّذِي سَخَّرَ الْبَحْرَ لِنَآكُلُوا مِنْهُ حَمًا طَرِيًّا وَتَسْتَخْرِجُوا مِنْهُ حِلْيَةً تَلْبَسُونَهَا وَتَرَى الْفُلْكَ مَوَاجِرَ فِيهِ وَلِيَبْتَلِيَكُمْ مِنْ فَضْلِهِ وَلَعَلَّكُمْ تَشْكُرُونَ

"Dan Dialah, Allah yang menundukkan lautan (untukmu), agar kamu dapat memakan daripadanya daging yang segar (ikan), dan kamu mengeluarkan dari lautan itu perhiasan yang kamu pakai; dan kamu melihat bahtera berlayar padanya, dan supaya kamu mencari (keuntungan) dari karunia-Nya, dan supaya kamu bersyukur." (QS: An-Nahl: 14)

Tafsir Kementerian Agama RI menjelaskan bahwa Allah menundukkan segala ciptaan-Nya di bumi, termasuk binatang dan tumbuhan, dengan berbagai jenis, warna, dan bentuk. Allah juga menundukkan laut agar manusia dapat mencari rezeki dari karunia-Nya yang ada di sana, dan agar manusia selalu bersyukur atas

nikmat yang diberikan-Nya serta memanfaatkannya sesuai dengan tujuan penciptaan. Oleh karena itu, rasa syukur dan tanggung jawab dalam memanfaatkan sumber daya alam sangat penting (Lajnah Pentashih Mushaf RI, 2016).

4.4.2 Muamalah Ma'a al-Alam

Penggunaan sumber daya alam tersebut juga seharusnya sesuai dengan tujuan penciptaannya dan tidak digunakan secara berlebihan yang menimbulkan kerusakan sejalan pada firman-Nya dalam QS. Ar-Rum ayat 41 yang berbunyi:

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

"Telah nampak kerusakan di darat dan di laut disebabkan karena perbuatan tangan manusia, supaya Allah merasakan kepada mereka sebahagian dari (akibat) perbuatan mereka, agar mereka kembali (ke jalan yang benar)." (QS: Ar-Rum: 41)

Tafsir dari Kementerian Agama RI mengungkapkan bahwa kerusakan yang dimaksud dapat berupa pencemaran lingkungan atau bencana alam. Kerusakan tersebut disebabkan oleh tindakan manusia yang dikendalikan hawa nafsu, seperti eksploitasi alam yang berlebihan. Allah menghendaki agar mereka merasakan sebagian dari akibat perbuatan buruk mereka agar mereka kembali ke jalan yang benar dengan menjaga kesesuaian perilakunya dengan fitrahnya (Lajnah Pentashih Mushaf RI, 2016).

4.4.3 Muamalah Ma'a an-Nas

Menurut ajaran Islam, memberikan manfaat kepada sesama dan saling membantu merupakan perbuatan yang mulia, sebagaimana yang disampaikan dalam hadis yang menyatakan:

خَيْرُ النَّاسِ أَنْفَعُهُمْ لِلنَّاسِ

“Sebaik-baik manusia adalah yang paling bermanfaat bagi manusia” (HR. ath-Thabrani).

Hadist dari kitab *Al-Muj'am Al-Awsat* karya (At-Thabrani, t.t.) menjelaskan bahwa telah menjadi kewajiban bagi seorang mukmin yang baik untuk berperilaku baik dan memberikan manfaat bagi lingkungannya. Oleh karena itu, peneliti telah melaksanakan penelitian ini dan menyajikan hasil mengenai tingkat *error* dalam menerapkan metode *Support Vector Regression* untuk memprediksi nilai ekspor migas. Dengan demikian, diharapkan bahwa pembaca dapat memanfaatkan hasil ini sebagai referensi atau melanjutkan penelitian ini agar dapat memberikan manfaat yang lebih luas.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil uji coba terhadap 27 skenario pengujian yang dilakukan pada model *Support Vector Regression* (SVR) dengan *kernel Radial Basis Function* (RBF), menggunakan dua rasio pembagian data latih dan uji, yaitu 80:20 dan 90:10, diperoleh model prediksi nilai impor migas di Indonesia yang paling optimal pada skenario 2 untuk rasio 80:20 dengan konfigurasi *hyperparameter* $C = 1$, $\epsilon = 0.001$, dan $\gamma = 0.01$ yang menghasilkan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 4.38%. Sementara untuk rasio 90:10, performa terbaik ada pada skenario 10 dengan konfigurasi *hyperparameter* $C = 10$, $\epsilon = 0.001$, dan $\gamma = 0.001$ dengan nilai MAPE sebesar 4.36%.

Nilai MAPE yang dihasilkan dari kedua skenario tersebut termasuk dalam kategori prediksi sangat baik, karena berada di bawah 10%, dan menunjukkan bahwa model SVR mampu memberikan hasil prediksi yang akurat dan mendekati nilai aktual impor migas. Artinya, nilai-nilai hasil prediksi model memiliki deviasi yang sangat kecil terhadap data riil, sehingga dapat digunakan sebagai alat bantu pengambilan keputusan dalam perencanaan dan pengawasan sektor energi, khususnya kebijakan impor migas di Indonesia.

Dalam kedua skenario rasio data latih-uji, yaitu 80:20 dan 90:10, pemilihan *hyperparameter* menunjukkan pola yang konsisten terhadap performa model SVR. Nilai $C = 10$ secara konsisten menghasilkan rata-rata MAPE terendah dibanding nilai C yang terlalu kecil ($C = 1$), yang cenderung menyebabkan *underfitting*,

maupun nilai yang terlalu besar ($C = 100$) yang meningkatkan risiko *overfitting*, sehingga $C = 10$ memberikan keseimbangan optimal antara margin kesalahan dan kompleksitas model. Untuk *hyperparameter* epsilon, nilai 0.1 juga memberikan performa terbaik secara konsisten dalam kedua skenario karena memberikan toleransi kesalahan yang cukup tanpa membuat model terlalu sensitif kehilangan informasi penting. Sementara itu, $\gamma = 0.01$ terbukti sebagai nilai yang paling optimal secara konsisten, karena mampu mengatur jangkauan pengaruh data secara tepat, menghindari baik *underfitting* akibat γ terlalu kecil maupun *overfitting* akibat γ terlalu besar.

Berdasarkan hasil penelitian, dapat disimpulkan bahwa metode *Support Vector Regression* (SVR) dengan *kernel Radial Basis Function* (RBF) terbukti efektif untuk memprediksi nilai impor migas di Indonesia. Evaluasi model menunjukkan bahwa konfigurasi *hyperparameter* yang optimal tidak hanya menurunkan tingkat *error* secara signifikan, tetapi juga menghasilkan prediksi yang stabil, akurat, dan dapat diandalkan. Dengan demikian, model ini memiliki potensi besar untuk diterapkan sebagai alat bantu prediktif dalam pengambilan kebijakan energi dan ekonomi, khususnya dalam mengantisipasi kebutuhan dan pengendalian impor migas secara lebih presisi dan berbasis data historis.

5.2 Saran

Berdasarkan penelitian yang sudah dijelaskan, terdapat beberapa saran yang dapat diambil untuk penelitian dan pengembangan lebih lanjut dalam memprediksi nilai ekspor migas di Indonesia agar mendapatkan hasil yang memuaskan yaitu sebagai berikut :

1. Menggunakan metode *tunning hyperparameter* yang berbeda untuk prediksi seperti *Grid Search Optimization* untuk mengevaluasi apakah ada parameter yang lebih baik dalam prediksi untuk nilai ekspor migas.
2. Melakukan eksperimen dengan metode pembelajaran mesin lainnya (seperti *LSTM*, *XGBoost*, atau *Random Forest*) sebagai pembanding untuk mengevaluasi keunggulan dan kelemahan SVR dalam konteks prediksi nilai impor migas.

DAFTAR PUSTAKA

- Afandi, W., Laksana, T. G., & Tanjung, N. A. F. (2023). *Penerapan Metode Support Vector Machine Analisis Sentimen Tweet Pergantian Logo Halal di Indonesia*. 16(1).
- Ahmad Mustofa Al-Maraghi. (1974). *Tafsirul Maraghi*.
- Annuri, I. F. A. (2017). Analisis Penggunaan Metode Altman (z-Score) Dalam Memprediksi Terjadinya Financial Distress Pada Perusahaan Minyak Bumi Dan Gas (migas) Yang Terdaftar Di Bursa Efek Indonesia (bei) Periode 2010-2014. *Jom FISIP Volume 4*, 4(2).
- Asyiva, A. (2019). *Prediksi Laju Inflasi Indonesia Menggunakan Metode Support Vector Regression Dengan Kernel Radial Basis Function*.
- At-Thabrani. (t.t.). *Al-Muj'am Al-Awsat*.
- Cabello-Solorzano, K., Ortigosa De Araujo, I., Peña, M., Correia, L., & J. Tallón-Ballesteros, A. (2023). The Impact of Data Normalization on the Accuracy of Machine Learning Algorithms: A Comparative Analysis. Dalam P. García Bringas, H. Pérez García, F. J. Martínez De Pisón, F. Martínez Álvarez, A. Troncoso Lora, Á. Herrero, J. L. Calvo Rolle, H. Quintián, & E. Corchado (Ed.), *18th International Conference on Soft Computing Models in Industrial and Environmental Applications (SOCO 2023)* (Vol. 750, hlm. 344–353). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-42536-3_33
- Cahyono, R. E., Sugiono, J. P., & Tjandra, S. (2019). Analisis Kinerja Metode Support Vector Regression (SVR) dalam Memprediksi Indeks Harga Konsumen. *JTIM : Jurnal Teknologi Informasi dan Multimedia*, 1(2), 106–116. <https://doi.org/10.35746/jtim.v1i2.22>
- Chang, C.-C., & Lin, C.-J. (2011). LIBSVM: A library for support vector machines. *ACM Transactions on Intelligent Systems and Technology*, 2(3), 1–27. <https://doi.org/10.1145/1961189.1961199>
- Chirkova, O. A. (2024). Forecasting the Implementation of Strategic Development Programs of the Municipality. *Economics Profession Business*, 1, 110–115. <https://doi.org/10.14258/epb202415>
- Chopra, D., & Khurana, R. (2023). *Introduction to Machine Learning with Python*. BENTHAM SCIENCE PUBLISHERS. <https://doi.org/10.2174/97898151244221230101>

- Ferryan, D. A., Intan, P. K., & Hafiyusholeh, M. (2022). Peramalan Harga Minyak Mentah di Indonesia dengan Metode Regresi Polinomial. *Jurnal Ilmiah Matematika Dan Terapan*, 19(1), 13–18. <https://doi.org/10.22487/2540766X.2022.v19.i1.15779>
- García-Florianó, A., López-Martín, C., Yáñez-Márquez, C., & Abran, A. (2018). Support vector regression for predicting software enhancement effort. *Information and Software Technology*, 97, 99–109. <https://doi.org/10.1016/j.infsof.2018.01.003>
- Guo, H., Yin, J., Zhao, J., Yao, L., Xia, X., & Luo, H. (2015). An Ensemble Learning for Predicting Breakdown Field Strength of Polyimide Nanocomposite Films. *Journal of Nanomaterials*, 2015(1), 950943. <https://doi.org/10.1155/2015/950943>
- Irwati, D. & Ade Nurul Hidayat. (2023). ANALISIS KEAKURATAN FORECAST RESIN ABS GRADE 500 322 MENGGUNAKAN PENDEKATAN MEAN ABSOLUTE PERCENTAGE ERROR (MAPE): STUDI KASUS INDUSTRI MANUFAKTUR PLASTIC COLORING DAN COMPOUNDING. *Industry Xplore*, 8(2), 269–273. <https://doi.org/10.36805/teknikindustri.v8i2.5518>
- Kocaoglu, A. (2024). Efficient Optimization of a Support Vector Regression Model with Natural Logarithm of the Hyperbolic Cosine Loss Function for Broader Noise Distribution. *Applied Sciences*, 14(9), 3641. <https://doi.org/10.3390/app14093641>
- Lajnah Pentashih Mushaf RI. (2016). *Tafsir Wajiz Al-Qur'an Al-karim Jilid II*.
- Le, L.-H. (2024). Time series analysis and applications in data analysis, forecasting and prediction. *HPU2 Journal of Science: Natural Sciences and Technology*, 3(1), 20–29. <https://doi.org/10.56764/hpu2.jos.2024.3.1.20-29>
- Leushuis, E., & Wetzels, A. M. M. (2014). Reducing Inter-Laboratory Differences between Semen Analyses Using Z Score and Regression Transformations. *International Journal of Fertility and Sterilityudha*.
- Mahdavi, M. (2024). Efficient Hardware Acceleration of Mean Squared Error Calculation Through In-Memory Computing. *2024 IEEE International Conference on Omni-layer Intelligent Systems (COINS)*, 1–6. <https://doi.org/10.1109/COINS61597.2024.10622442>
- Muhammad Arif Abdul Syukur, Muhammad Faishal. (2023). Penerapan Model Regresi Linear Untuk Estimasi Mobil Bekas menggunakan Bahasa Phyton. *Jurnal Ilmiah Matematika, Sains dan Teknologi*, 11, No. 2, hlm., 182–191. <https://doi.org/DOI: https://doi.org/10.37905/euler.v11i2.20698>

- Muhammad Sahi, Muhammad Faisal, Yunifa Miftachul Arif, Cahyo Crysdian. (2023). Analysis of the Use of Artificial Neural Network Models In Predicting Bitcoin. *Applied Information System and Management*, 6, (2) 2023, hlm., 91–96. <https://doi.org/DOI: 10.15408/aism.vxix. xxxxx>
- Mustakim, M., Buono, A., & Hermadi, I. (2016). Performance Comparison Between Support Vector Regression and Artificial Neural Network for Prediction of Oil Palm Production. *Jurnal Ilmu Komputer dan Informasi*, 9(1), 1. <https://doi.org/10.21609/jiki.v9i1.287>
- Nabillah, I., & Ranggadara, I. (2020). Mean Absolute Percentage Error untuk Evaluasi Hasil Prediksi Komoditas Laut. *JOINS (Journal of Information System)*, 5(2), 250–255. <https://doi.org/10.33633/joins.v5i2.3900>
- Parbat, D., & Chakraborty, M. (2020). A python based support vector regression model for prediction of COVID19 cases in India. *Chaos, Solitons & Fractals*, 138, 109942. <https://doi.org/10.1016/j.chaos.2020.109942>
- Purnama, D. I., & Hendarsin, O. P. (2020). Peramalan Jumlah Penumpang Berangkat Melalui Transportasi Udara di Sulawesi Tengah Menggunakan Support Vector Regression (SVR). *Jambura Journal of Mathematics*, 2(2), 49–59. <https://doi.org/10.34312/jjom.v2i2.4458>
- Putri, A. S., Soehardjoepri, S., & Suharsono, A. (2023). Optimasi Parameter Support Vector Regression pada Prediksi Nilai Tukar Dolar Amerika terhadap Rupiah dengan Menggunakan Genetic Algorithm dan Particle Swarm Optimization. *Jurnal Sains dan Seni ITS*, 12(2), D119-D126D127-D134. <https://doi.org/10.12962/j23373520.v12i2.111596>
- Rahmawati. (2020). *Implementasi Algoritme Support Vector Regression Dan Particle Swarm Optimization Dalam Peramalan Penjualan*.
- Rais, Z., & Ahmar, A. S. (2024). *Implementation of the Support Vector Regression (SVR) Method in Inflation Prediction in Makassar City*. 4.
- Ramdhani, Y., & Mubarak, A. (2019). *Analisis Time Series Prediksi Penutupan Harga Saham Antm.Jk Dengan Algoritma SVM Model Regresi*.
- Reiter, S., & Werner, S. W. R. (2024). *Interpolatory model order reduction of large-scale dynamical systems with root mean squared error measures (Versi 2)*. arXiv. <https://doi.org/10.48550/ARXIV.2403.08894>
- Safira, A. N., Warsito, B., & Rusgiyono, A. (2023). Analisis Support Vector Regression (svr) Dengan Algoritma Grid Search Time Series Cross Validation Untuk Prediksi Jumlah Kasus Terkonfirmasi Covid-19 Di Indonesia. *Jurnal Gaussian*, 11(4), 512–521. <https://doi.org/10.14710/j.gauss.11.4.512-521>

- Saputra, G. H., Wigena, A. H., & Sartono, B. (2019). Penggunaan Support Vector Regression Dalam Pemodelan Indeks Saham Syariah Indonesia Dengan Algoritme Grid Search. *Indonesian Journal of Statistics and Its Applications*, 3(2), 148–160. <https://doi.org/10.29244/ijisa.v3i2.172>
- Sirocchi, C., Bogliolo, A., & Montagna, S. (2024). Medical-informed machine learning: Integrating prior knowledge into medical decision systems. *BMC Medical Informatics and Decision Making*, 24(S4), 186. <https://doi.org/10.1186/s12911-024-02582-4>
- Syahrudin, Fatmawati, & Suprajitno, H. (2022). Investigations on Impact of Feature Normalization Techniques for Prediction of Hydro-Climatology Data Using Neural Network Backpropagation with Three Layer Hidden. *International Journal of Sustainable Development and Planning*, 17(07), 2069–2074. <https://doi.org/10.18280/ijstdp.170707>
- Thanh Ngoc, T., Van Dai, L., & Minh Thuyen, C. (2021). Support Vector Regression based on Grid Search method of Hyperparameters for Load Forecasting. *Acta Polytechnica Hungarica*, 18(2), 143–158. <https://doi.org/10.12700/APH.18.2.2021.2.8>
- Verdonck, T., Baesens, B., Óskarsdóttir, M., & Vanden Broucke, S. (2024). Special issue on feature engineering editorial. *Machine Learning*, 113(7), 3917–3928. <https://doi.org/10.1007/s10994-021-06042-2>
- Wardani, N. K., Afandi, M. R., & Riani, L. P. (2020). Analisis Forecasting Demand Dengan Metode Linear Exponential Smoothing (studi Pada: Produk Batik Fendy, Klaten). *Jurnal Ekonomi Dan Pendidikan*, 16(2), 81–89. <https://doi.org/10.21831/jep.v16i2.33714>
- Wei, W. W. S. (2006). *Time series analysis: Univariate and multivariate methods* (2nd ed). Pearson Addison Wesley.
- Yudhawan, D. H. (2020). *Implementasi Support Vector Regression Untuk Peramalan Harga Saham Perusahaan Pertambangan Di Indonesia*.
- Yunanda, V. D., & Hendrastuty, N. (2024). Perbandingan Kernel Polynomial dan RBF Pada Algoritma SVM Untuk Analisis Sentimen Skincare di Indonesia. *Jurnal Media Informatika Budidarma*, 8(2), 726. <https://doi.org/10.30865/mib.v8i2.7425>
- Zhang, N., Shen, S.-L., Wu, H.-N., Chai, J.-C., Xu, Y.-S., & Yin, Z.-Y. (2015). Evaluation of effect of basal geotextile reinforcement under embankment loading on soft marine deposits. *Geotextiles and Geomembranes*, 43(6), 506–514. <https://doi.org/10.1016/j.geotextmem.2015.05.005>

LAMPIRAN

Lampiran 1 :Data nilai impor migas di Indonesia

Periode		Nilai Impor Migas	Periode		Nilai Impor Migas
Tahun	Bulan		Tahun	Bulan	
2015	Januari	2115.1	2020	Januari	2906.1
	Februari	1719.6		Februari	2406.5
	Maret	2268		Maret	3014.8
	April	2336.3		April	2955
	Mei	2080.5		Mei	3135.1
	Juni	2577.5		Juni	2222.3
	Juli	2294.3		Juli	3132.1
	Agustus	2108		Agustus	2662
	September	1912.4		September	3328.6
	Oktober	1763		Oktober	3206.8
	November	1640.4		November	3488.7
	Desember	1798		Desember	3372.4
2016	Januari	1221.5	2021	Januari	2698.3
	Februari	1122.9		Februari	2979.6
	Maret	1552.4		Maret	3326.5
	April	1362.1		April	2984.3
	Mei	1668.5		Mei	2748.2
	Juni	1772.2		Juni	3270.5
	Juli	1506.4		Juli	3557.7
	Agustus	1795.9		Agustus	2648.4
	September	1766.4		September	2528.5
	Oktober	1545.1		Oktober	3665.9
	November	1724.1		November	2570.3
	Desember	1701.9		Desember	3296.8
2017	Januari	1221.5	2022	Januari	2906.1
	Februari	1122.9		Februari	2406.5
	Maret	1552.4		Maret	3014.8
	April	1362.1		April	2955
	Mei	1668.5		Mei	3135.1
	Juni	1772.2		Juni	2222.3
	Juli	1506.4		Juli	3132.1
	Agustus	1795.9		Agustus	2662
	September	1766.4		September	3328.6
	Oktober	1545.1		Oktober	3206.8
	November	1724.1		November	3488.7

	Desember	1701.9		Desember	3372.4
2018	Januari	1221.5	2023	Januari	2698.3
	Februari	1122.9		Februari	2979.6
	Maret	1552.4		Maret	3326.5
	April	1362.1		April	2984.3
	Mei	1668.5		Mei	2748.2
	Juni	1772.2		Juni	3270.5
	Juli	1506.4		Juli	3557.7
	Agustus	1795.9		Agustus	2648.4
	September	1766.4		September	2528.5
	Oktober	1545.1		Oktober	3665.9
	November	1724.1		November	2570.3
	Desember	1701.9		Desember	3296.8
2019	Januari	1221.5	2024	Januari	2698.3
	Februari	1122.9		Februari	2979.6
	Maret	1552.4		Maret	3326.5
	April	1362.1		April	2984.3
	Mei	1668.5		Mei	2748.2
	Juni	1772.2		Juni	3270.5
	Juli	1506.4		Juli	3557.7
	Agustus	1795.9		Agustus	2648.4
	September	1766.4		September	2528.5
	Oktober	1545.1		Oktober	3665.9
	November	1724.1		November	2570.3
	Desember	1701.9		Desember	3296.8