

**PREDIKSI *URBAN HEAT ISLAND* (UHI) BERDASARKAN PENGINDERAAN
JAUH SATELIT MENGGUNAKAN *SUPPORT VECTOR REGRESION***

SKRIPSI

**Oleh :
SALMA AINUR ROHMA
NIM. 200605110007**



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2024**

**PREDIKSI *URBAN HEAT ISLAND* (UHI) BERDASARKAN
PENGINDERAAN JAUH SATELIT MENGGUNAKAN
*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:
SALMA AINUR ROHMA
NIM. 200605110007

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2024**

HALAMAN PERSETUJUAN

**PREDIKSI *URBAN HEAT ISLAND* (UHI) BERDASARKAN
PENGINDERAAN JAUH SATELIT MENGGUNAKAN
*SUPPORT VECTOR REGRESSION***

SKRIPSI

Oleh:
SALMA AINUR ROHMA
NIM. 200605110007

Telah Diperiksa dan Disetujui untuk Diuji:
Tanggal: 6 Mei 2024

Pembimbing I,



Hani Nurhayati, M.T
NIP. 19780625 200801 2 006

Pembimbing II,



Dr. 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



P. Fachri Kurniawan, M.MT, IPM
NIP. 19771020 200912 1 001

HALAMAN PENGESAHAN

**PREDIKSI *URBAN HEAT ISLAND* (UHI) BERDASARKAN
PENGINDERAAN JAUH SATELIT MENGGUNAKAN
*SUPPORT VECTOR REGRESSION***

SKRIPSI

Oleh:
SALMA AINUR ROHMA
NIM. 200605110007

Telah Dipertahankan di Depan Dewan Penguji Skripsi
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Sarjana Komputer (S.Kom)
Tanggal: 21 Mei 2024

Susunan Dewan Penguji

Ketua Penguji : Dr. Fresy Nugroho, M.T
NIP. 19710722 201101 1 001

Anggota Penguji I : Okta Qomaruddin Azis, M.Kom
NIP. 19911019 201903 1 013

Anggota Penguji II : Hani Nurhayati, M.T
NIP. 19780625 200801 2 006

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



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




Dr. Fachrud Kurniawan, M.MT, IPM
NIP. 19771020 200912 1 001

PERNYATAAN KEASLIAN TULISAN

Saya yang bertanda tangan di bawah ini:

Nama : Salma Ainur Rohma
NIM : 200605110007
Fakultas / Program Studi : Sains dan Teknologi / Teknik Informatika
Judul Skripsi : Prediksi Urban Heat Island (UHI) Berdasarkan
Penginderaan Jauh Satelit Menggunakan 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, 5 Mei 2024

Yang membuat pernyataan,



Salma Ainur Rohma

NIM. 200605110007

MOTTO

وَأَحْسِنُ كَمَا أَحْسَنَ اللَّهُ إِلَيْكَ

“Teruslah berbuat baik, sebagaimana Allah selalu menyiapkan yang terbaik untukmu”

HALAMAN PERSEMBAHAN

Segala puji bagi Allah SWT yang telah memberikan limpahan rahmat dan hidayah kepada hamba-Nya, sehingga saya bisa menyelesaikan karya ini. Serta shalawat dan salam semoga selalu tercurahkan kepada nabi Muhammad SAW.

Saya persembahkan karya ini kepada:

Ayah dan ibu saya,

Suratno, S.Pd., dan Anita Mustikasari, S.Pd.

Terima kasih atas segala ilmu, dukungan dan semangatnya serta yang tidak kalah penting adalah doa di setiap pagi dan malamnya, sehingga saya bisa menyelesaikan ujian demi ujian khususnya skripsi ini. semoga karya ini menjadi karya yang bermanfaat dunia dan akhirat serta menjadi keberkahan untuk semuanya.

Teruntuk kakak dan saudari kembar saya,

Viranita Quratul Aini, S.Si dan Shima Ainur Rofi, S.Psi.

Terima kasih atas semangat, dukungan, kesabaran, dan doa serta selalu ada baik saat senang maupun duka

Tim Penelitian serta pihak yang membantu penelitian

Terima kasih atas ilmu, pengalaman, dan kesempatannya serta dukungan yang selalu diberikan. Sehingga saya bisa menyelesaikan karya ini.

Teman-teman seperjuangan,

Seruluh Mahasiswa Teknik Informatika khususnya untuk Angkatan 2020 yang tidak bisa saya sebutkan satu-persatu

Yang telah berbagi ilmu, support serta pengalaman yang berharga selama perkuliahan ini. Semoga kita semua selalu diberi kesehatan dan kemudahan untuk menuntut ilmu serta dimudahkan dalam urusan lainnya oleh Allah SWT

KATA PENGANTAR

Assalamualaikum Warahmatullahi Wabarakatuh.

Segala puji hanya milik Allah Subhanahu Wa Ta'ala atas segala nikmat dan kasih sayang-Nya yang telah memudahkan penulis untuk menyelesaikan skripsi yang berjudul “Prediksi *Urban Heat Island* (UHI) Berdasarkan Penginderaan Jauh Satelit Menggunakan *Support Vector Regression*”. Semoga shalawat dan salam senantiasa terlimpah kepada Nabi Muhammad Sallallahu ‘Alaihi wa Sallam. Dan semoga kita semua mendapat syafaatnya di hari kiamat nanti, Aamiin.

Penulis mengucapkan rasa syukur dan terima kasih yang tak terhingga kepada semua pihak-pihak yang selalu memberikan bantuan dan motivasi kepada penulis untuk dapat menyelesaikan skripsi ini. Ucapan ini 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. Fachrul Kurniawan, M.MT., IPM, selaku Ketua Program Studi Teknik Informatika Universitas Islam Negeri Maulana Malik Ibrahim Malang.
4. Hani Nurhayati, M.T selaku dosen pembimbing I dan Dr. Yunifa Miftachul Arif, M.T selaku dosen pembimbing II yang telah memberikan bantuan dan arahan kepada penulis, sehingga bisa menuntaskan skripsi ini.
5. Dr. Fresy Nugroho, M.T selaku dosen penguji I dan Okta Qomaruddin Aziz, M.Kom selaku dosen penguji II yang telah menguji serta memberikan masukan sehingga penulis dapat menuntaskan skripsi dengan baik.

6. Segenap Dosen, Admin, Laboran dan Mahasiswa Program Studi Teknik Informatika yang telah memberikan banyak dukungan dan bimbingan selama pengerjaan skripsi ini.
7. Ibu, Ayah, Kakak, serta saudari kembar saya yang selalu memberikan dukungan dan motivasi untuk terus berusaha, dan doa yang tak putus-putusnya selalu disampaikan agar dapat menuntaskan skripsi ini dengan lancar dan baik.

Akhir kata, penulis mengakui bahwa penulisan pada skripsi ini masih banyak kekurangan. Saya berharap semoga skripsi ini diterima sebagai amal ibadah yang tulus dan bermanfaat di sisi Allah Subhanahu Wa Ta'ala. Semoga karya ini menjadi bagian dari kontribusi yang tak terputus dalam rangka memperkuat dan mengembangkan ilmu pengetahuan, serta melaksanakan tugas sebagai hamba Allah yang berkomitmen.

Wassalamualaikum Warahmatullahi Wabarakatuh.

Malang, 6 Mei 2024

Penulis

DAFTAR ISI

HALAMAN JUDUL	i
LEMBAR PENGAJUAN.....	ii
HALAMAN PERSETUJUAN	iii
HALAMAN PENGESAHAN.....	iv
PERNYATAAN KEASLIAN TULISAN.....	v
MOTTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR.....	viii
DAFTAR ISI.....	x
DAFTAR GAMBAR.....	xii
DAFTAR TABEL	xiv
ABSTRAK	xvi
ABSTRACT.....	xvii
مستخلص البحث.....	xviii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	6
1.3 Batasan Masalah	6
1.4 Tujuan Penelitian	7
1.5 Manfaat Penelitian	7
BAB II STUDI PUSTAKA	8
2.1 Penelitian Terdahulu	8
2.2 Prediksi	11
2.3 <i>Urban Heat Island</i> (UHI).....	11
2.3.1 Pengertian UHI	12
2.3.2 Identifikasi Estimasi Fenomena <i>Urban Heat Island</i>	13
2.3.3 Faktor-faktor yang mempengaruhi UHI	14
2.4 <i>Support Vector Regresion</i> (SVR).....	17
2.5 Fungsi Kernel.....	21
2.5.1 Kernel Linear	21
2.5.2 Kernel <i>Polynomial</i>	22
2.5.3 Kernel Radial Basis Function (RBF)	23
2.6 Evaluasi Performa Model	23
2.6.1 Koefisien determinasi (R^2).....	23
2.6.2 Mean Absolute Percentage Error (MAPE)	24
2.6.3 Mean Square Error (MSE).....	25
BAB III DESAIN DAN IMPLEMENTASI	26
3.1 Desain Penelitian	26
3.1.1 Landsat-8.....	27
3.1.2 Sentinel-2	28
3.1.1 SRTM.....	29
3.2 <i>Cloud Masking</i>	30
3.3 Perhitungan fitur-fitur	31

3.3.1 NDVI.....	32
3.3.2 NDBI.....	33
3.3.3 NDWI.....	34
3.3.4 NDMI.....	35
3.3.5 UDI	36
3.3.6 Elevasi.....	37
3.3.7 LST	37
3.4 Normalisasi Data.....	38
3.5 Metode <i>Support Vector Regresion</i>	40
3.7 Evaluasi.....	45
3.8 Skenario Pengujian	46
BAB IV UJI COBA DAN PEMBAHASAN.....	48
4.1 Hasil Dataset	48
4.1.1 Cloud Masking.....	48
4.1.2 Feature Scalling	51
4.2 Normalisasi Data.....	51
4.3 Hasil Data Splitting.....	52
4.4.1 Hasil pengujian Skenario 1	52
4.4.2 Hasil pengujian Skenario 2	56
4.4.3 Hasil pengujian Skenario 3	59
4.5 Analisis Dan Pembahasan Hasil Pengujian	62
4.6 Visualisasi Hasil Prediksi	83
4.7 Integrasi Islam.....	85
4.7.1 Muamalah Mu'allah.....	85
4.7.2 Muamalah Mu'annas	86
4.7.3 Muamalah Mu'alam.....	88
BAB V KESIMPULAN DAN SARAN	91
5.1 Kesimpulan	91
5.2 Saran	92
DAFTAR PUSTAKA	
LAMPIRAN	

DAFTAR GAMBAR

Gambar 1. 1 Efek UHI berdasarkan LST (Sumber : Fuladlu et al., 2018).....	4
Gambar 2. 1 Matrix Support Vector Regresion (Sumber :Bozkir et al., 2019)	19
Gambar 3. 1 Desain Penelitian yang digunakan	26
Gambar 3. 2 Citra Landsat 8 pada Band 10	27
Gambar 3. 3 Citra Sentinel-2	29
Gambar 3. 4 Citra SRTM.....	30
Gambar 3. 5 Sebelum Cloud Masking	31
Gambar 3. 6 Setelah Cloud Masking	31
Gambar 3. 7 NDVI.....	33
Gambar 3. 8 NDBI.....	34
Gambar 3. 9 NDWI.....	35
Gambar 3. 10 NDMI	36
Gambar 3. 11 Flowchart Support Vector Regresion.....	40
Gambar 4. 1 Perbandingan visualisasi citra vegetasi menggunakan Sentinel-2 sebelum dan setelah dilakukan Cloud Masking.....	49
Gambar 4. 2 Perbandingan visualisasi citra Land Surface Temperature menggunakan satelit Landsat-8 sebelum dan setelah dilakukan Cloud Masking.....	50
Gambar 4. 3 Evaluasi Performa R^2 Skenario 1	53
Gambar 4. 4 Evaluasi Performa MSE Skenario 1	54
Gambar 4. 5 Evaluasi Performa MAPE Skenario 1	55
Gambar 4. 6 Evaluasi Performa R^2 Skenario 2	56
Gambar 4. 7 Evaluasi Performa MSE Skenario 2	57
Gambar 4. 8 Evaluasi Performa MAPE Skenario 2.....	58
Gambar 4. 9 Evaluasi Performa R^2 Skenario 3	59
Gambar 4. 10 Evaluasi Performa MSE Skenario 3	60
Gambar 4. 11 Evaluasi Performa MAPE Skenario 3.....	61
Gambar 4. 12 Rata-rata dan standar deviasi MAPE per skenario.....	65
Gambar 4. 13 Rata-rata MAPE setiap kernel pada skenario 1.....	68
Gambar 4. 14 Rata-rata MAPE setiap kernel pada skenario 2.....	69
Gambar 4. 15 Rata-rata MAPE setiap kernel pada skenario 3.....	70
Gambar 4. 16 Rata-rata MAPE nilai <i>Cost</i> pada Kernel Linier	72
Gambar 4. 17 Rata-rata MAPE nilai <i>Cost</i> pada Kernel Polynomial.....	73
Gambar 4. 18 Rata-rata MAPE nilai <i>Cost</i> pada Kernel RBF.....	74
Gambar 4. 19 Rata-rata MAPE berdasarkan perubahan nilai <i>Epsilont</i> pada Kernel Linier	76
Gambar 4. 20 Rata-rata MAPE berdasarkan perubahan nilai <i>Epsilont</i> pada Kernel Polynomial.....	77
Gambar 4. 21 Rata-rata MAPE berdasarkan perubahan nilai <i>Epsilont</i> pada Kernel RBF.....	78

Gambar 4. 22 Rata-rata MAPE berdasarkan perubahan nilai <i>Degree</i> pada Kernel Polynomial.....	80
Gambar 4. 23 Rata-rata MAPE berdasarkan perubahan nilai <i>Gamma</i> pada Kernel RBF.....	82
Gambar 4. 24 Perbandingan citra data aktual dan hasil prediksi	84

DAFTAR TABEL

Tabel 2. 1 Tabel penelitian sebelumnya.....	10
Tabel 2. 2 Kriteria Nilai MAPE	24
Tabel 3. 1 Tabel Data Citra yang akan digunakan	26
Tabel 3. 2 Fitur-fitur yang akan digunakan beserta perhitungannya	32
Tabel 3. 3 Contoh perhitungan fitur:.....	38
Tabel 3. 4 Data sebelum dilakukan Normalisasi data	39
Tabel 3. 5 Data setelah dilakukan Normalisasi data	39
Tabel 3. 6 Tuning parameter Linier	41
Tabel 3. 7 Tuning parameter Polynomial.....	41
Tabel 3. 8 Tuning parameter Radial Basis Function (RBF).....	42
Tabel 3. 9 Perhitungan Jarak	42
Tabel 3. 10 Perhitungan Kernel linier	42
Tabel 3. 11 Perhitungan Matriks Hessian	43
Tabel 3. 12 Inisialisasi Nilai (\mathbf{a}_i^* dan \mathbf{a}_i).....	44
Tabel 3. 13 Hasil Nilai (\mathbf{a}_i dan \mathbf{a}_i^*)	44
Tabel 3. 14 Hasil perhitungan nilai eror.....	44
Tabel 3. 15 Perhitungan Fungsi Regresi	45
Tabel 3. 16 Skenario Pengujian pembagian data	46
Tabel 3. 17 Skenario Fungsi Kernel.....	46
Tabel 4. 1 Feature Calculation	51
Tabel 4. 2 Sebelum dan Sesudah Normalisasi data.....	51
Tabel 4. 3 Rasio Spliting Data	52
Tabel 4. 4 Rata-rata dan standar deviasi MAPE per skenario.....	64
Tabel 4. 5 Rata-rata dan standar deviasi MAPE setiap kernel pada skenario 1	67
Tabel 4. 6 Rata-rata dan standar deviasi MAPE setiap kernel pada skenario 2....	68
Tabel 4. 7 Rata-rata dan standar deviasi MAPE setiap kernel pada skenario 3....	69
Tabel 4. 8 Rata-rata dan standar deviasi MAPE nilai <i>Cost</i> pada Kernel Linier ...	71
Tabel 4. 9 Rata-rata dan standar deviasi MAPE nilai <i>Cost</i> pada Kernel Polynomial.....	73
Tabel 4. 10 Rata-rata dan standar deviasi MAPE nilai <i>Cost</i> pada Kernel RBF....	74
Tabel 4. 11 Rata-rata dan standar deviasi MAPE nilai <i>Epsilont</i> pada Kernel Linier	76
Tabel 4. 12 Rata-rata dan standar deviasi MAPE nilai <i>Epsilont</i> pada Kernel Polynomial	77
Tabel 4. 13 Rata-rata dan standar deviasi MAPE nilai <i>Epsilont</i> pada Kernel RBF	78
Tabel 4. 14 Rata-rata dan standar deviasi MAPE nilai <i>Degree</i> pada Kernel Polynomial	79
Tabel 4. 15 Rata-rata dan standar deviasi MAPE nilai <i>Gamma</i> pada Kernel RBF	81

Tabel 4. 16 Perbandingan Data Aktual dan Hasil Prediksi 83

ABSTRAK

Rohma, Salma Ainur. 2024. **Prediksi *Urban Heat Island* (UHI) Berdasarkan Penginderaan Jauh Satelit Menggunakan Support Vector Regression**. Skripsi. Program Studi Teknik Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang. Pembimbing: (I) Hani Nurhayati., M.T. (II) Dr Yunifa Miftahul Arif, M.T.

Kata kunci: *Urban Heat Island, Land Surface Temperature, Support Vector Regression*

Urban Heat Island merupakan kondisi di mana suhu di wilayah perkotaan menjadi secara signifikan lebih tinggi daripada di wilayah pedesaan sekitarnya. Sehingga memunculkan indeks ketidaknyamanan dengan ditandai meningkatnya suhu global, perubahan iklim, serta risiko kesehatan bagi penduduk kota. Fenomena ini menjadi perhatian global karena dampaknya yang luas terhadap lingkungan. Untuk mengatasi permasalahan tersebut, pada penelitian ini akan dirancang sistem prediksi UHI berdasarkan data penginderaan jauh menggunakan metode *Support Vector Regression*, dengan tujuan untuk mengetahui performa metode SVR dalam memprediksi UHI berdasarkan data penginderaan jauh saetelit. Data yang digunakan diperoleh dari situs Google Earth Engine dengan menggunakan 3 satelit yaitu *Landsat 8 OLI/TIRSC2 L1*, *Sentinel-2 Level-2A*, dan *NASA SRTM Digital Elevation 30m*, yang berisikan 4850 titik data sampel dengan 7 atribut. Penelitian ini membandingkan tiga kernel Support Vector Machine beserta tuning hyperparameter berbeda. Untuk mengevaluasi performa metode dalam melakukan prediksi, pengukuran dilakukan dengan memanfaatkan koefisien determinasi (R^2) untuk menunjukkan seberapa baik model melalui variabel-variabel yang digunakan, *Mean Square Error* (MSE) untuk memberikan gambaran seberapa besar kesalahan prediksi dalam bentuk kuadrat, serta nilai *Mean Absolute Percentage Error* (MAPE) untuk menghitung rata-rata kesalahan relatif dalam bentuk persentase. Hasil analisis menunjukkan bahwa pada skenario 3 dengan rasio 90:10 dengan kernel linear dan nilai hyperparameter $C=10$ dan *Epsilon* senilai 1, diperoleh performa terbaik berdasarkan nilai rata-rata dan standar deviasi MAPE.

ABSTRACT

Rohma, Salma Ainur. 2024. *Urban Heat Island (UHI) Prediction Based on Satellite Remote Sensing Using Support Vector Regression*. Thesis. Department of Informatics Engineering Faculty of Science and Technology Islamic State University of Maulana Malik Ibrahim Malang. Supervisors: (I) Hani Nurhayati., M.T. (II) Dr Yunifa Miftahul Arif, M.T.

Urban Heat Island is a condition where temperatures in urban areas are significantly higher than in surrounding rural areas. This gives rise to a discomfort index marked by increasing global temperatures, climate change and health risks for city residents. This phenomenon is of global concern because of its broad impact on the environment. To overcome this problem, in this research a UHI prediction system will be designed based on remote sensing data using the Support Vector Regression method, with the aim of knowing the performance of the SVR method in predicting UHI based on satellite remote sensing data. The data used was obtained from the Google Earth Engine website using 3 satellites, namely Landsat 8 OLI/TIRSC2 L1, Sentinel-2 Level-2A, and NASA SRTM Digital Elevation 30m, which contains 4850 sample data points with 7 attributes. This research compares three Support Vector Machine kernels along with different hyperparameter tuning. To evaluate the performance of the method in making predictions, measurements are carried out using the coefficient of determination (R^2) to show how good the model is through the variables used, Mean Square Error (MSE) to give an idea of how big the prediction error is in square form, and the Mean Absolute value Percentage Error (MAPE) to calculate the average relative error in percentage form. The analysis results show that in scenario 3 with a ratio of 90:10 with a linear kernel and a hyperparameter value of $C=10$ and *Epsilon* of 1, the best performance is obtained based on the average value and standard deviation of MAPE.

Keywords: Urban Heat Island, Land Surface Temperature, Support Vector Regression

مستخلص البحث

رحمة، سلمى عبنور. 2024. التنبؤ بجزيرة الحرارة الحضرية (UHI) بناءً على الاستشعار عن بعد عبر الأقمار الصناعية باستخدام الخدار متجه الدعم. أطروحة. بحث جامعي قسم الهندسة المعلوماتية، كلية العلوم والتكنولوجيا، جامعة مولانا مالك إبراهيم الإسلامية الحكومية، مالانج. المشرف الأول: (أنا) هاني نورحياتي، ماجستير في تكنولوجيا. المشرف الثاني. الدكتور يونيفة مفتاح عارف، ماجستير في تكنولوجيا

الكلمات المفتاحية: جزيرة الحرارة الحضرية، درجة حرارة سطح الأرض، دعم الخدار المتجهات

جزيرة الحرارة الحضرية هي حالة تكون فيها درجة الحرارة في المناطق الحضرية أعلى بكثير منها في المناطق الريفية المحيطة. وهذا يخلق مؤشراً من عدم الراحة يتسم بارتفاع درجات الحرارة العالمية وتغير المناخ والمخاطر الصحية لسكان المدينة. وتثير هذه الظاهرة قلقاً هو تغير عدد كبير من الأسطح الطبيعية إلى أسطح UHI عالمياً بسبب تأثيرها الواسع على البيئة. العامل الرئيسي في حدوث ظاهرة غير منفذة، مما يؤدي إلى تغييرات كبيرة في استخدام الأراضي والغطاء في المناطق الحضرية والريفية. للتغلب على هذه المشكلة، سيقوم Support Vector Regression، يعتمد على بيانات الاستشعار عن بعد باستخدام طريقة UHI هذا البحث بتصميم نظام تنبؤ بناء على بيانات الاستشعار عن بعد عبر الأقمار الصناعية. تم الحصول على البيانات UHI في التنبؤ SVR بهدف معرفة أداء طريقة Landsat 8 OLI/TIRSC2 L1 باستخدام 3 أقمار صناعية، وهي Google Earth Engine المستخدمة من موقع الذي يحتوي على 4850 نقطة بيانات NASA SRTM Digital Elevation 30m و Sentinel-2 Level-2A و عينة مع 7 سمات. تضمن هذا البحث 3 خطوات رئيسية. الخطوة الأولى هي جمع البيانات. هناك 3 أقمار صناعية سيتم استخدامها وحساب الميزات التي سيتم استخدامها. بعد Cloud Masking لاحقاً في الأبحاث. الخطوة التالية هي إعداد البيانات التي تتضمن ثم تقسيمها إلى ثلاثة سيناريوهات رئيسية بنسب مختلفة، وهي 90% بيانات Z-Score ذلك سيتم تسوية البيانات أولاً باستخدام : التدريب: 10% بيانات الاختبار، 80% بيانات التدريب: 20% بيانات الاختبار، وبيانات الاختبار، و70% بيانات التدريب مع ضبط مختلف للمعلمات Support Vector Machine بيانات الاختبار. بعد ذلك، يقارن هذا البحث ثلاث نواة 30% لبيان مدى جودة النموذج من (R2) الفائقة. ولتقييم أداء الطريقة في إجراء التنبؤات يتم إجراء القياسات باستخدام معامل التحديد، لإعطاء فكرة عن مدى حجم الخطأ يكون خطأ التنبؤ في شكل مربع (MSE) خلال المتغيرات المستخدمة، متوسط مربع الخطأ لحساب متوسط الخطأ النسبي في شكل نسبة مئوية. تظهر نتائج التحليل أنه (MAPE) وقيمة متوسط النسبة المئوية للخطأ المطلق يتم الحصول على أفضل أداء بناءً على $\epsilon=1$ و $C=10$ في السيناريو 3 بنسبة 90:10 مع نواة خطية وقيم المعلمات الفائقة MAPE. متوسط القيمة والانحراف المعياري لـ

BAB I

PENDAHULUAN

1.1 Latar Belakang

Sebagai tempat aktivitas manusia yang mendasar, kota merupakan pembawa utama pembangunan ekonomi dan teknis modern. Masa depan umat manusia bergantung pada pembangunan kota yang berkelanjutan (Sun et al., 2019). Dalam beberapa dekade terakhir, dunia telah mengalami urbanisasi berskala besar dan cepat (Furuya et al., 2023). Selama dekade berikutnya, dunia akan semakin mengalami urbanisasi, dengan tingkat urbanisasi meningkat dari 56,2% pada tahun 2020 menjadi 60,4% pada tahun 2030 (Unite Nation, 2020). Dan delapan puluh persen populasi perkotaan dunia diperkirakan pada tahun 2025 akan tinggal di pusat perkotaan di negara-negara berkembang (Kusumadewi et al., 2023). Untuk memenUHI laju urbanisasi yang pesat, sejumlah besar permukaan alami telah digantikan oleh permukaan kedap air, sehingga mendorong perubahan penggunaan lahan dan tutupan lahan yang signifikan di wilayah perkotaan dan perdesaan (Unal Cilek & Cilek, 2021).

Kota Malang dikenal sebagai kota pendidikan karena menjadi salah satu pusat tujuan pendidikan di Provinsi Jawa Timur. Melalui slogan Tri Bina Citta, pendidikan menjadi salah satu rencana pembangunan kota (Nouval et al., 2023). Seiring berkembangnya pusat-pusat kegiatan pendidikan tentunya arus urbanisasi di Kota Malang juga meningkat. Setiap tahunnya peningkatan urbanisasi terjadi sebesar puluhan ribu mahasiswa memadati Kota Malang dan memberikan dampak

negatif pada lingkungan, yaitu: meningkatnya produksi gas CO₂, dan perubahan tutupan lahan menjadi lahan terbangun (Syamdermawan & Kurniawan, 2012).

Perubahan penggunaan lahan dan tutupan lahan merupakan salah satu faktor penting yang menyebabkan pemanasan global, yang diprediksi menyebabkan pemanasan permukaan. Di antara berbagai masalah lingkungan, UHI telah menjadi perhatian karena perannya yang negatif terhadap kelayakhunian perkotaan dan pembangunan berkelanjutan (Ren et al., 2021). Efek UHI, yang mengacu pada fenomena bahwa kota mengalami suhu yang lebih tinggi dibandingkan dengan daerah pinggiran merupakan salah satu dampak paling signifikan dari aktivitas manusia terhadap iklim lokal yang diwakili oleh urbanisasi (Furuya et al., 2023). Konsekuensi utama dari UHI termasuk memburuknya pencemaran lingkungan, konsumsi sumber daya yang semakin meningkat, dan ancaman terhadap kesehatan manusia (Y. Zhang et al., 2021).

Pada surah Ar-Rum : 41 Allah SWT berfirman :

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

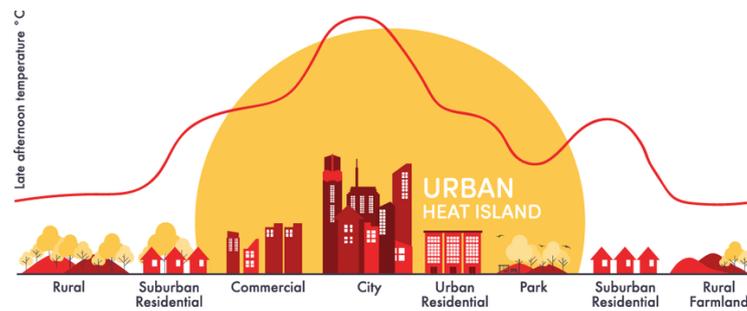
“Telah tampak kerusakan di darat dan di laut disebabkan karena perbuatan tangan manusia, Allah menghendaki agar mereka merasakan sebagian dari (akibat) perbuatan mereka agar mereka kembali (ke jalan yang benar)” (QS. Ar-Rum : 41).

Menurut Zubdatut Tafsir Min Fathil Qadir, البحر merupakan daerah pemukiman yang berada di atas laut atau sungai. Sedangkan البر adalah daerah pemukiman yang berada di bawah laut atau sungai. Allah menjelaskan bahwa kemusyrikan dan kemaksiatan adalah sebab timbulnya kerusakan di alam semesta. Kerusakan ini dapat berupa kekeringan, paceklik, ketakutan yang merajalela,

barang-barang yang tidak laku, sulitnya mencari penghidupan, maraknya perampokan dan kezaliman, dan lain sebagainya. Yakni agar mereka merasakan akibat dari sebagian perbuatan mereka sehingga menjaUHI kemaksiatan mereka dan bertaubat kepada Allah.

Berdasarkan tafsir di atas dan melihat fenomena yang ada, Suhu yang tinggi di pulau-pulau panas dapat memberikan dampak buruk bagi kesehatan individu, seperti suhu panas, dehidrasi, dan gangguan pernapasan. Sebagai contoh, selama musim panas 2003 di Eropa, lebih dari 70.000 kematian disebabkan oleh gelombang panas. Tidak hanya gelombang panas, banyak faktor yang memengarUHI UHI, termasuk bentuk perkotaan, perubahan LULC (*Land Use and Land Cover*), perubahan iklim, dan emisi panas antropogenik (Liu et al., 2021). Di antara faktor-faktor tersebut, perubahan LULC secara langsung berhubungan dengan proses ekologi, seperti penyerapan radiasi matahari di permukaan dan evapotranspirasi (Fitria et al., 2019) sehingga memengarUHI perpindahan panas di permukaan dan menentukan intensitas UHI. Variasi pola lanskap mencerminkan bagaimana manusia mengubah penggunaan lahan (Liu et al., 2021). Salah satu contoh nyata lainnya, yaitu di Kota Malang. Data BPS tahun 2021 menyebutkan pertumbuhan penduduk di Kota Malang mencapai 0,69% per tahun dengan tingkat kepadatan 9.582 jiwa/Km². Dan dalam kurun waktu 5 tahun terakhir (2015-2020), Kota Malang teridentifikasi mengalami peningkatan intensitas UHI dengan semakin naiknya suhu permukaan tanah yang mencapai 1.7C (Kusumadewi et al., 2023). Akibatnya suhu di Kota Malang mengalami kenaikan yang signifikan. Kondisi ini menyebabkan menurunnya kenyamanan termal di Kota Malang.

Land Surface Temperature (LST) merupakan salah satu indikator terpenting dari UHI permukaan (Tian et al., 2023). Berdasarkan data penginderaan jauh historis, banyak peneliti telah menyelidiki hubungan keterkaitan antara LULC dan LST dari pola lanskap dan telah mencapai pemahaman yang sama. Secara umum, LST tertinggi terutama terkonsentrasi di area terbangun (Wang et al., 2022), sementara danau dan hutan besar memiliki LST yang lebih rendah karena efek pendinginan (Zheng et al., 2023). Berikut ini adalah ilustrasi mengenai Efek UHI berdasarkan nilai LST.



Gambar 1. 1 Efek UHI berdasarkan LST (Sumber : Fuladlu et al., 2018)

Berdasarkan Gambar 1.1, penggunaan lahan dan tutupan lahan memiliki pengaruh yang besar terhadap LST sehingga mengakibatkan terbentuklah pulau panas perkotaan (UHI). Fenomena ini ditandai dengan suhu yang lebih tinggi di daerah perkotaan dibandingkan dengan daerah lainnya dan dapat berdampak negatif terhadap ekosistem, iklim lokal, sistem hidrologi, keanekaragaman hayati dan kesehatan manusia. Oleh karena itu, dapat disimpulkan bahwa UHI sangat berkaitan erat dengan LST. Maka LST dapat dinyatakan sebagai parameter kunci untuk mewakili UHI (Furuya et al., 2023).

Untuk memprediksi UHI, dapat memanfaatkan data penginderaan jauh, melalui citra satelit berdasarkan citra suhu permukaan tanah. Citra suhu permukaan

tanah didapatkan melalui sensor termal inframerah (TIR) yang nantinya akan dijadikan variable LST sebagai pengukur langsung indicator UHI (Mathew et al., 2019).

Penelitian terbaru mengenai deteksi tren pertumbuhan UHI *spatiotemporal* di kota Tehran dengan menggunakan dua metode yaitu *Artificial Neural Network* (ANN) dan *Support Vector Regression* (SVR). Hasil telah menunjukkan hubungan yang besar antara LST yang disimulasikan dan yang sebenarnya yang diambil dari pita termal gambar satelit pada tahun 2007 ($r = 0,843$ untuk metode ANN dan $r = 0,856$ untuk metode SVR).

Sebelumnya juga sudah ada penelitian mengenai prediksi Kurs Jual Rupiah terhadap Dollar Amerika Serikat, dilakukan dengan menggunakan metode *Support Vector Regression* (SVR) dengan jumlah data training sebanyak 344 data. Hasil dari penelitian ini menunjukkan bahwa metode SVR berhasil menghasilkan prediksi dengan akurasi yang cukup baik, baik dengan menggunakan kernel linier maupun kernel *Polynomial*. Pada kernel linier, akurasi prediksi mencapai 100% dengan tingkat kesalahan yang sangat rendah, yaitu *Mean Absolute Percentage Error* (MAPE) sebesar 0,3757%. Sementara pada fungsi kernel *Polynomial*, juga didapatkan akurasi 100% dengan tingkat kesalahan yang cukup rendah, yaitu MAPE sebesar 0,4477%. Dapat disimpulkan, bahwa tingkat kesalahan fungsi kernel linier lebih rendah dibandingkan dengan tingkat kesalahan pada fungsi kernel *Polynomial*.

Studi-studi ini menunjukkan bahwa metode SVR, terutama dengan pemilihan kernel yang tepat, dapat memberikan prediksi yang akurat dan efektif dalam

berbagai konteks prediksi di bidang keuangan, seperti prediksi return saham syariah dan prediksi harga batu bara. Selain itu, penelitian terbaru pada prediksi Kurs Jual Rupiah terhadap Dollar Amerika Serikat juga menegaskan efektivitas metode SVR dalam menghasilkan prediksi yang sangat akurat dan dapat diandalkan.

Berdasarkan permasalahan diatas maka diajukan penelitian dengan judul *Prediksi Urban Heat Island Berdasarkan Penginderaan Jauh Satelit Menggunakan Metode Support Vector Regresion(SVR)*. Hasil penelitian ini harapannya mampu memberikan hasil berupa prediksi *Urban Heat Island* yang mampu membantu dalam mengatasi permasalahan Fenomena *Urban Heat Island* kedepannya.

1.2 Rumusan Masalah

Berdasarkan pada latar belakang yang telah dijelaskan sebelumnya, rumusan masalah pada penelitian ini adalah bagaimana ukuran evaluasi performa model *Support Vector Regression (SVR)* untuk menentukan prediksi *Urban Heat Island* di Kota Malang berdasarkan Faktor Penentu *Urban Heat Island* ?

1.3 Batasan Masalah

Batasan masalah yang digunakan dalam penelitian ini adalah :

1. Data yang digunakan berdasarkan penginderaan jauh satelit melalui *Google Earth Engine*.
2. Batas administrasi yang digunakan adalah Kota Malang
3. Evaluasi performa menggunakan R^2 , MAPE, dan MSE

1.4 Tujuan Penelitian

Berdasarkan masalah yang telah dijelaskan, maka tujuan dari penelitian adalah Mengukur *error prediction* model prediksi menggunakan metode *Support Vector Regresion* (SVR) dalam memprediksi *Urban Heat Island* di Kota Malang berdasarkan Faktor Penentu *Urban Heat Island*

1.5 Manfaat Penelitian

Berikut beberapa manfaat yang diharapkan dari prediksi *Urban Heat Island* di Kota Malang, baik bagi peneliti maupun pembaca:

1. Memprediksi *Urban Heat Island* di Kota Malang dengan menggunakan metode *Support Vector Regresion* dapat digunakan sebagai acuan dalam pengambilan keputusan terkait kebijakan dan tindakan mengenai Fenomena *Urban Heat Island*.
2. Dapat menjadi bahan referensi bagi penelitian berikutnya mengenai prediksi *Urban Heat Island* di daerah lain atau pendekatan lainnya.

BAB II

STUDI PUSTAKA

Bab ini menjelaskan mengenai penelitian terdahulu, tinjauan pustaka, dan dasar teori yang digunakan untuk mendukung penelitian ini.

2.1 Penelitian Terdahulu

Yumna & Muhamad (2020), dalam penelitiannya telah mengimplementasikan metode CA untuk deteksi tren pertumbuhan UHI *spatiotemporal* Tehran berdasarkan parameter penyebaran perkotaan (seperti Jarak ke jalan terdekat, *Model Elevation Digital*, Kemiringan dan Rasio Aspek). Penelitian ini menggunakan dua metode yaitu *Artificial Neural Network* (ANN) dan *Support Vector Regression* (SVR). Hasil telah menunjukkan hubungan yang besar antara LST yang disimulasikan dan yang sebenarnya yang diambil dari pita termal gambar satelit pada tahun 2007 ($r = 0,843$ untuk metode ANN dan $r = 0,856$ untuk metode SVR). Meskipun SVR menyebabkan hasil yang lebih baik, metode ini jauh lebih memakan waktu daripada metode ANN, terutama ketika jumlah piksel pelatihan meningkat.

Penelitian yang telah dilakukan oleh J. Li et al., 2021 telah membangun model statistik UHI berdasarkan suhu udara dan suhu permukaan perkotaan. Hasil menunjukkan bahwa pendekatan yang diusulkan memberikan hasil pemodelan AUHI yang memuaskan untuk lokasi dengan tingkat urbanisasi paling rendah. Hasil terbaik diperoleh dengan model regresi linier sederhana dengan prosedur iteratif untuk meminimalkan *Mean Absolute Gross Error* (MAGE). MAGE terendah untuk

UHI yang dimodelkan adalah 1,18 °C dengan 69% variasi dijelaskan. Hasil menunjukkan kecocokan model yang memuaskan terutama pada lokasi dengan urbanisasi rendah.

Penelitian Henrique et al., 2018 menggunakan teknik pembelajaran mesin yang disebut *Support Vector Regression* (SVR) untuk memprediksi harga saham untuk kapitalisasi besar dan kecil dan di tiga pasar yang berbeda, menggunakan harga dengan frekuensi harian dan hingga menit. Hasil menunjukkan bahwa SVR memiliki kekuatan prediksi, terutama saat menggunakan strategi pembaruan model secara berkala. Juga terdapat hasil indikatif dari peningkatan presisi prediksi selama periode volatilitas rendah.

Riset yang telah dilakukan oleh Putri dkk., 2023 yaitu memprediksi nilai tukar dolar Amerika terhadap rupiah dengan menggunakan metode SVR-GA (*Support Vector Regression-Genetic Algorithm*). Hasil penelitian menunjukkan bahwa SVR-GA memiliki hasil optimasi yang lebih baik berdasarkan nilai kebaikan model.

Kemudian riset oleh (Lestari et al., 2021) memprediksi penurunan jumlah penderita pandemic COVID-19 dengan menggunakan metode *Support Vector Regression* (SVR) dengan Kernel RBF, Sigmoid, *Polynomial*. Hasil penelitian menunjukkan bahwa metode SVR dengan kernel RBF memiliki performa prediksi yang lebih baik dibandingkan dengan kernel lainnya.

Tabel 2. 1 Tabel Penelitian Sebelumnya

No	Judul	Hasil	Persamaan	Perbedaan
1.	Combining Landsat 8 and Sentinel-2 Data in Google Earth Engine to Derive Higher Resolution Land Surface Temperature Maps in Urban Environment (2022)	R^2 tertinggi didapatkan oleh model yang menggabungkan citra Landsat dan Sentinel yaitu 0,96	Analisis <i>Urban Heat Island</i> menggunakan satelit Landsat dan sentinel	Menggunakan metode regresi linear
2.	Statistical Modeling of <i>Urban Heat Island</i> Intensity in Warsaw, Poland Using Simultaneous Air and Surface Temperature Observations (2020)	Selama sepuluh tahun , warsaw mengalami kenaikan UHI. AUHI dan SUHI memiliki korelasi yang kuat.	Analisis Urban Heat Island menggunakan suhu udara dan permukaan	Penggunaan citra satelit MODIS
3.	Machine Learning Techniques to Map the Impact of <i>Urban Heat Island</i> : Investigating the City of Jeddah (2023)	Wilayah perkotaan bertambah 80%, UHI meningkat	Penggunaan variable NDVI, NDBI, NDWI dan LST untuk memprediksi UHI	Metode yang digunakan OLR
4.	A machine learning approach for mapping surface <i>Urban Heat Island</i> using environmental and socioeconomic variables: a case study in a medium-sized Brazilian city (2023)	Evaluasi SVR : - $R^2 = 0,98$ - MAE = 1.72 - RMSE= 2.04	Memprediksi UHI menggunakan variabel NDVI, NDBI dan LST dan menggunakan satelit Landsat-8 dan Sentinel-2	Menggunakan Weka Algorithm
5.	Prediction of land surface temperature for <i>Urban Heat Island</i> assessment surface in Chandigarh city using support vector regression model (2019)	1. Evaluasi SVR: - MAE = 0.52 - MAPE = 0.18 - MSE = 0.394 2. SVR lebih baik dari ANN	Memprediksi UHI menggunakan variabel elevasi dan LST dengan menggunakan metode SVR	Menggunakan variabel lainnya seperti kepadatan jalan dan EVI dengan menggunakan metode SVR
6.	Stock price prediction using support vector regression on daily and up to the minute prices (2019)	Hasil perbandingan model SVR lebih baik dari pada RLB-OLS	Penggunaan metode support vector regression	Prediksi Harga saham
7.	Analisis Support Vector Regression (SVR) Dalam Memprediksi Kurs Rupiah Terhadap Dollar Amerika Serikat (2023)	Hasil evaluasi : Metode SVR-GA lebih baik dari SVR-PSO	Penggunaan metode support vector regression	Memprediksi Kurs Rupiah Terhadap Dollar Amerika Serikat

2.2 Prediksi

Istilah prediksi dalam Kamus Besar Bahasa Indonesia (KBBI) adalah ramalan; prakiraan. Secara etimologis istilah prediksi berasal dari bahasa *Latin prae-*, *before*, and *dicere*, *to say*. Prediksi atau *forecast* adalah pernyataan tentang peristiwa masa depan berdasarkan data masa lalu untuk memperkirakan nilai sebuah variabel atau kumpulan variabel di masa yang akan datang. Dua kategori utama metode peramalan adalah kualitatif dan kuantitatif. Metode kuantitatif bergantung pada informasi masa lalu yang dikuantitatifkan dalam bentuk data numerik. Metode kuantitatif bergantung pada matematika dan statistika untuk membuat ramalan. Dua model peramalan kuantitatif adalah model deret waktu (*time series*) dan model regresi. Menurut Heizer & Render, 2020 Prediksi atau peramalan merupakan suatu ilmu yang berfokus pada memperkirakan kejadian atau kondisi di masa depan dengan menggunakan model matematika atau melalui penilaian subyektif berdasarkan data historis yang tersedia. Proses ini melibatkan penggunaan metode ilmiah untuk mengkaji data masa lalu yang relevan guna memberikan gambaran tentang apa yang mungkin terjadi di masa depan. Peramalan bertujuan untuk menyediakan informasi yang berguna bagi pengambilan keputusan dan perencanaan strategis. Metode peramalan dapat diterapkan secara kuantitatif melalui perhitungan matematis atau secara kualitatif (Nurmahaludin, 2014).

2.3 *Urban Heat Island* (UHI)

UHI adalah fenomena peningkatan suhu di wilayah perkotaan yang disebabkan oleh aktivitas manusia, struktur bangunan, dan permukaan yang menyerap dan memancarkan panas lebih tinggi dibandingkan dengan daerah

sekitarnya. Beberapa faktor yang berkontribusi terhadap UHI meliputi penggunaan material bangunan yang menyerap panas, rendahnya vegetasi, dan intensitas aktivitas manusia (Smith et al., 2021). Penelitian terbaru menyoroti perlunya mengatasi UHI melalui perencanaan perkotaan yang lebih berkelanjutan, penghijauan kota, dan adaptasi infrastruktur perkotaan untuk mengurangi efek pemanasan (Z. Zhang et al., 2021). Upaya ini bertujuan untuk menciptakan lingkungan perkotaan yang lebih nyaman dan berkelanjutan dalam menghadapi perubahan iklim global.

2.3.1 Pengertian UHI

Urban Heat Island adalah suatu kondisi klimatologi dimana daerah pusat kota memiliki suhu yang lebih tinggi dari daerah pinggir kota (Nainggolan et al., 2020). Faktor utama terbentuknya UHI adalah sebagian vegetasi digantikan oleh aspal dan beton untuk jalan, bangunan, dan infrastruktur lain yang diperlukan untuk mengakomodasi kebutuhan dan pertumbuhan populasi manusia. Permukaan yang tergantikan tersebut lebih banyak menyerap panas matahari dan juga lebih banyak memantulkannya, sehingga mengakibatkan suhu permukaan naik.

Wilayah urban akan cenderung mengalami peningkatan suhu dibandingkan dengan wilayah sub-urban. Khususnya, setelah matahari terbit suhu udara di daerah rural akan menyamai suhu udara di wilayah urban. Hal ini disebabkan wilayah urban memiliki tutupan bayangan oleh bangunan tinggi (*urban canopy*) dan melemahnya sinar matahari karena lapisan polusi yang terangkat yang mengakibatkan suhu udara meningkat lebih lambat pada pagi hari. Beberapa hasil kajian UHI teridentifikasi bahwa perbedaan suhu udara perkotaan lebih tinggi 0.02-

1 oc dibandingkan dengan daerah di sekitarnya pada daerah tropis (Stewart et al., 2021). Penelitian tentang UHI di beberapa kota besar di Indonesia dengan data satelit menunjukkan adanya perubahan temperatur yang merupakan salah satu indikasi adanya perubahan iklim, Hal ini ada hubungannya dengan perubahan lahan yang terjadi akibat urbanisasi. Di Bandung teramati perluasan UHI (daerah dengan suhu tinggi 30-35 0C yang terletak pada kawasan terbangun di pusat kota per tahun kira-kira 12606 ha atau 4.47%, di Semarang 12174 ha atau 8.4%, di Surabaya 1512 ha atau 4.8%. Pertumbuhan kawasan terbangun di Bandung per tahun kurang lebih 1029 ha (0.36%), Semarang 1200 ha (0.83%), dan Surabaya 531.28 ha (1.69%) (Munawaroh, 2015)

2.3.2 Identifikasi Estimasi Fenomena *Urban Heat Island*

Penelitian sebelumnya telah banyak menggunakan nilai UHI untuk menilai efek UHI secara kuantitatif. Banyak penelitian yang telah dilakukan untuk memetakan dan menilai fenomena UHI dengan menggunakan algoritma *machine learning* (ML) (Hosseinalizadeh et al., 2019). Nilai UHI dihitung berdasarkan LST untuk area mana pun yang intensitas UHI-nya dapat diperkirakan. Nilai LST yang lebih tinggi mengindikasikan intensitas UHI yang tinggi dan sebaliknya (Al Kafy et al., 2021).

Penelitian sebelumnya, nilai UHI telah digunakan untuk memperkirakan efek UHI, namun penerapannya di daerah iklim gurun yang panas masih terbatas. Sebagai contoh, Naim dan Al Kafy mempelajari hubungan antara UHI dan LUALC di Chattogram City, Bangladesh. Untuk menghitung UHI,

$$UHI = \frac{T_s + T_m}{SD} \quad (2.3)$$

Keterangan :

Ts = LST

Tm = rata-rata LST

SD = deviasi standar area.

Dalam penelitian Addas, 2023, perhitungan UHI berdasarkan LST dan mengekstrak data dari citra Landsat dengan menunjukkan UHI berdasarkan indeks penginderaan jauh dan hubungannya dengan indeks biofisik.

2.3.3 Faktor-faktor yang mempengaruhi UHI

Di perkotaan, sebaran spasial LST tidak homogen namun menghadirkan heterogenitas spasial. Heterogenitas spasial LST di suatu kota biasanya bervariasi karena variasi sifat permukaan (F. Li et al., 2023). Dalam literatur sebelumnya, telah diketahui bahwa komposisi lanskap, seperti permukaan kedap air, badan air, dan ruang hijau (tutupan vegetasi), sangat menentukan distribusi spasial LST di perkotaan (Liu et al., 2021). Oleh karena itu, penting untuk memasukkan SEV (*Satellite-derived Environmental Variables*) sebagai faktor independen yang memberikan informasi mengenai berbagai aspek lingkungan di suatu wilayah dan dapat digunakan untuk analisis berbagai fenomena, termasuk fenomena *Urban Heat Island*. Secara umum, SEV dapat dikategorikan menjadi 4 kategori, yaitu :

a. Permukaan Kedap Air

Permukaan Kedap Air merupakan kategori yang berkaitan dengan tutupan lahan, seperti jenis tutupan tanah (contohnya hutan, lahan pertanian, dan perkotaan) dan karakteristik fisik permukaan tanah (seperti tekstur tanah dan elevasi). Data ini

diperoleh melalui citra satelit, dengan menggunakan satelit seperti Landsat dan Sentinel-2, yang memiliki berbagai band-band yang mendukung, seperti *Red*, *Green*, *Blue*, *NIR*, dan *SWIR*. Contoh variabel yang sering digunakan adalah NDBI dan NDBaI. Kedua variabel tersebut digunakan untuk menentukan dampak permukaan kedap air terhadap intensitas UHI. Berdasarkan penelitian sebelumnya oleh (Addas, 2023), didapatkan kesimpulan bahwa daerah yang memiliki proporsi permukaan kedap air yang tinggi maka nilai intensitas UHI pada daerah tersebut juga tinggi (Shi et al., 2021).

b. Vegetasi

Vegetasi merupakan kategori yang berkaitan dengan keadaan vegetasi, seperti NDVI (*Normalized Difference Vegetation Index*), SAVI, luas tutupan vegetasi, dan parameter-parameter lainnya. Sejumlah satelit seperti MODIS, Landsat, dan Sentinel-2 digunakan untuk mengumpulkan data ini, dengan penggunaan *band* seperti *NIR* dan *Red*.

Parameter ini telah banyak digunakan pada penelitian sebelumnya untuk mengamati pengaruh tutupan vegetasi terhadap intensitas UHI. Telah terbukti bahwa intensitas UHI yang rendah terjadi di tempat dengan tutupan vegetasi yang tinggi dan sebaliknya (J. Li et al., 2021). Penelitian terbaru juga menemukan bahwa tutupan vegetasi mempunyai efek pendinginan yang signifikan di wilayah perkotaan (Sannigrahi et al., 2018). Oleh karena itu, indeks vegetasi dapat menjadi parameter yang sangat membantu untuk memahami intensitas UHI di suatu wilayah tertentu (X. Zhang et al., 2017).

c. Air

Kategori air melibatkan pemantauan variabel lingkungan yang berkaitan dengan kualitas dan kuantitas air di suatu daerah. Contoh variabel yang sering digunakan adalah NDWI, MNDWI, suhu permukaan air, konsentrasi sedimen, dan tingkat keasaman. Satelit yang sering digunakan untuk parameter ini adalah Landsat, Modis, ERA5, dan Sentinel-2. Pada penelitian sebelumnya menunjukkan bahwa badan air atau ruang biru secara signifikan mengurangi suhu. Dengan demikian, Perairan atau ruang biru juga memiliki dampak yang signifikan terhadap intensitas UHI (Odindi et al., 2015).

d. Panas

Kategori panas melibatkan pemantauan variabel lingkungan yang berhubungan dengan suhu atmosfer, seperti suhu permukaan tanah dan suhu udara. Dalam hal ini, satelit yang sering digunakan adalah satelit seperti Landsat dan MODIS. Contohnya pada satelit Landsat, memiliki band termal yang digunakan dapat digunakan untuk mengukur suhu permukaan tanah (LST).

LST adalah isu yang memberikan kontribusi terkuat yang mempengaruhi intensitas UHI (Bokaie et al., 2016). Hal ini sebagian besar dipengaruhi oleh konfigurasi dan komposisi permukaan tanah di suatu wilayah. Misalnya, sifat kedap air pada permukaan berhubungan positif dengan LST, sedangkan vegetasi dan badan air berhubungan negatif dengan LST (X. Zhang et al., 2017). Dengan demikian, perubahan komposisi biofisik sangat mempengaruhi LST (X. Zhang et al., 2017). Kawasan dengan LST tinggi di perkotaan ditandai dengan intensitas UHI

yang tinggi (Mathew et al., 2016). Dengan demikian, LST telah dianggap sebagai faktor dominan yang mempengaruhi intensitas UHI.

Selain suhu permukaan tanah, suhu udara juga sering digunakan untuk memberikan informasi tentang perubahan iklim, pola suhu, dan distribusi energi termal di suatu wilayah.

2.4 Support Vector Regression (SVR)

Support Vector Machine adalah salah satu model pembelajaran untuk klasifikasi dan regresi. Gabungan *Vector Machine* untuk regresi secara khusus dikatakan sebagai *Support Vector Regression*. *Support Vector Regression* dapat berupa linier atau *non-linier* menggunakan fungsi kernel masing-masing (Kavitha et al., 2017). Namun, tidak seperti klasifikasi SVM yang menghasilkan output biner (yaitu label kelas), SVR menangani masalah regresi yang memungkinkan estimasi fungsi bernilai nyata (misalnya, skor kontinu dalam skala klinis). SVR menerapkan ide dasar dari SVM, yaitu mesin kernel jarang yang melakukan klasifikasi menggunakan *hyperplane* yang didefinisikan oleh beberapa vektor pendukung. Hasilnya, optimasi dalam SVR direpresentasikan dalam bentuk *support vector* (sekumpulan kecil sampel data training), dimana solusi optimasi tidak bergantung pada dimensi data input, tetapi hanya bergantung pada jumlah *support vector*. SVR memiliki kelebihan tambahan jika dibandingkan dengan metode regresi lainnya. Dengan penggunaan kernel, SVR dapat memberikan cara yang efisien untuk menangani masalah regresi nonlinier dengan memproyeksikan fitur asli ke dalam ruang kernel di mana data dapat didiskriminasikan secara linier (Orrù et al., 2012).

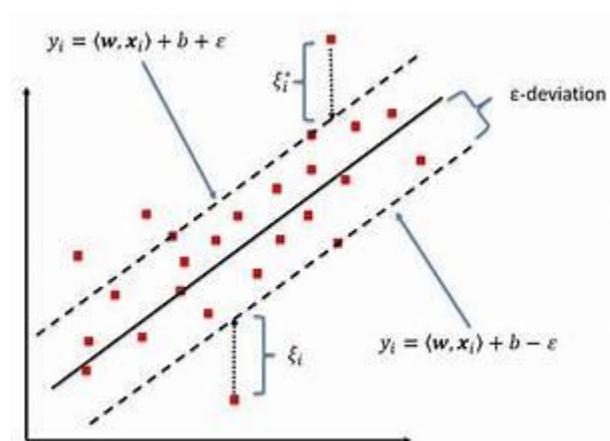
SVR dikembangkan oleh Vapnik dan rekan-rekannya dengan memperluas algoritma SVM. Dalam pembelajaran mesin, SVM terkenal dengan kinerjanya yang baik untuk menangani data berdimensi tinggi. SVM didasarkan pada kerangka teori pembelajaran statistik (teori Vapnik-Chervonenkis [VC]) dan menawarkan pendekatan yang berprinsip pada masalah pembelajaran mesin karena landasan matematika ini. Ide dasar SVM awalnya diusulkan pada tahun 60-an oleh Vapnik dkk. (1963, 1964), yang kemudian algoritmanya banyak dikembangkan pada dekade-dekade berikutnya. Keseluruhan sistem SVM secara resmi dipublikasikan pada tahun 1992 untuk klasifikasi dan kemudian untuk regresi (dikenal sebagai model ε -SVR).

Dalam klasifikasi SVM, setiap sampel yang diberi label diperlakukan sebagai titik data dalam ruang fitur multidimensi, dan *hyperplane* dalam ruang fitur ini dihitung untuk mengklasifikasikan sampel pelatihan sebanyak mungkin dengan benar. Sampel baru kemudian diklasifikasikan berdasarkan sisi *hyperplane* mana yang berada di ruang fitur multidimensi. Untuk menemukan *hyperplane* yang baik, pengoptimalan dilakukan dengan memaksimalkan margin antara vektor pendukung (yaitu, titik data yang paling dekat dengan *hyperplane*). Untuk regresi data, alih-alih menemukan *hyperplane* yang dapat memisahkan sampel pelatihan, SVR memperkenalkan fungsi *loss ε -insensitive* untuk menghitung *hyperplane* sedemikian rupa sehingga nilai respons yang diprediksi dari sampel pelatihan memiliki deviasi paling banyak ε dari nilai respons yang diamati (aktual). *Hyperplane* ditambah ε mendefinisikan sebuah tabung (atau pita) *ε -insensitive* untuk menghitung batas generalisasi untuk regresi. Optimasi dilakukan dengan

meminimalkan tabung ε -insensitif menjadi serata (sempit) mungkin sambil berisi sebagian besar sampel pelatihan. Dalam hal ini, *hyperplane* direpresentasikan dalam bentuk beberapa vektor pendukung, yaitu sampel pelatihan yang berada di luar batas ε -insensitive tube. Sebagai hasil dari pelatihan SVR, sebuah model regresi dipelajari untuk memprediksi keluaran respons untuk sampel baru.

Dalam penelitian ini *Support Vector Regression* (SVR) digunakan untuk memprediksi nilai variabel-variabel yang digunakan untuk memberikan nilai hasil prediksi yang baik berupa nilai aktual dan hasil prediksi yang dapat diminimalkan tingkat kesalahannya dalam prediksi.

Selanjutnya merupakan ilustrasi dari algoritma SVR merupakan pengujian yang ditujukan untuk mencari nilai terbaik dalam bentuk garis antara garis berupa *hyperplane* dan *boundary line* dapat dilihat pada Gambar 2.1 :



Gambar 2. 1 Matrix Support Vector Regression (Sumber :Bozkir et al., 2019)

Dari gambar 2.1 terdapat garis yang memisahkan antar dua garis yaitu kelas data yang atas dengan kelas yang bawah yang disebut dengan *Hyperplane*. *Hyperplane* garis yang digunakan untuk memisahkan dua kelas data dalam ruang multidimensional. Dalam konteks SVR, *hyperplane* berfungsi sebagai model

prediksi yang memisahkan data ke atas dan ke bawah dari *hyperplane* tersebut.

Berikut adalah rumus persamaannya :

$$y = (w x) + b \pm \epsilon \quad (2.3)$$

Keterangan:

Y = nilai prediksi

W = bobot

x = nilai variabel

b = nilai bias

ϵ = ϵ - deviation

Dari persamaan diatas, nilai y merupakan nilai prediksi yang ingin diprediksi oleh model, W (*Weight*) adalah koefisien yang mengukur pengaruh masing-masing variabel atau fitur terhadap prediksi, x adalah vektor yang berisi variabel atau fitur-fitur yang digunakan untuk membuat prediksi, dan b adalah nilai bias atau offset yang memungkinkan model untuk melakukan penyesuaian terhadap prediksi. *Hyperplane* ini berperan sebagai pemisah antara data di atas dan di bawahnya, memungkinkan model untuk melakukan prediksi berdasarkan variabel input dengan memanfaatkan bobot (W) dan bias (b) yang telah diatur selama proses pelatihan model. Dengan menggunakan rumus ini, model SVR dapat membangun model regresi yang akurat sesuai dengan data yang ada. Langkah selanjutnya yaitu menghitung nilai bias menggunakan rumus dibawah :

$$b = y_i - \sum_{j=1}^n a_j \times y_j \times K(x_i, x_j) \quad (2.4)$$

keterangan:

b = nilai bias.

y_i = target aktual untuk sampel pelatihan ke- i

a_j = nilai multiplikator Lagrange untuk vektor pendukung ke- j

y_j = target aktual untuk sampel pelatihan ke- j

$K(x_i, x_j)$ = hasil kernel antara sampel pelatihan ke- i dan ke- j

Persamaan 2.4 bertujuan untuk menghitung nilai bias dengan menggunakan koefisien Lagrange, nilai target dan kernel yang akan digunakan untuk melatih data training. Nilai b yang dihasilkan dari rumus ini akan membantu dalam memprediksi nilai target untuk data baru dengan menggunakan model SVR.

2.5 Fungsi Kernel

Kernel dalam SVR adalah fungsi matematika yang memetakan data menuju ruang dimensi yang lebih tinggi (disebut ruang fitur). Data menjadi lebih terpisah dan lebih mudah dipisahkan oleh *hyperplane*. Kernel membantu meningkatkan kinerja SVR dengan memungkinkan model untuk menangani kasus di mana data tidak dapat dipisahkan secara linier dalam ruang dimensi asli. Fungsi kernel memainkan peran penting dalam membentuk *hyperplane* yang lebih kompleks dan memungkinkan model untuk menangani kasus di mana pemisahan data tidak linier.

Terdapat beberapa kernel seperti linear, *Polynomial* dan radial basis function (RBF) yang berfungsi untuk menemukan *hyperplane*. Pada penelitian ini, menggunakan 3 jenis fungsi kernel yaitu sebagai berikut:

2.5.1 Kernel Linear

Kernel Linier digunakan ketika data dapat dipisahkan secara Linier, yaitu dapat dipisahkan menggunakan satu Garis. Ini adalah salah satu kernel yang paling umum digunakan. kernel linear terbukti menjadi fungsi terbaik ketika ada banyak fitur. Kernel linier lebih banyak digunakan untuk masalah klasifikasi teks karena sebagian besar masalah klasifikasi semacam ini dapat dipisahkan secara linier.

Fungsi kernel linier lebih cepat dibandingkan fungsi lainnya. Berikut adalah persamaanya :

$$k(x_i, x_j) = x_i \cdot x_j \quad (2.5)$$

Keterangan :

x_i = data training ke- i

x_j = data training ke- j

2.5.2 Kernel *Polynomial*

Kernel *Polynomial* akan melakukan pengambilan data yang ada dalam ruang berdimensi rendah ke dalam ruang berdimensi tinggi dengan menerapkan fungsi polinomial. Transformasi ini memiliki tujuan utama khususnya untuk data yang tidak dapat dipisahkan dengan baik dalam ruang berdimensi rendah, tetapi dapat menjadi lebih terpisah dalam ruang berdimensi tinggi.

$$k(x_i, x_j) = (x_i \cdot x_j)^d \quad d > 1, \quad (2.6)$$

Keterangan :

x_i = data training ke- i

x_j = data training ke- j

d = *degree* parameter

Dengan meningkatkan derajat polinomial (d), diharapkan dapat memproyeksikan data ke dalam ruang berdimensi yang lebih tinggi. tujuan utamanya untuk meningkatkan pemisahan antara kelas data. Namun, dengan meningkatkan derajat polinomial maka akan menyebabkan *overfitting* dalam model.

2.5.3 Kernel Radial Basis Function (RBF)

Radial Basis Function (RBF) adalah salah satu jenis fungsi kernel yang umum digunakan dalam SVM dan SVR karena memiliki kemampuan untuk menangani pemisahan data yang tidak linier

$$k(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (2.7)$$

Keterangan :

x_i = data training ke- i

x_j = data training ke- j

σ = standar deviasi

Berdasarkan rumus diatas, cara kerja kernel *Radial Basis Function* (RBF) adalah eksponensial dari kuadrat jarak Euclidean yang dinormalisasi antara dua vektor data untuk menghitung kemiripan atau kedekatan antara mereka dalam ruang fitur yang tinggi. Pada dasarnya, RBF kernel memberikan bobot pada vektor data berdasarkan seberapa mirip mereka dalam ruang fitur yang lebih tinggi, dan ini membantu dalam membentuk *hyperplane* yang dapat memisahkan data dengan baik, bahkan jika data tidak dapat dipisahkan secara linier dalam ruang asli.

2.6 Evaluasi Performa Model

Dalam penelitian ini untuk mengukur performa model prediksi menggunakan Koefisien determinasi (R^2), *Mean Absolute Percentage Error* (MAPE), dan *Mean Square Error* (MSE) sebagai evaluasi hasil akhir dari pengukuran metode prediksi.

2.6.1 Koefisien determinasi (R^2)

Koefisien determinasi (R^2) merupakan alat untuk mengukur besarnya keragaman variabel terikat (variabel dependent) yang mampu dijelaskan oleh

variabel bebas (variabel *independent*) dalam model. Nilai R^2 menunjukkan kebaikan model. Model yang baik memiliki nilai R^2 yang mendekati angka 1, sedangkan model yang tidak baik memiliki nilai R^2 mendekati angka 0. Kisaran dari nilai nilai R^2 yaitu dari 0 hingga 1 atau $0 \leq R^2 \leq 1$ (Evy Sulistianingsih, 2018). Nilai R^2 dihitung menggunakan persamaan 2.8 sebagai berikut :

$$R^2 = 1 - \frac{RSS}{TSS} \quad (2.8)$$

Keterangan :

RSS = Jumlah kuadrat residual

TSS = Jumlah total kuadrat

2.6.2 Mean Absolute Precentage Error (MAPE)

MAPE menghitung persentase penyimpangan antara data aktual dengan data prediksi. Semakin kecil nilai MAPE, peramalan yang dilakukan semakin baik (F. Zhang & O'Donnell, 2019). MAPE dihitung menggunakan persamaan 2.9 sebagai berikut :

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \times 100\% \quad (2.9)$$

Keterangan :

n = jumlah data

A_t = nilai aktual pada periode t

F_t = nilai prediksi pada periode t

Kriteria nilai MAPE untuk mengetahui standar minimal dari kinerja model prediksi disajikan pada Tabel 2.2 (F. Zhang & O'Donnell, 2019).

Tabel 2. 2 Kriteria Nilai MAPE

Nilai MAPE	Kriteria
<10%	Sangat Baik
10%-20%	Baik
20%-50%	Cukup
>50%	Buruk

2.6.3 Mean Square Error (MSE)

MSE menghitung menghitung rata-rata dari selisih kuadrat antara nilai prediksi dan nilai aktual.. Semakin kecil nilai MSE, peramalan yang dilakukan semakin baik. MSE dihitung menggunakan persamaan 2.10 sebagai berikut :

$$MSE = \frac{1}{n} \sum (A_t - F_t)^2 \quad (2.10)$$

Keterangan :

n = jumlah data

A_t = nilai aktual pada periode t

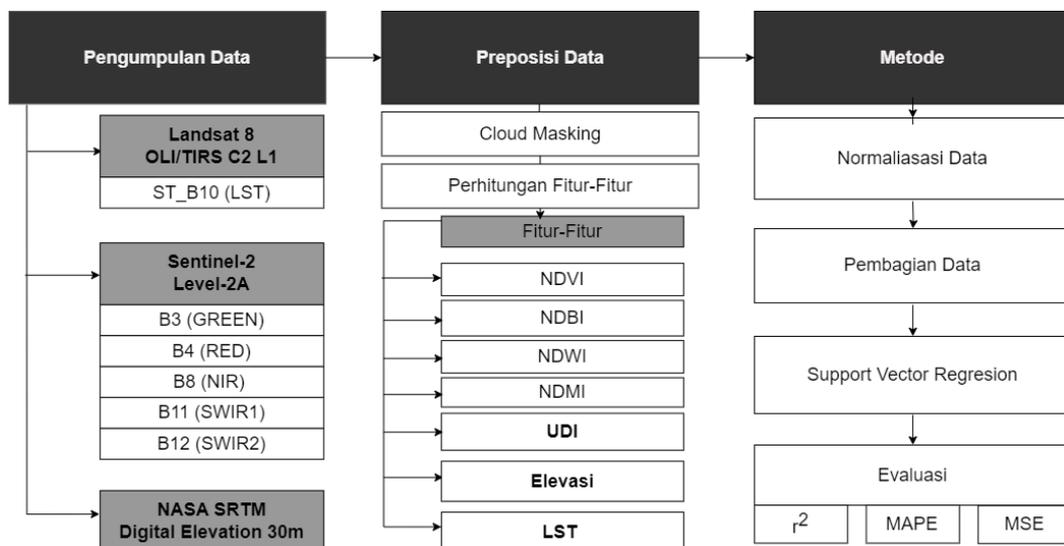
F_t = nilai prediksi pada periode t

BAB III

DESAIN DAN IMPLEMENTASI

3.1 Desain Penelitian

Dalam penelitian ini, serangkaian langkah telah dilakukan secara berurutan dan sistematis untuk memudahkan peneliti dalam menentukan langkah berikutnya, sehingga hasil yang diharapkan dapat tercapai.



Gambar 3. 1 Desain Penelitian yang digunakan

Berdasarkan desain penelitian pada Gambar 3.1. Data yang digunakan dalam penelitian ini adalah data penginderaan jauh satelit yang diambil dari *Web Google Earth Engine*. Citra satelit yang digunakan adalah citra Landsat, SRTM dan Sentinel. Dengan band yang digunakan adalah pada Tabel 3.1 :

Tabel 3. 1 Tabel Data Citra yang akan digunakan

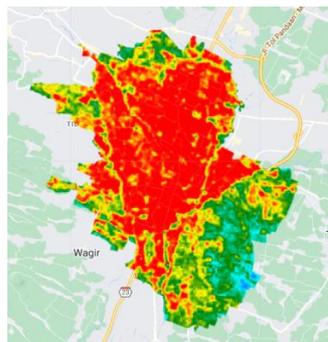
No	Citra	Band	Deskripsi	Scale	Offset
1.	Landsat-8 OLI/TIRS C2 L1	ST B10	LST	0.00341802	149
2.	Sentinel-2 Level-2A	B3	Green	0.0001	-
		B4	Red	0.0001	-
		B8	NIR	0.0001	-

No	Citra	Band	Deskripsi	Scale	Offset
		B11	SWIR 1	0.0001	-
		B12	SWIR 2	0.0001	-
3.	NASA SRTM Digital Elevation 30m	elevation	-	-	-

Dari band tersebut, akan didapatkan fitur-fitur yang nantinya akan digunakan melalui perhitungan terlebih dahulu. Sebelum dilakukan perhitungan, data harus di proses terlebih dahulu, untuk menghasilkan data yang baik dan sesuai.

3.1.1 Landsat-8

Landsat adalah serangkaian satelit observasi bumi yang dimiliki oleh NASA dan dioperasikan oleh *U.S. Geological Survey* (USGS). Landsat sering digunakan untuk memonitor suhu permukaan bumi menggunakan citra termal pada band 10. Dalam konteks *Land Surface Temperature* (LST) atau suhu permukaan tanah, band 10 seringkali menjadi fokus utama. Berikut ini merupakan citra Landsat 8 Band 10 yang digunakan untuk variable LST.



Gambar 3. 2 Citra Landsat 8 pada Band 10

Citra Landsat pada band 10 dapat memberikan informasi yang berharga tentang suhu permukaan tanah. Band ini beroperasi dalam rentang panjang gelombang termal dan biasanya digunakan untuk mengukur panas yang dipancarkan oleh permukaan bumi. Suhu yang diukur dalam band 10 dapat

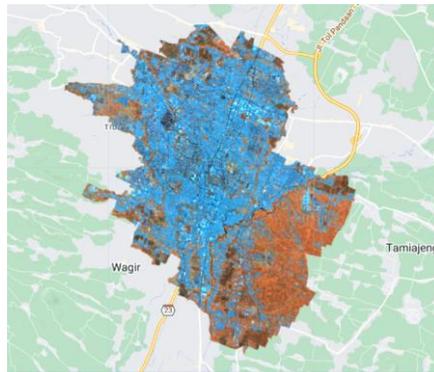
digunakan untuk analisis suhu permukaan, termasuk identifikasi *Urban Heat Island* (UHI) di area perkotaan.

Keuntungan dari citra Landsat pada band 10 adalah kemampuannya untuk menyediakan data suhu permukaan dengan resolusi spasial yang cukup baik. Data ini dapat digunakan untuk pemantauan suhu harian atau perubahan suhu jangka panjang di suatu wilayah. Sebelum analisis, data citra dapat di-preparation dengan mengkalibrasi nilai-nilai piksel, dan penggunaan skala sesuai dengan kebutuhan analisis spesifik. Untuk data yang diambil dari citra Landsat-8 untuk band ST B10 dikalikan dengan ukuran skala yang sebenarnya yaitu 0.00341802, dan ditambahkan 149 untuk merubah menjadi satuan Kelvin (K) dan ditambahkan dengan -273.15 untuk merubah menjadi satuan Celcius (C).

3.1.2 Sentinel-2

Sentinel-2 diluncurkan oleh ESA sebagai bagian dari program Copernicus untuk menyediakan informasi lingkungan dan keamanan di seluruh dunia. Sentinel-2 memiliki kemampuan untuk melacak perubahan lahan, mengamati pertumbuhan tanaman, dan mendeteksi berbagai perubahan lingkungan.

Sentinel-2 memiliki sensor multi-spektral dengan 13 band pada rentang panjang gelombang yang berbeda. Band ini mencakup area spektrum yang luas, termasuk visual, inframerah dekat, dan inframerah tengah, yang memungkinkan analisis yang lebih rinci tentang berbagai fenomena di permukaan Bumi. Berikut ini merupakan citra Sentinel-2 yang nantinya akan digunakan pada variabel NDVI, NDBI, NDWI, NDMI dan UDI.



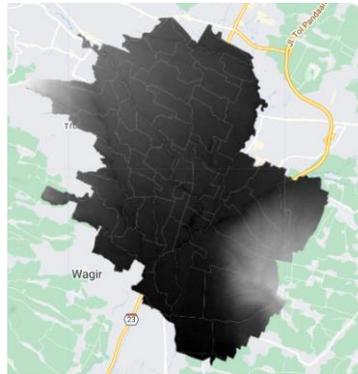
Gambar 3. 3 Citra Sentinel-2

Pada Gambar 3.3 merupakan visualisasi dari citra Sentinel-2 pada Band 2, 3, dan 4 yang mencakup warna merah, hijau, dan biru, sementara band-band lainnya fokus pada berbagai aspek seperti vegetasi, air, dan inframerah dekat Keunggulan dari citra Sentinel-2 adalah memiliki resolusi spasial tinggi hingga 10 meter, memungkinkan identifikasi dan analisis UHI di tingkat yang lebih rinci. Band yang akan digunakan dari citra Sentinel-2 adalah B3, B4, B8, B11, dan B12. Sebelum digunakan data akan di-preparation terlebih dahulu, dengan dikalikan dengan ukuran skala yang sebenarnya yaitu dikali dengan 0.0001, dengan tujuan untuk merubah nilai dari rentang awal 0-65455 menjadi rentang 0-1.

3.1.1 SRTM

SRTM (*Shuttle Radar Topography Mission*) adalah misi penginderaan jauh yang dilakukan oleh NASA dan National Geospatial-Intelligence Agency (NGA) pada tahun 2000. Misi ini dirancang untuk menghasilkan model elevasi permukaan bumi yang sangat akurat dan global. Citra SRTM menggunakan teknologi radar interferometri untuk mengukur elevasi permukaan bumi dengan tingkat resolusi

yang tinggi. Berikut ini merupakan citra SRTM yang nantinya akan digunakan pada variabel Elevasi.



Gambar 3. 4 Citra SRTM

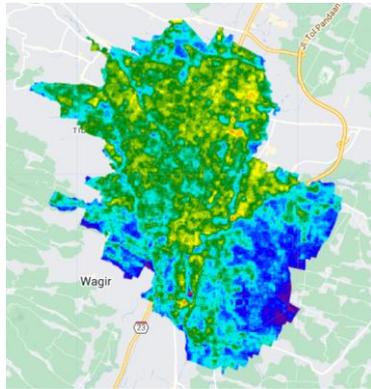
Pada Gambar 3.4 menunjukkan visualisasi citra SRTM yang akan digunakan sebagai variable elevasi yang nantinya akan sangat berguna dalam berbagai aplikasi, termasuk pemodelan topografi, hidrologi, dan perencanaan lingkungan. Citra ini dapat digunakan untuk memahami morfologi permukaan bumi, mengidentifikasi cekungan air, dan mendeteksi perubahan topografi signifikan.

Keunggulan citra SRTM termasuk resolusi spasial yang tinggi dan kemampuan untuk menyediakan data elevasi pada skala global. Data ini dapat digunakan dalam analisis SIG (Sistem Informasi Geografis) untuk mendapatkan informasi mendalam tentang struktur topografi suatu wilayah.

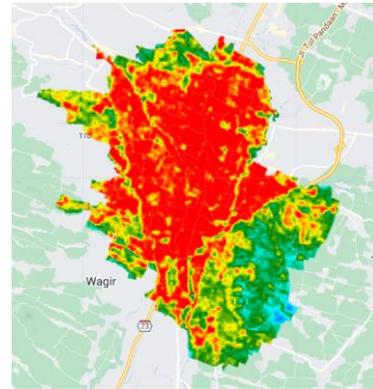
3.2 *Cloud Masking*

Langkah selanjutnya adalah pemanggilan fungsi *Cloud Masking*. Fungsi ini akan membantu untuk menghasilkan citra yang lebih bersih dan menghilangkan piksel-piksel yang terpengaruh oleh awan atau bayangan awan yang akan

mengganggu hasil dari citra. Berikut ini perbandingan citra sebelum dilakukan *Cloud Masking* (Gambar 3.5) dan sesudah dilakukan *Cloud Masking* (Gambar 3.6)



Gambar 3. 5 Sebelum *Cloud Masking*



Gambar 3. 6 Setelah *Cloud Masking*

Berdasarkan pada perbandingan gambar 3.5 dan Gambar 3.6, terdapat perbedaan warna yang signifikan. Pada Gambar 3.5, yaitu visualisasi citra sebelum dilakukan *Cloud Masking*, visualisasi citra cenderung ke warna biru, hijau dan kuning. Yang menandakan bahwa nilai LST rendah. Nilai LST rendah dikarenakan masih adanya pengaruh awan dan bayangannya. Pada Gambar 3.6, visualisasi citra berwarna merah, kuning dan hijau. Yang berarti LST memiliki nilai yang rendah-tinggi. ini merupakan data LST yang sebenarnya, karena sudah menerapkan *Cloud Masking* untuk menghilangkan pengaruh awan dan bayangan awan.

3.3 Perhitungan fitur-fitur

Perhitungan dilakukan dengan rumus-rumus matematika yang sederhana untuk menghitung fitur-fitur yang akan digunakan. Fitur yang akan digunakan adalah NDVI, NDBI, NDWI, NDMI, UDI, elevasi, dan LST. Fitur NDVI, NDBI,

NDWI, dan NDMI perlu dilakukan perhitungan berdasarkan persamaan 3.1, 3.2, 3.3, dan 3.4.

Tabel 3. 2 Fitur-fitur yang akan digunakan beserta perhitungannya

No	Fitur	Keterangan	Perhitungan
1.	NDVI	Indeks yang digunakan dalam penginderaan jauh untuk mengukur tingkat kehijauan atau keberadaan vegetasi pada suatu area. Nilai tinggi menunjukkan adanya vegetasi yang subur.	$\frac{(NIR - Red)}{(NIR + Red)}$
2.	NDBI	Indeks yang digunakan dalam penginderaan jauh untuk mengukur area yang telah dibangun atau penggunaan lahan yang terurbanisasi.	$\frac{(SWIR2 - NIR)}{(SWIR2 + NIR)}$
3.	NDWI	Indeks yang digunakan dalam penginderaan jauh untuk mengukur kandungan air atau kelembaban dalam permukaan tanah	$\frac{(Green - NIR)}{(Green + NIR)}$
4.	NDMI	Indeks yang digunakan dalam penginderaan jauh untuk mengukur tingkat kelembaban atau keadaan hidrasi dari suatu wilayah	$\frac{(NIR - SWIR1)}{(NIR + SWIR1)}$
5.	UDI	Indeks yang digunakan dalam penginderaan jauh untuk mengukur tingkat urbanisasi.	-
6.	Elevasi	data elevasi permukaan bumi yang diukur oleh misi Shuttle Radar Topography Mission (SRTM). Memberikan informasi ketinggian suatu wilayah di atas permukaan laut.	-
7.	LST	Nilai suhu permukaan pada suatu daerah yang direkam menggunakan ST B10 dari satelit Landsat	-

3.3.1 NDVI

Nilai NDVI diperoleh dengan perhitungan Near Infrared dengan Red yang dipantulkan oleh tumbuhan. Nilai NDVI diperoleh dengan membandingkan jumlah cahaya inframerah dekat (NIR) dan cahaya merah (Red) yang dipantulkan oleh vegetasi(Purwanto, 2015). Berikut ini adalah persamaan untuk menghitung nilai NDVI pada persamaan 3.1:

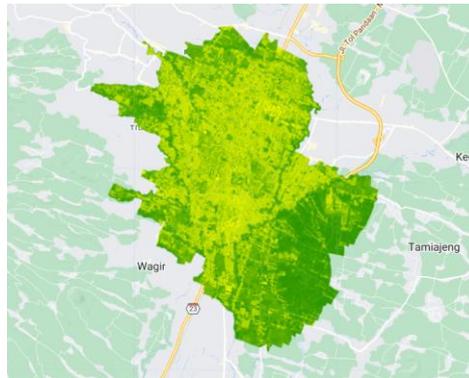
$$NDVI = \frac{(NIR - Red)}{(NIR + Red)} \quad (3.1)$$

Keterangan :

NIR* : Band 8 Sentinel 2

RED* : Band 4 Sentinel 2

*merujuk pada tabel 3.1



Gambar 3. 7 NDVI

Nilai yang dihasilkan berkisar antara -1 hingga 1, dengan nilai yang lebih tinggi menunjukkan vegetasi yang lebih lebat dan sehat. NDVI biasanya digunakan dalam penginderaan jauh dan citra satelit untuk memantau perubahan dan kesehatan vegetasi.

3.3.2 NDBI

Nilai NDBI merupakan bentuk gambaran dari tingkat kepadatan bangunan atau perkembangan perkotaan di suatu wilayah ormulanya mirip dengan NDVI, tetapi NDBI membandingkan perbedaan antara intensitas inframerah dekat (NIR) dan SWIR2 dengan mengurangi nilai SWIR2 dari nilai inframerah dekat, kemudian membaginya dengan jumlah nilai SWIR2 dan inframerah dekat. Berikut ini adalah persamaan untuk menghitung nilai NDBI pada persamaan 3.2:

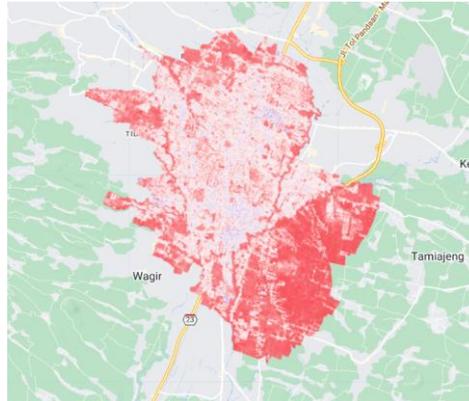
$$NDBI = \frac{(SWIR2 - NIR)}{(SWIR2 + NIR)} \quad (3.2)$$

Keterangan :

NIR : Band 8 Sentinel 2

SWIR2 : Band 12 Sentinel 2

*merujuk pada Tabel 3.1



Gambar 3. 8 NDBI

Nilai NDBI berkisar antara -1 hingga 1. Nilai positif menunjukkan keberadaan material yang tidak memantulkan cahaya di spektrum merah dan menunjukkan kemungkinan area yang terbangun (bangunan atau infrastruktur). Sebaliknya, nilai negatif menunjukkan keberadaan material yang memantulkan cahaya di spektrum merah, seperti air atau vegetasi, dan menunjukkan kemungkinan area yang tidak terbangun.

3.3.3 NDWI

Nilai NDWI digunakan untuk mendeteksi dan memetakan air pada citra penginderaan jauh. NDWI memanfaatkan perbedaan absorbansi antara dua panjang gelombang, yaitu inframerah dekat (NIR) dan hijau (G). NDWI dihitung dengan membandingkan jumlah cahaya hijau dan inframerah dekat (NIR) yang dipantulkan oleh badan air. Berikut ini adalah persamaan untuk menghitung nilai NDMI pada persamaan 3.3:

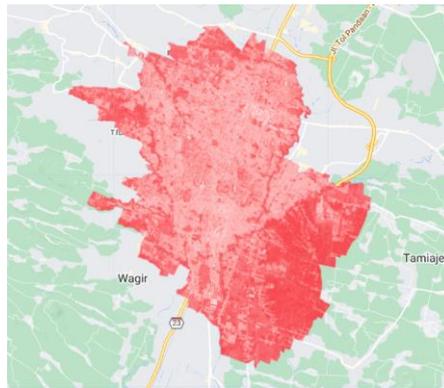
$$NDWI = \frac{(Green - NIR)}{(Green + NIR)} \quad (3.3)$$

Keterangan :

NIR : Band 8 Sentinel 2

Green : Band 3 Sentinel 2

*merujuk pada tabel 3.1



Gambar 3. 9 NDWI

Nilai NDWI berkisar antara -1 hingga 1. Area dengan nilai positif cenderung menunjukkan keberadaan air, sementara nilai negatif menunjukkan non-air. Nilai NDWI dapat membantu mengidentifikasi dan memetakan badan air seperti sungai, danau, atau wilayah tergenang.

3.3.4 NDMI

Nilai NDMI digunakan untuk untuk menilai kelembaban atau kelembaban tanah pada citra penginderaan jauh. NDMI memanfaatkan perbedaan absorptansi antara dua panjang gelombang, yaitu inframerah dekat (NIR) dan SWIR1. Berikut ini adalah persamaan untuk menghitung nilai NDMI pada persamaan 3.4:

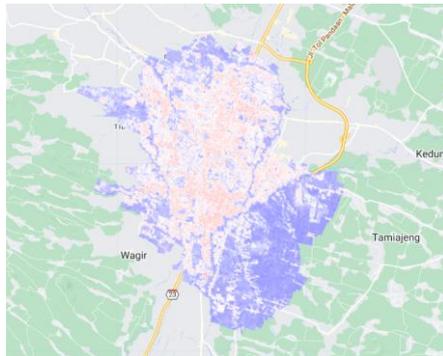
$$NDMI = \frac{(NIR - SWIR1)}{(NIR + SWIR1)} \quad (3.4)$$

Keterangan :

NIR : Band 8 Sentinel 2

SWIR1 : Band 11 Sentinel 2

*merujuk pada tabel 3.1



Gambar 3. 10 NDMI

Seperti halnya dengan indeks lainnya, nilai NDMI berkisar antara -1 hingga 1. Nilai yang lebih tinggi cenderung menunjukkan kelembaban atau keberadaan air, sementara nilai yang lebih rendah dapat menunjukkan kekeringan atau kurangnya kelembaban. NDMI sering digunakan untuk memantau kondisi kelembaban tanah, mengidentifikasi wilayah yang memerlukan perhatian lebih dalam hal pengairan, (seperti danau, sungai, dan lahan basah) atau bahkan mendeteksi dampak kekeringan pada pertanian.

3.3.5 UDI

Indeks kepadatan kota (UDI) adalah ukuran yang digunakan dalam perencanaan kota dan desain kota untuk menilai jumlah orang yang mendiami suatu wilayah perkotaan. Hal ini merupakan faktor penting dalam memahami bagaimana kota berfungsi dan digunakan untuk mengkarakterisasi perluasan kota.

UDI sering digunakan bersama dengan indeks lain, seperti indeks kepadatan kehijauan (GDI), untuk memberikan pemahaman yang lebih komprehensif tentang

lingkungan perkotaan. GDI adalah indeks yang mengukur jumlah ruang hijau di dalam area perkotaan, dan dihitung dengan menggunakan indeks spektral yaitu NDWI, NDBI dan NBR2. Dari ketiga fitur tersebut lalu dihitung rata rata nilai pikselnya.

3.3.6 Elevasi

Hubungan antara elevasi dan suhu permukaan tanah (LST) telah menjadi subjek dari berbagai penelitian. Penelitian telah menunjukkan bahwa elevasi dapat secara signifikan mempengaruhi LST di area tertentu. Sebagai contoh, sebuah penelitian yang dilakukan di Hangzhou, Cina, menganalisis pengaruh faktor topografi, termasuk elevasi, terhadap LST. Studi tersebut menemukan bahwa daerah dengan elevasi yang lebih tinggi dan fluktuasi topografi yang lebih besar menunjukkan LST yang lebih rendah, yang disebabkan oleh lebih sedikitnya aktivitas manusia dan efek pendinginan dari ruang terbuka hijau, yang dapat menurunkan LST. Selain itu, dampak elevasi terhadap LST terutama disebabkan oleh suhu udara, dengan nilai suhu yang berangsur-angsur menurun seiring dengan meningkatnya elevasi karena proses pertukaran panas antara permukaan dan udara.

Pada penelitian ini, variable elevasi diambil dari citra NASA SRTM Digital Elevation 30m karena pada satelit ini hanya terdapat satu band khusus yaitu elevasi dengan resolusi gambar sebesar 30 meter.

3.3.7 LST

LST adalah radiasi suhu kulit permukaan tanah, yang diukur berdasarkan arah sensor jarak jauh. Diperkirakan dari suhu kecerahan TOA dari saluran spektral

inframerah konstelasi satelit geostasioner. Perkiraan selanjutnya bergantung pada albedo, tutupan vegetasi, dan kelembaban tanah.

LST merupakan campuran vegetasi dan suhu tanah gundul. Karena keduanya merespons dengan cepat terhadap perubahan radiasi matahari yang masuk karena tutupan awan, modifikasi muatan aerosol, dan variasi iluminasi diurnal, LST juga menampilkan variasi yang cepat. Pada gilirannya, LST mempengaruhi UHI partisi energi antara tanah dan vegetasi, dan menentukan suhu udara permukaan. Ini sebenarnya adalah suhu permukaan bumi, karena bersentuhan langsung dengan alat ukur (biasanya diukur dalam kelvin).

Berikut ini, contoh perhitungan 4 fitur yang akan digunakan :

Tabel 3. 3 Contoh Perhitungan Fitur:

Variabel	Band 3 (G)	Band 4 (R)	Band 8 (N)	Band 11 (S1)	Band 12 (S2)	Rumus	Perhitungan	Hasil
NDVI	0.0741	0.0668	0.23855	0.19025	0.1289	$\frac{(NIR - Red)}{(NIR + Red)}$	$\frac{(0.23855 - 0.0668)}{(0.23855 + 0.0668)}$	0.144
NDMI						$\frac{(SWIR2 - NIR)}{(SWIR2 + NIR)}$	$\frac{(0.1289 - 0.23855)}{(0.1289 + 0.23855)}$	-0.174
NDBI						$\frac{(Green - NIR)}{(Green + NIR)}$	$\frac{(0.0741 - 0.23855)}{(0.0741 + 0.23855)}$	0.149
NDWI						$\frac{(NIR - SWIR1)}{(NIR + SWIR1)}$	$\frac{(0.23855 - 0.19025)}{(0.23855 + 0.19025)}$	-0.187

3.4 Normalisasi Data

Fitur yang telah didapatkan sebelumnya, akan dilakukan normalisasi data tujuannya data yang akan digunakan dapat dianalisis dengan baik. Normalisasi data dilakukan untuk membuat nilai data menjadi standar dan memiliki rentang nilai yang sama. Jenis normalisasi data yang digunakan adalah normalisasi *Z-Score*.

Normalisasi *Z-Score* adalah salah satu metode normalisasi data yang digunakan untuk mengukur penyimpangan data dari nilai rata-ratanya yang diukur dalam satuan standar deviasinya. Jika nilainya terletak diatas rata-rata maka *Z-*

Scorenya akan bernilai positif, sedangkan apabila nilainya dibawah nilai rata-rata maka *Z-Score*nya akan bernilai negatif. Rumus normalisasi *Z-Score* seperti ditunjukkan dalam persamaan 3.5(Maulana et al., 2019) :

$$\text{Normalisasi} = \frac{x - \mu}{\sigma} \quad (3.5)$$

Keterangan :

x = nilai variabel

μ = Rata-rata

σ = Standar deviasi

Berikut ini, perbandingan dari contoh 5 data sebelum dilakukan normalisasi *Z-Score* (Tabel 3.3) dan sesudah dilakukan normalisasi *Z-Score* (Tabel 3.4) :

Tabel 3. 4 Data sebelum dilakukan Normalisasi data

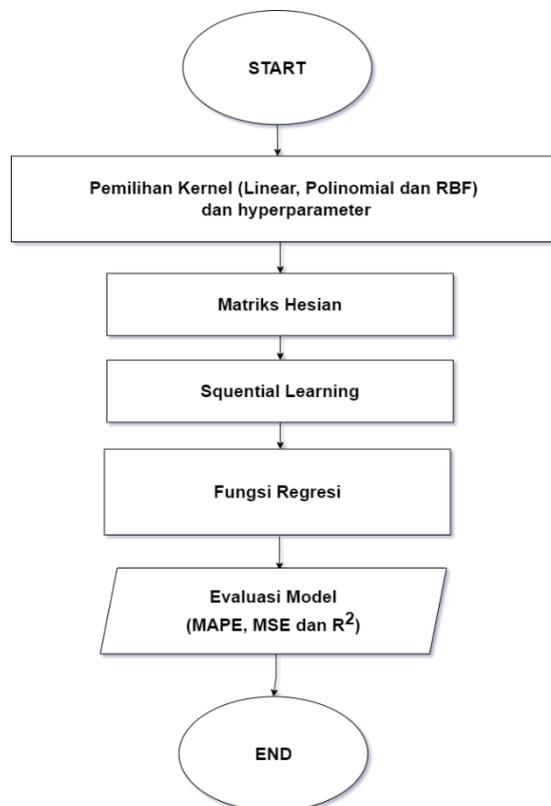
No	NDVI	NDMI	NDBI	NDWI	UDI	Elevation	LST
1	-0.015	-0.160	0.210	0.016	0.931	491	38.1
2	-0.018	-0.215	0.272	0.004	0.966	466	39.6
3	-0.006	-0.162	0.183	0.005	0.931	423	40.2
4	-0.011	-0.028	0.065	0.024	0.931	431	41.7

Tabel 3. 5 Data setelah dilakukan Normalisasi data

No	NDVI	NDMI	NDBI	NDWI	UDI	Elevation	LST
1	-1.671	-1.056	1.298	1.956	0.885	0.226	0.377
2	-1.682	-1.335	1.497	1.903	0.972	-0.272	0.754
3	-1.639	-1.067	1.212	1.908	0.885	-0.109	0.933
4	-1.657	-0.390	0.834	1.991	0.885	-0.970	1.315

Setelah melakukan normalisasi data, langkah selanjutnya adalah proses pembagian data antara data training dengan data testing yang nantinya akan diterapkan pada proses prediksi. Rasio yang digunakan adalah 90:10, 80:20, dan 70:30.

3.5 Metode *Support Vector Regression*



Gambar 3. 11 Flowchart Support Vector Regresion

Gambar 3.11 merupakan *flowchart* proses prediksi menggunakan metode SVR pada penelitian ini. Dalam penelitian ini Support Vector Regression (SVR) digunakan untuk memprediksi nilai variabel, yang dapat memberikan nilai akurasi prediksi optimal nilai aktual dan nilai hasil prediksi yang dapat diminimalkan tingkat kesalahannya dalam prediksi. Pada metode *Support Vector Regression* (SVR), beberapa aspek kunci yang perlu diperhatikan adalah pemilihan kernel, penyetelan parameter (tuning), dan evaluasi kinerja model. Keempat aspek ini memiliki peran penting dalam membangun model SVR yang efektif.

3.5.1 Pemilihan kernel dan *Hyperparameter*

Sebelum membuat model prediksi menggunakan metode SVR dilakukan pemilihan kernel dan *tunning parameter* terlebih dahulu untuk memperoleh parameter yang optimal dalam membangun model. Tuning parameter dilakukan pada parameter yang dimiliki oleh setiap kernel pada algoritma SVR. Parameter yang digunakan disesuaikan dengan kernel yang dipakai pada pemodelan. Untuk kernel linear, *tunning parameter* digunakan untuk mencari C dan ϵ paling optimal. Nilai C yang terlalu besar tidak memerhatikan perubahan maksimum margin sehingga menghasilkan error yang konstan, sebaliknya nilai C yang terlalu kecil terlalu memerhatikan nilai penalti dalam SVR. Sementara itu, nilai ϵ yang kecil membuat toleransi error yang dibatasi kecil, sebaliknya nilai ϵ yang besar menghasilkan toleransi error yang dibatasi besar.

Pada kernel polinomial, *tunning parameter* digunakan untuk mencari C, ϵ , γ (*Gamma*) dan d (*Degree*) paling optimal. Pada kernel Radial Basis Function (RBF), *tunning parameter* digunakan untuk mencari C dan γ yang optimal. Parameter γ menentukan besarnya pengaruh dari setiap titik data dalam pemetaan ruang input ke dimensi yang lebih tinggi. Pengaturan rentang nilai pada setiap parameter yang diproses pada tuning parameter menggunakan nilai pada Tabel 3.5, 3.6, dan 3.7.

Tabel 3. 6 *Tunning parameter* Linier

Fungsi Kernel	Parameter <i>Hyperplane</i>	Nilai Parameter
Kernel Linear	C (<i>Cost</i>)	10^{-1} , 1, 10^1
	ϵ (<i>Epsilon</i>)	10^{-3} , 10^{-2} , 10^{-1}

Tabel 3. 7 *Tunning parameter* Polynomial

Fungsi Kernel	Parameter <i>Hyperplane</i>	Nilai Parameter
Kernel <i>Polynomial</i>	C (<i>Cost</i>)	10^{-1} , 1, 10^1
	ϵ (<i>Epsilon</i>)	10^{-3} , 10^{-2} , 10^{-1}
	d (<i>Degree</i>)	2, 4, 8

Tabel 3. 8 Tuning parameter Radial Basis Function (RBF)

Fungsi Kernel			Parameter Hyperplane	Nilai Parameter
Kernel Radial Basis Function			C (Cost)	$10^{-1}, 1, 10^1$
			ϵ (Epsilon)	$10^{-3}, 10^{-2}, 10^{-1}$
			γ (Gamma)	$10^{-1}, 1, 10^1$

Pada perhitungan kernel pada metode SVR yang digunakan dalam penelitian ini, salah satunya adalah kernel linier yang ditunjukkan dalam persamaan (2.xx). sebelum menghitung nilai kernel, jarak antar data dihitung terlebih dahulu dengan cara membandingkan satu persatu berdasarkan hasil normalisasi data. Berikut ini contoh perhitungan jarak pada data 1 dan 2 :

$$(x_1 - x_2) = (-0.431 - (-1.0788))^2 + (-0.022 - (-0.721))^2 + \dots + (1.274 - (-0.510))^2 = \mathbf{2.693} \quad (3.6)$$

Tabel 3. 9 Perhitungan Jarak

	X_1	X_2	X_3	X_4	X_5
X_1	0	2.693	3.457	3.953	3.957
X_2	2.693	0	3.765	4.855	2.163
X_3	3.457	3.765	0	3.066	3.680
X_4	3.953	4.855	3.066	0	4.911
X_5	3.957	2.163	3.680	4.911	0

Setelah perhitungan jarak, maka akan menghitung kernel linier berdasarkan persamaan (2.5). Berikut ini contoh perhitungan kernel linier pada data 1 dan 2:

$$(x_1 - x_2) = (-0.431 * (-1.0788))^2 + (-0.022 * (-0.721))^2 + \dots + (1.274 * (-0.510))^2 = \mathbf{0.790} \quad (3.7)$$

Tabel 3. 10 Perhitungan Kernel linier

	X_1	X_2	X_3	X_4	X_5
X_1	1	0.790	-1.618	-1.091	-2.580
X_2	0.790	1	-2.813	-5.145	2.829
X_3	-1.618	-2.813	1	1.879	-1.663
X_4	-1.091	-5.145	1.879	1	-4.587
X_5	-2.580	2.829	-1.663	-4.587	1

3.5.2 Menghitung Matriks Hessian

Setelah melakukan perhitungan kernel selanjutnya menghitung matriks Hessian. Pada proses perhitungan matriks Hessian membutuhkan nilai dari hasil perhitungan kernel seperti pada tabel 3.10. proses perhitungan nilai matriks hessian didapatkan dari hasil perhitungan kernel dan parameter lamda. Berikut ini contoh perhitungan matriks hessian pada data 1 dan 2:

$$R_{(1,2)} = 0.790 + (0.2)^2 = \mathbf{0.830892} \quad (3.8)$$

Tabel 3. 11 Perhitungan Matriks Hessian

	X_1	X_2	X_3	X_4	X_5
X_1	1.04	0.830892	-1.5784	-1.05111	-2.54092
X_2	0.830892	1.04	-2.77313	-5.10528	2.869683
X_3	-1.5784	-2.77313	1.04	1.919123	-1.62319
X_4	-1.05111	-5.10528	1.919123	1.04	-4.54767
X_5	-2.54092	2.869683	-1.62319	-4.54767	1.04

3.5.3 Sequential Learning

Pada perhitung untuk Squential Learning dari hasil matriks Hessian. Perhitungan sequential learning berfungsi untuk mendapatkan nilai Lagrange Multiplier (α_i dan α_i^*). Dalam perhitungan Squential learning terdiri dari perhitungan perhitungan nilai error, nilai $\delta \alpha_i^*$ dan $\delta \alpha_i$ dan perhitungan nilai Lagrange Multiplier (α_i dan α_i^*).

Perhitungan nilai error ini nilai dibutuhkan alpha* dan nilai alpha yang diinisialisasi terdahulu nilainya null semua seperti yang ditunjukkan pada Tabel 3.xx. Contoh perhitungan nilai error ini menggunakan data ke-2 iterasi ke 2, serta dibutuhkan data normal target (Y) pada Tabel 3.5 dan matriks hessian yang

ditunjukkan dalam Tabel 3.11. Serta nilai α^* dan nilai α iterasi sebelumnya.

Berikut contoh perhitungannya :

Tabel 3. 12 Inisialisasi Nilai ($\mathbf{a_i^*}$ dan $\mathbf{a_i}$)

$\mathbf{a_i^*}$	$\mathbf{a_i}$
0	0
0	0
0	0
0	0
0	0

Tabel 3. 13 Hasil Nilai ($\mathbf{a_i}$ dan $\mathbf{a_i^*}$)

$\mathbf{a_i^*}$	$\mathbf{a_i}$
0.21935	0
0.25802	0
0.12653	0
0.45882	0
0.19898	0

Pada perhitungan nilai error didapatkan dari matriks normalisasi akan di kurangi oleh, jumlah dari keseluruhan α star kurang α yang diambil dari iterasi sebelumnya lalu dikali dengan matriks. Berikut ini contoh perhitungan hasil hitung nilai error pada data 2:

$$E_i = 0.022 - (((0.219 - 0) \times (0.830) + \dots + (0.198 - 0) \times (2.869)) = \mathbf{0.310629} \quad (3.9)$$

Tabel 3. 14 Hasil perhitungan nilai error

$\mathbf{E_i}$
0.291692
0.310629
0.090626
0.421966
0.556029

3.6 Menentukan Fungsi Regresi

Langkah selanjutnya yaitu menghitung nilai fungsi regresi $f(x)$. Untuk melakukan perhitungan menentukan nilai fungsi regresi $f(x)$ menggunakan nilai

Nilai α_i dan $\alpha_i * \text{iterasi terakhir}$ dan matrik hessian. Fungsi regresi diperoleh dengan jumlah keseluruhan dari alpha star baru dikurangi alpha pada iterasi yang terakhir yang akan dikali dengan matriks hessian. Berikut ini contoh perhitungan fungsi regresi pada data 2:

$$f(x) = (((0.219 - 0) \times (-1.578) + \dots + (0.1982 - 0) \times (-1.623)) = -1.508 \quad (3.10)$$

Tabel 3. 15 Perhitungan Fungsi Regresi

$f(x)$
-0.77311
-1.50806
0.796089
0.418475
-4.08154

3.7 Evaluasi

Tahapan terakhir dalam penelitian ini adalah evaluasi performa. Evaluasi performa adalah langkah penting dalam menilai seberapa baik model atau algoritma yang telah dibuat bekerja dalam memprediksi suatu data. Evaluasi performa ini dilakukan dengan menggunakan R^2 , MAPE dan MSE. Dengan menggunakan ketiga evaluasi tersebut, diharapkan mampu memberikan hasil evaluasi performa yang detail dan komprehensif.

Berikut ini contoh perhitungan MAPE :

$$MAPE = \frac{1}{3} \sum_t \left(\left| \frac{38 - 40}{38} \right| + \left| \frac{35 - 36}{35} \right| + \left| \frac{37 - 36}{35} \right| \right) \times 100\% \quad (3.11)$$

$$MAPE = 0.9\%$$

Berikut ini contoh perhitungan MSE :

$$MSE = \frac{1}{3} \sum ((40 - 38)^2 + (35 - 36)^2 + (37 - 36)^2) = 2 \quad (3.12)$$

3.8 Skenario Pengujian

Skenario pengujian adalah serangkaian langkah uji yang digunakan untuk mengevaluasi sistem yang telah dibangun. Dataset yang digunakan, dibagi menjadi 5 skenario yang berbeda untuk memisahkan data latih dan data uji. Pembagian ini dilakukan untuk menemukan skenario manakah yang menghasilkan nilai akurasi terbaik. Jumlah data yang digunakan untuk setiap skenario pembagian dataset dapat dilihat pada Tabel 3.6.

Tabel 3. 16 Skenario Pengujian pembagian data

Skenario	Presentase Data Latih	Presentase Data Uji
1	90%	10%
2	80%	20%
3	70%	30%

Selain skenario pembagian dataset, terdapat juga sub-skenario tuning parameter. Tuning parameter digunakan untuk mencari nilai parameter yang optimal sehingga SVR memberikan keseimbangan yang baik antara kesalahan klasifikasi dan margin maksimum sesuai dengan karakteristik data yang ada. Nantinya, setiap skenario pada Tabel 3.6 akan diuji dengan sub-skenario yang ada pada Tabel 3.7.

Tabel 3. 17 Skenario Fungsi Kernel

Sub-Skenario	Fungsi Kernel	Parameter <i>Hyperplane</i>	Nilai Parameter
1	Kernel Linear	C (<i>Cost</i>)	$10^{-1}, 1, 10^1$
		ε (<i>Epsilon</i>)	$10^{-3}, 10^{-2}, 10^{-1}$
2	Kernel <i>Polynomial</i>	C (<i>Cost</i>)	$10^{-1}, 1, 10^1$
		ε (<i>Epsilon</i>)	$10^{-3}, 10^{-2}, 10^{-1}$
		d (<i>Degree</i>)	2, 4, 8

Sub-Skenario	Fungsi Kernel	Parameter <i>Hyperplane</i>	Nilai Parameter
3	Kernel Radial Basis Function	C (<i>Cost</i>)	$10^{-1}, 1, 10^1$
		ε (<i>Epsilon</i>)	$10^{-3}, 10^{-2}, 10^{-1}$
		γ (<i>Gamma</i>)	$10^{-1}, 1, 10^1$

BAB IV

UJI COBA DAN PEMBAHASAN

4.1 Hasil Dataset

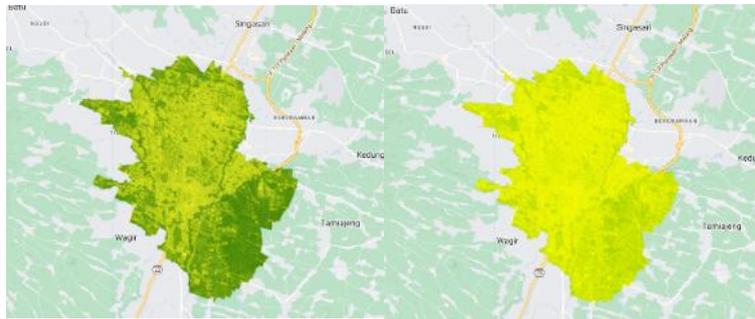
Dataset yang digunakan pada penelitian ini adalah data penginderaan jauh satelit yang didapatkan dari google earth engine dengan menggunakan 3 satelit yaitu Sentinel-2 Level-2A, Landsat-8 OLI/TIRS C2 L1, NASA SRTM Digital Elevation 30m dengan lokasi penelitian di Kota Malang. Data satelit yang akan digunakan, harus dilakukan proses *Cloud Masking* dan *feature scaling* terlebih dahulu sebelum data digunakan.

4.1.1 Cloud Masking

Fungsi *Cloud Masking* digunakan untuk menghasilkan citra yang lebih bersih dengan menghilangkan piksel piksel yang terpengaruh oleh awan ataupun bayangannya yang akan mengganggu hasil dari data yang akan digunakan. Berikut ini perbandingan visualisasi citra dan data dalam bentuk tabel sebelum dan setelah dilakukan *Cloud Masking*

a. Sentinel-2 Level 2

Berikut ini merupakan perbandingan visualisasi pada citra vegetasi Kota Malang sebelum dan setelah dilakukan *Cloud Masking*:

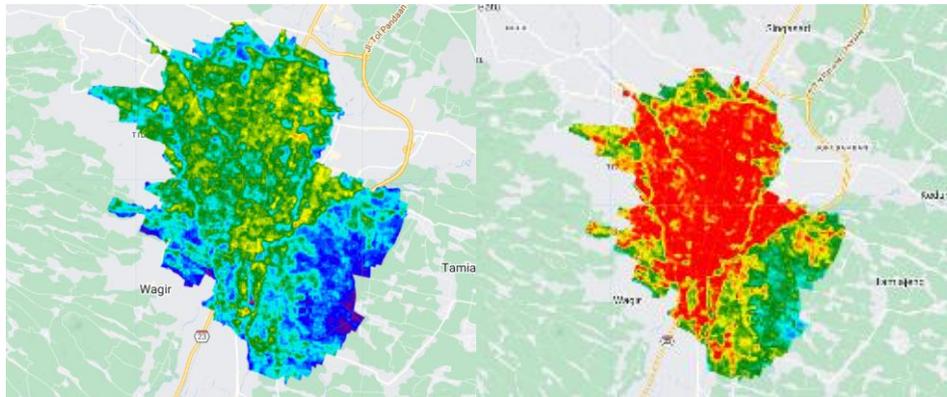


Gambar 4. 1 Perbandingan visualisasi citra vegetasi menggunakan Sentinel-2 sebelum dan setelah dilakukan Cloud Masking

Gambar 4.1 menunjukkan hasil perbandingan nilai piksel vegetasi sebelum dan setelah penerapan *Cloud Masking* pada citra Sentinel-2 Level 2. *Cloud Masking* berfungsi untuk menghilangkan pengaruh piksel yang terpengaruh oleh awan atau bayangannya, sehingga menghasilkan citra yang lebih bersih dan optimal untuk analisis data. Terlihat bahwa setelah proses *Cloud Masking*, nilai piksel secara signifikan berubah, yang ditunjukkan dengan hasil visualisasi dengan warna yang lebih gelap dengan dominan warna hijau, kecuali di bagian tengah perkotaan, citra vegetasi tetap berwarna kuning, ini menunjukkan bahwa ditengah perkotaan vegetasi bernilai rendah. Sedangkan jika dibandingkan dengan citra vegetasi sebelum dilakukan *Cloud Masking*, dominasi warna citra adalah warna kuning pada keseluruhan kota Malang, ini menunjukkan bahwa adanya citra awan dan bayangan awan yang ikut terekam satelit.

b. Landsat OLI/TIRS C2 L1

Berikut ini merupakan perbandingan visualisasi pada citra LST kota malang sebelum dan setelah dilakukan *Cloud Masking*:



Gambar 4. 2 Perbandingan visualisasi citra *Land Surface Temperature* menggunakan satelit Landsat-8 sebelum dan setelah dilakukan *Cloud Masking*

Gambar 4.2 menunjukkan perbandingan nilai LST sebelum dan setelah dilakukan *Cloud Masking* pada citra Landsat-8. *Cloud Masking* pada citra LST bertujuan untuk menghilangkan efek bayangan dan gangguan akibat awan, sehingga menghasilkan estimasi suhu permukaan tanah yang lebih akurat. Dari visualisasi Gambar 4.5 terlihat bahwa setelah *Cloud Masking* diterapkan, nilai-nilai LST mengalami peningkatan dan perubahan yang dapat menggambarkan kondisi suhu yang lebih tepat dan tidak terganggu oleh keberadaan awan.

Visualisasi citra sebelum dilakukan *Cloud Masking*, visualisasi citra cenderung ke warna biru, hijau dan kuning. Yang menandakan bahwa nilai LST bernilai dingin-rendah. Nilai LST dingin-rendah dikarenakan masih adanya pengaruh awan dan bayangannya. Pada Gambar 4.2 pada visualisasi citra setelah *Cloud Masking*, visualisasi citra berwarna merah, kuning dan hijau. Yang berarti LST memiliki nilai yang rendah-tinggi. ini merupakan data LST yang sebenarnya, karena sudah menerapkan *Cloud Masking* untuk menghilangkan pengaruh awan dan bayangan awan.

4.1.2 Feature Scalling

Feature scalling digunakan untuk menghitung variabel yang perlu dilakukan perhitungan feature terlebih dahulu. Berikut ini hasil dari perhitungan featuremya:

Tabel 4. 1 *Feature Calculation*

Data	Sebelum Feature Calculation					Setelah Feature Calculation				
	Band 3 (G)	Band 4 (R)	Band 8 (N)	Band 11 (S1)	Band 12 (S2)	NDVI	NDBI	NDMI	NDWI	UDI
1	0.0741	0.0668	0.2385	0.1902	0.1289	0.0741	0.0668	0.23855	0.19025	0.1289
2	0.0785	0.0737	0.2559	0.1981	0.1418	0.5528	-0.2868	0.24862	-0.5305	0.2413
3	0.1146	0.1173	0.1987	0.2211	0.1979	0.2574	-0.0020	0.15357	-0.2685	1

4.2 Normalisasi Data

Normalisasi data dilakukan menggunakan metode z-score beberapa variabel perlu dilakukan normalisasi untuk memberikan rentang yang sama antar variabel dengan menggunakan persamaan 3.1, Berikut ini hasil normalisasi data, sebelum dan sesudah dilakukan normalisasi:

Tabel 4. 2 Sebelum dan Sesudah Normalisasi data

Sebelum Normalisasi						
NDVI	NDMI	NDBI	NDWI	UDI	Elevation	LST
-0.015	-0.160	0.210	0.016	0.931	491	38.1
-0.018	-0.215	0.272	0.004	0.966	466	39.6
-0.006	-0.162	0.183	0.005	0.931	423	40.2
-0.011	-0.028	0.065	0.024	0.931	431	41.7
-0.015	-0.226	0.248	-0.007	0.966	463	42.9

Sesudah Normalisasi						
NDVI	NDMI	NDBI	NDWI	UDI	Elevation	LST
-1.671	-1.056	1.298	1.956	0.885	0.226	0.377
-1.682	-1.335	1.497	1.903	0.972	-0.272	0.754
-1.639	-1.067	1.212	1.908	0.885	-0.109	0.933
-1.657	-0.390	0.834	1.991	0.885	-0.970	1.315
-1.671	-1.390	1.420	1.855	0.972	-0.332	1.648

4.3 Hasil Data Splitting

Proses data splitting menghasilkan dua data yaitu data training dan data testing. Berikut ini adalah hasil splitting data menggunakan rasio yang berbeda-beda. Splitting data menggunakan metode random state data:

Tabel 4. 3 Rasio Splitting Data

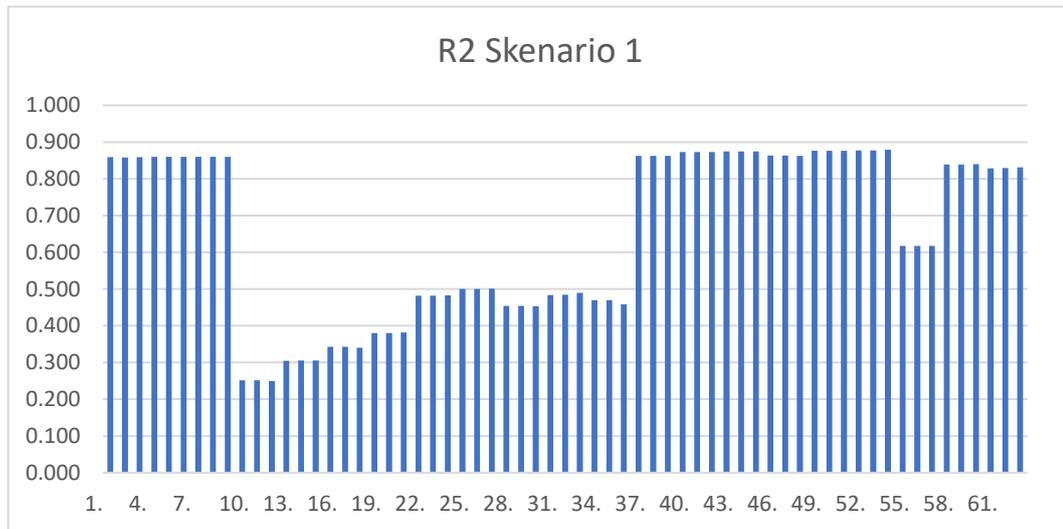
Rasio	Σ Data Training	Σ Data Test
70:30	5950	2550
80:20	6800	1700
90:10	7650	850

4.4 Hasil Pengujian Model SVR

Pada bagian ini, akan membahas hasil evaluasi performa model dengan menggunakan metode SVR berdasarkan variasi penggunaan kernel dan tuning parameter. Hasil evaluasi performa model didapatkan berdasarkan hasil perbandingan antara nilai y_{test} (data aktual) dan y_{pred} (data hasil prediksi) sebagai tolak ukur tingkat keberhasilan metode. Evaluasi performa model yang digunakan pada penelitian ini berfokus pada MAPE untuk menunjukkan tingkat kesalahan pada model berdasarkan tabel klasifikasi nilai mape pada tabel 2.2

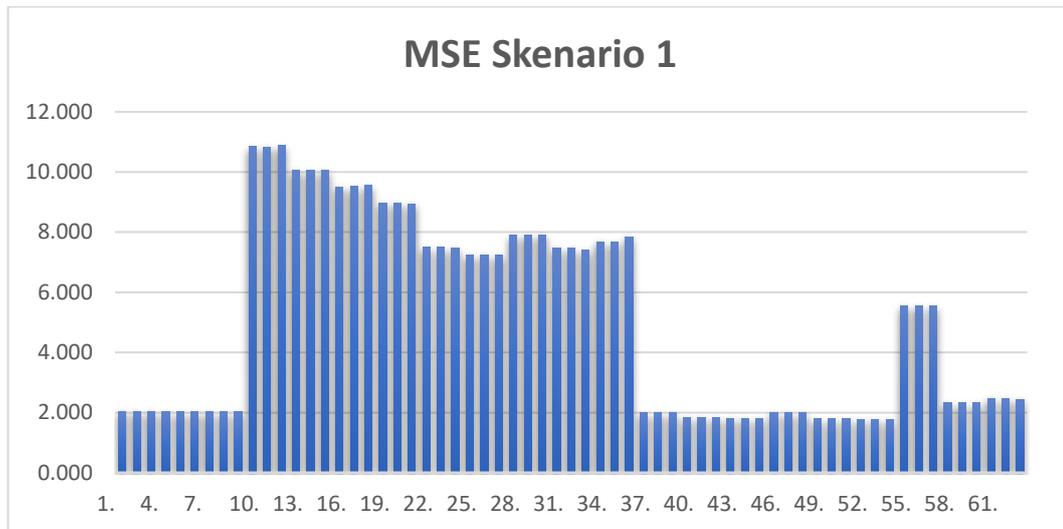
4.4.1 Hasil pengujian Skenario 1

Dalam skenario 1, pengujian rasio splitting data yang digunakan adalah 70:30, dengan 5950 data training dan 2550 untuk data testing serta terdapat beberapa sub-skenario pengujian berupa pemilihan parameter dan kernel untuk pengujian yang terdapat pada Lampiran 1. Waktu yang diperlukan untuk mendapatkan hasil pengujian skenario 1 sekitar 3 menit. Berikut ini, hasil evaluasi pengujian skenario 1:



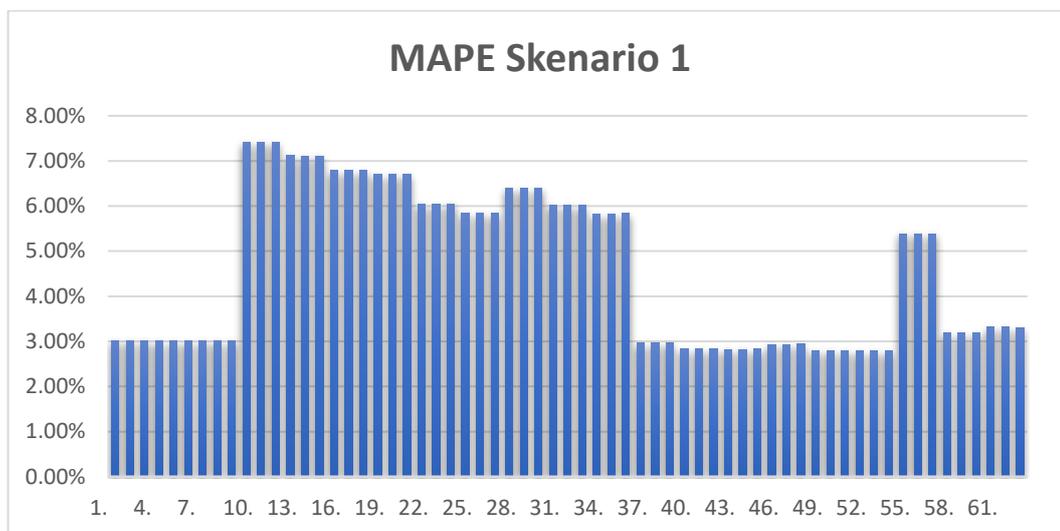
Gambar 4.3 Evaluasi Performa R² Skenario 1

Gambar 4.3 menunjukkan evaluasi nilai performa pengujian dengan menggunakan R². Dengan menggunakan kernel linier didapatkan nilai R² tertinggi sebesar 0.860 dengan menggunakan konfigurasi hyperparameter C = 1 dan *Epsilon* = 0.0001. Sedangkan jika menggunakan kernel *Polynomial* didapatkan nilai R² tertinggi sebesar 0.469 dengan menggunakan hyperparameter C = 10, *Epsilon* = 0.001, dan *Degree* senilai 8. Selanjutnya, jika menggunakan kernel RBF didapatkan nilai R² tertinggi sebesar 0.878 dengan menggunakan hyperparameter C = 10, *Epsilon* = 0.1, dan *Gamma* bernilai 1. Jadi nilai R² tertinggi pada skenario 1 adalah 0.878 dengan menggunakan kernel RBF dengan nilai hyperparameter C = 10, *Epsilon* = 0.1, dan *Gamma* bernilai 1 yang menunjukkan bahwa model ini memiliki hubungan yang sangat kuat/sepurna antara variabel yang digunakan dalam model.



Gambar 4. 4 Evaluasi Performa MSE Skenario 1

Gambar 4.4 menunjukkan evaluasi nilai performa pengujian dengan menggunakan Mean Squared Error (MSE). Dengan menggunakan kernel linier, didapatkan nilai MSE terendah sebesar 2.030 dengan konfigurasi hyperparameter $C = 1$ dan $Epsilon = 0.0001$. Ketika menggunakan kernel Polynomial, nilai MSE tertinggi sebesar 7.681 dengan hyperparameter $C = 10$, $Epsilon = 0.001$, dan $Degree$ senilai 8. Selanjutnya, jika menggunakan kernel RBF, didapatkan nilai MSE terendah sebesar 1.772 dengan hyperparameter $C = 10$, $Epsilon = 0.1$, dan $Gamma$ bernilai 1. Jadi, nilai MSE terendah pada skenario ini adalah 1.772 dengan menggunakan kernel RBF, dengan hyperparameter $C = 10$, $Epsilon = 0.1$, dan $Gamma$ bernilai 1. Hal ini menunjukkan bahwa model ini memiliki tingkat kesalahan prediksi yang rendah, serta menunjukkan kualitas prediksi yang baik.

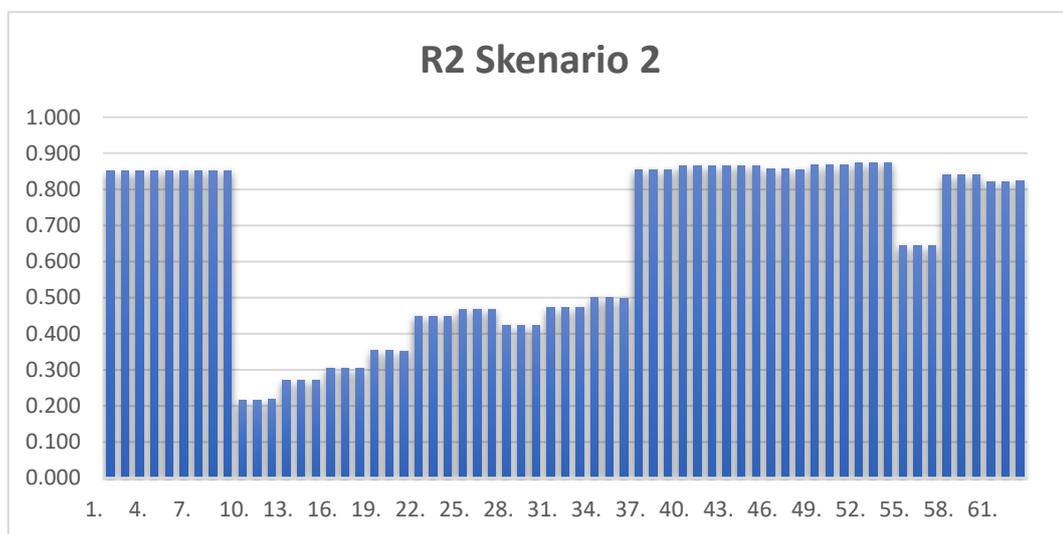


Gambar 4. 5 Evaluasi Performa MAPE Skenario 1

Gambar 4.5 menunjukkan evaluasi nilai performa pengujian dengan menggunakan MAPE. Dengan menggunakan kernel linier didapatkan nilai MAPE terendah sebesar 3.00% dengan menggunakan konfigurasi hyperparameter $C = 1$ dan $Epsilon = 0.0001$. Sedangkan jika menggunakan kernel *Polynomial* didapatkan nilai MAPE terendah sebesar 5.82% dengan menggunakan hyperparameter $C = 10$, $Epsilon = 0.001$, dan $Degree$ senilai 8. Selanjutnya, jika menggunakan kernel RBF didapatkan nilai MAPE terendah sebesar 2.78% dengan menggunakan hyperparameter $C = 10$, $Epsilon = 0.1$, dan $Gamma$ bernilai 1. Jadi nilai MAPE terendah pada skenario 1 adalah 2.78% dengan menggunakan kernel RBF dengan nilai hyperparameter $C = 10$, $Epsilon = 0.1$, dan $Gamma$ bernilai 1 yang menunjukkan bahwa model ini menghasilkan tingkat kesalahan relatif yang rendah dalam memprediksi variabel LST, sehingga menunjukkan nilai kriteria model yang sangat baik berdasarkan Tabel 2.2.

4.4.2 Hasil pengujian Skenario 2

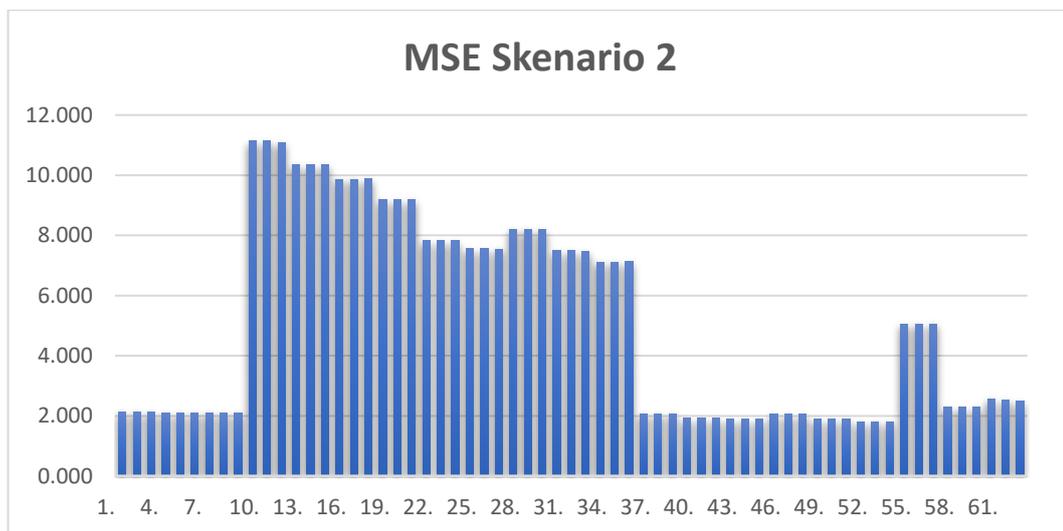
Dalam skenario 2, pengujian rasio splitting data yang digunakan adalah 80:20, dengan 6800 data training dan 1700 untuk data testing serta terdapat beberapa sub-skenario pengujian berupa pemilihan parameter dan kernel untuk pengujian yang terdapat pada Lampiran 1. Waktu yang diperlukan untuk mendapatkan hasil pengujian skenario 2 sekitar 4 menit, hanya selisih 1 menit jika dibandingkan dengan skenario 1. Berikut ini, hasil evaluasi pengujian skenario 2:



Gambar 4. 6 Evaluasi Performa R² Skenario 2

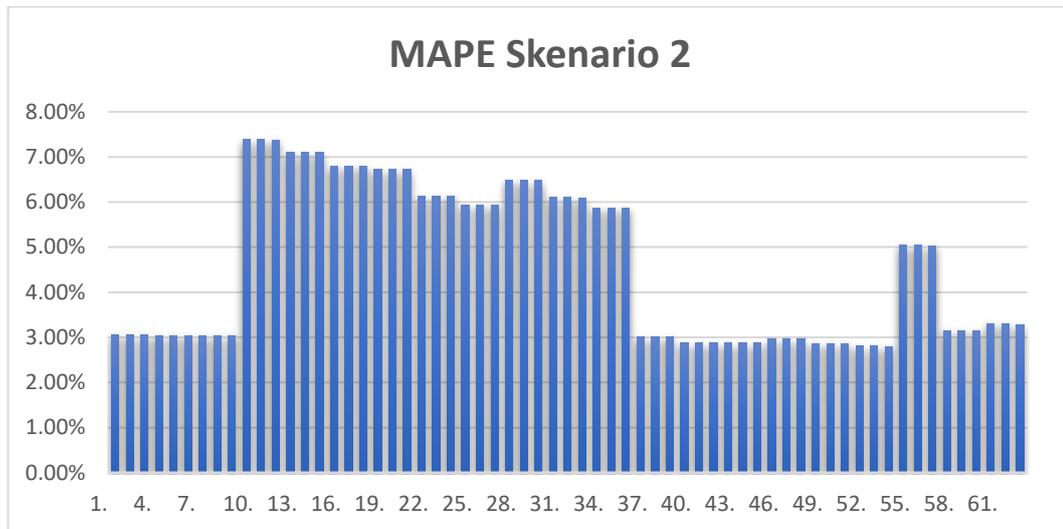
Gambar 4.6 menunjukkan evaluasi nilai performa pengujian dengan menggunakan R². Dengan menggunakan kernel linier didapatkan nilai R² tertinggi sebesar 0.851 dengan menggunakan konfigurasi hyperparameter $C = 1$ dan $Epsilon = 0.0001$. Sedangkan jika menggunakan kernel *Polynomial* didapatkan nilai R² tertinggi sebesar 0.498 dengan menggunakan hyperparameter $C = 10$, $Epsilon = 0.001$, dan $Degree$ senilai 8. Selanjutnya, jika menggunakan kernel RBF didapatkan nilai R² tertinggi sebesar 0.873 dengan menggunakan hyperparameter $C = 10$, $Epsilon = 0.1$, dan $Gamma$ bernilai 1. Jadi nilai R2 tertinggi pada skenario 2 adalah

0.878 dengan menggunakan kernel RBF dengan nilai hyperparameter $C = 10$, $Epsilon = 0.1$, dan $Gamma$ bernilai 1 yang menunjukkan bahwa model ini memiliki hubungan yang sangat kuat/sempurna antara variabel yang digunakan dalam model.



Gambar 4. 7 Evaluasi Performa MSE Skenario 2

Gambar 4.7 menunjukkan evaluasi nilai performa pengujian dengan menggunakan Mean Squared Error (MSE). Dengan menggunakan kernel linier, didapatkan nilai MSE terendah sebesar 2.107 dengan konfigurasi hyperparameter $C = 1$ dan $Epsilon = 0.0001$. Ketika menggunakan kernel Polynomial, nilai MSE tertinggi sebesar 7.105 dengan hyperparameter $C = 10$, $Epsilon = 0.001$, dan $Degree$ senilai 8. Selanjutnya, jika menggunakan kernel RBF, didapatkan nilai MSE terendah sebesar 1.797 dengan hyperparameter $C = 10$, $Epsilon = 0.1$, dan $Gamma$ bernilai 1. Jadi, nilai MSE terendah pada skenario ini adalah 1.797 dengan menggunakan kernel RBF, dengan hyperparameter $C = 10$, $Epsilon = 0.1$, dan $Gamma$ bernilai 1. Hal ini menunjukkan bahwa model ini memiliki tingkat kesalahan prediksi yang rendah, serta menunjukkan kualitas prediksi yang baik.

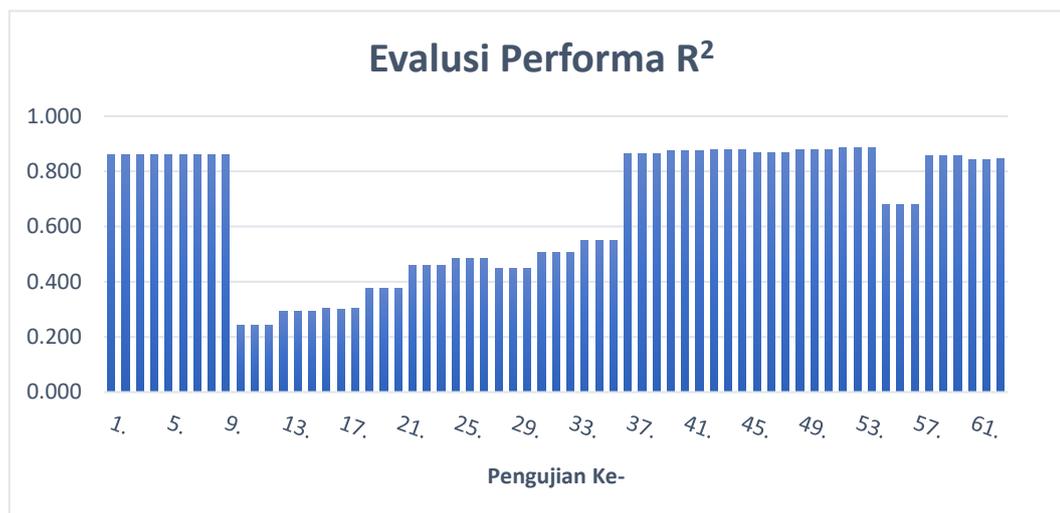


Gambar 4. 8 Evaluasi Performa MAPE Skenario 2

Gambar 4.8 menunjukkan evaluasi nilai performa pengujian dengan menggunakan MAPE. Dengan menggunakan kernel linier didapatkan nilai MAPE terendah sebesar 3.04% dengan menggunakan konfigurasi hyperparameter $C = 1$ dan $Epsilon = 0.0001$. Sedangkan jika menggunakan kernel *Polynomial* didapatkan nilai MAPE terendah sebesar 5.87% dengan menggunakan hyperparameter $C = 10$, $Epsilon = 0.001$, dan $Degree$ senilai 8. Selanjutnya, jika menggunakan kernel RBF didapatkan nilai MAPE terendah sebesar 2.80% dengan menggunakan hyperparameter $C = 10$, $Epsilon = 0.1$, dan $Gamma$ bernilai 1. Jadi nilai MAPE terendah pada skenario 2 adalah 2.80% dengan menggunakan kernel RBF dengan nilai hyperparameter $C = 10$, $Epsilon = 0.1$, dan $Gamma$ bernilai 1 yang menunjukkan bahwa model ini menghasilkan tingkat kesalahan relatif yang rendah dalam memprediksi variabel LST, sehingga menunjukkan nilai kriteria model yang sangat baik berdasarkan Tabel 2.2.

4.4.3 Hasil pengujian Skenario 3

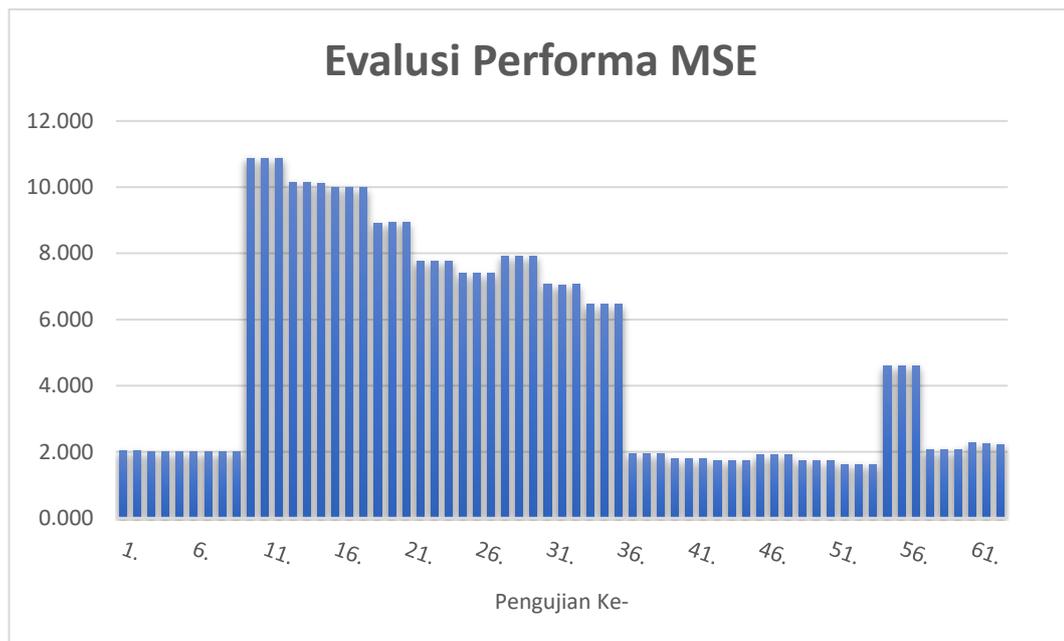
Dalam skenario 3, pengujian rasio splitting data yang digunakan adalah 90:10, dengan 7650 data training dan 850 untuk data testing serta terdapat beberapa sub-skenario pengujian berupa pemilihan parameter dan kernel untuk pengujian yang terdapat pada Lampiran 1. Waktu yang diperlukan untuk mendapatkan hasil pengujian skenario 3 sekitar 5 menit, hanya selisih 2 menit jika dibandingkan dengan skenario 1 dan selisih 1 menit jika dibandingkan dengan skenario 2. Berikut ini, hasil evaluasi pengujian skenario 3:



Gambar 4. 9 Evaluasi Performa R² Skenario 3

Gambar 4.9 menunjukkan evaluasi nilai performa pengujian dengan menggunakan R². Dengan menggunakan kernel linier didapatkan nilai R² tertinggi sebesar 0.859 dengan menggunakan konfigurasi hyperparameter C = 1 dan *Epsilon* = 0.0001. Sedangkan jika menggunakan kernel *Polynomial* didapatkan nilai R² tertinggi sebesar 0.549 dengan menggunakan hyperparameter C = 10, *Epsilon* = 0.001, dan *Degree* senilai 8. Selanjutnya, jika menggunakan kernel RBF didapatkan nilai R² tertinggi sebesar 0.887 dengan menggunakan hyperparameter C = 10,

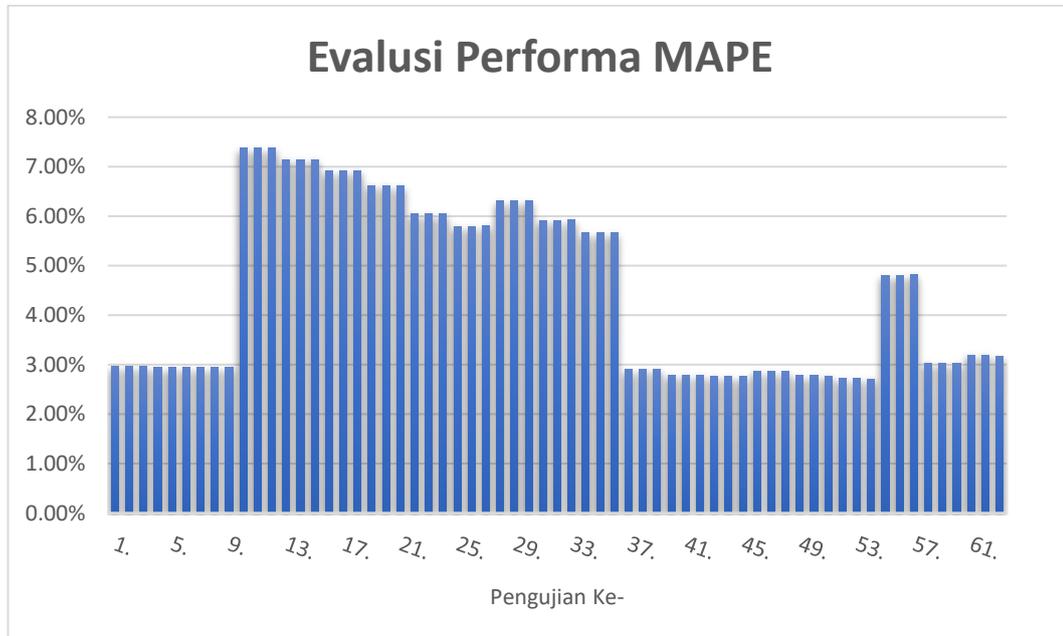
$Epsilon = 0.1$, dan $Gamma$ bernilai 1. Jadi nilai R^2 tertinggi pada skenario 3 adalah 0.887 dengan menggunakan kernel RBF dengan nilai hyperparameter $C = 10$, $Epsilon = 0.1$, dan $Gamma$ bernilai 1 yang menunjukkan bahwa model ini memiliki hubungan yang sangat kuat/sempurna antara variabel yang digunakan dalam model.



Gambar 4.10 Evaluasi Performa MSE Skenario 3

Gambar 4.10 menunjukkan evaluasi nilai performa pengujian dengan menggunakan Mean Squared Error (MSE). Dengan menggunakan kernel linier, didapatkan nilai MSE terendah sebesar 1.999 dengan konfigurasi hyperparameter $C = 1$ dan $Epsilon = 0.0001$. Ketika menggunakan kernel Polynomial, nilai MSE tertinggi sebesar 6.466 dengan hyperparameter $C = 10$, $Epsilon = 0.001$, dan $Degree$ senilai 8. Selanjutnya, jika menggunakan kernel RBF, didapatkan nilai MSE terendah sebesar 1.625 dengan hyperparameter $C = 10$, $Epsilon = 0.1$, dan $Gamma$ bernilai 1. Jadi, nilai MSE terendah pada skenario ini adalah 1.625 dengan menggunakan kernel RBF, dengan hyperparameter $C = 10$, $Epsilon = 0.1$, dan

Γ bernilai 1. Hal ini menunjukkan bahwa model ini memiliki tingkat kesalahan prediksi yang rendah, serta menunjukkan kualitas prediksi yang baik.



Gambar 4. 11 Evaluasi Performa MAPE Skenario 3

Gambar 4.11 menunjukkan evaluasi nilai performa pengujian dengan menggunakan MAPE. Dengan menggunakan kernel linier didapatkan nilai MAPE terendah sebesar 2.49% dengan menggunakan konfigurasi hyperparameter $C = 1$ dan $Epsilon = 0.0001$. Sedangkan jika menggunakan kernel *Polynomial* didapatkan nilai MAPE terendah sebesar 5.66% dengan menggunakan hyperparameter $C = 10$, $Epsilon = 0.001$, dan $Degree$ senilai 8. Selanjutnya, jika menggunakan kernel RBF didapatkan nilai MAPE terendah sebesar 2.71% dengan menggunakan hyperparameter $C = 10$, $Epsilon = 0.1$, dan Γ bernilai 1. Jadi nilai MAPE terendah pada skenario 3 adalah 2.71 dengan menggunakan kernel RBF dengan nilai hyperparameter $C = 10$, $Epsilon = 0.1$, dan Γ bernilai 1 yang menunjukkan bahwa model ini menghasilkan tingkat kesalahan relatif yang rendah

dalam memprediksi variabel LST, sehingga menunjukkan nilai kriteria model yang sangat baik berdasarkan Tabel 2.2.

4.5 Analisis Dan Pembahasan Hasil Pengujian

Pada penelitian ini, terdapat tiga skenario utama dengan melakukan splitting data dengan rasio yang berbeda untuk menentukan skenario yang menghasilkan evaluasi performa yang paling optimal dalam penggunaan metode SVR untuk memprediksi fenomena UHI di Kota Malang. Pada setiap skenario terdapat sub-skenario yang telah dilakukan pengujian dengan menerapkan tiga jenis kernel yaitu linier, *Polynomial* dan RBF beserta variasi nilai parameter *Cost*, *Epsilon*, *Degree* dan *Gamma* untuk menemukan tuning parameter yang menghasilkan hasil pengujian performa terbaik.

Pada skenario 1 dengan menggunakan splitting data rasio 70:30, penggunaan kernel RBF dengan hyperparameter nilai $C = 10$, $Epsilon = 0.1$ dan $Gamma$ senilai 1, mampu menghasilkan performa yang terbaik jika dibandingkan dengan variasi penggunaan kernel dan hyperparameter lainnya. Kernel RBF dinilai sangat cocok pada penelitian ini karena pola pemisahan data yang digunakan lebih kompleks dibandingkan dengan kernel lainnya. Kernel RBF sangat sesuai digunakan pada permasalahan non-linear dengan data yang kompleks yang ditunjukkan dengan banyaknya fitur yang digunakan. Selain itu hyperparameter yang digunakan yaitu nilai *Cost*, *Epsilon* dan *Gamma* yang digunakan juga mendukung tingkat evaluasi kinerja model. Dengan menggunakan nilai *Cost* yang besar, mampu membuat model menjadi lebih sensitif terhadap kesalahan pengujian. Sehingga mampu mengarah pada pembentukan batas keputusan yang lebih ketat dan akurat. Selain

itu, penggunaan nilai *Epsilon* yang kecil, mampu menghasilkan batas keputusan yang lebih ketat di sekitar titik-titik dengan meminimalkan lebar margin pada model. Nilai *Epsilon* mampu membantu untuk melakukan penyesuaian data yang bervariasi serta menghindari *overfitting* pada model. Selain menggunakan nilai hyperparameter *Cost* dan *Epsilon*, penggunaan kernel RBF juga dilengkapi dengan menggunakan hyperparameter nilai *Gamma*. Penggunaan nilai *Gamma* yang tinggi mampu menghasilkan model yang lebih sensitif terhadap data serta mampu mengontrol pengaruh antara satu titik data terhadap titik lainnya. Nilai *Gamma* sangat cocok digunakan pada data yang memiliki kompleksitas tinggi.

Pada skenario 2 dengan rasio splitting data 80:20, menghasilkan performa terbaik pada penggunaan kernel RBF dengan hyperparameter $C = 10$, $Epsilon = 0.1$ dan *Gamma* senilai 1. Jika dibandingkan dengan skenario sebelumnya yaitu skenario 1, variasi kernel dan hyperparameter yang menghasilkan performa tertinggi, memiliki variasi yang sama. Hal ini menunjukkan bahwa perbedaan rasio dengan peningkatan jumlah data pengujian menjadi 20% serta pengurangan jumlah data latih menjadi 80% tidak berpengaruh terhadap kestabilan hasil performa model SVR dengan pemilihan kernel dan tuning parameter yang terbaik.

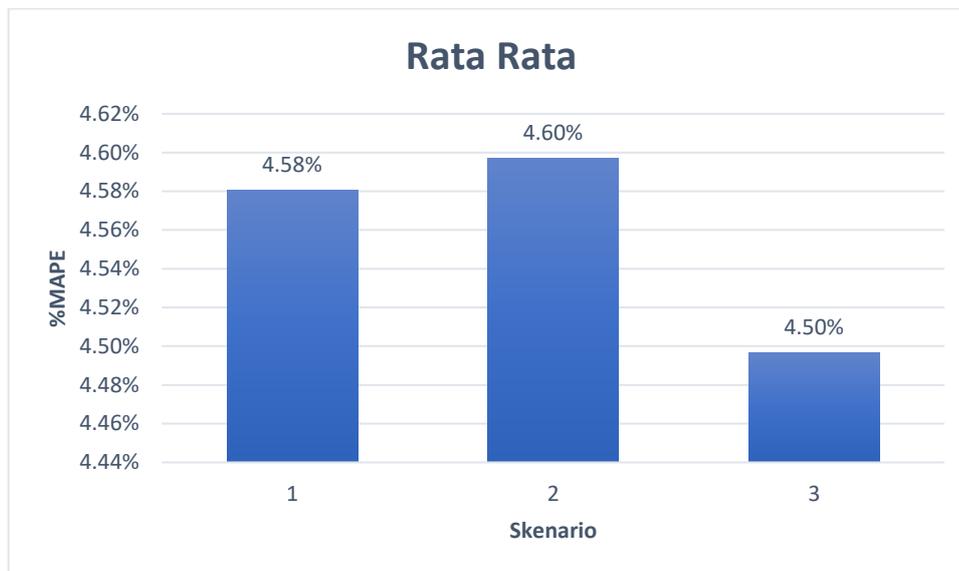
Skenario terakhir yang digunakan adalah dengan melakukan splitting data menggunakan rasio 90:10. Parameter dan kernel yang menghasilkan performa tertinggi, merupakan parameter dan kernel yang sama dengan 2 skenario sebelumnya yaitu menggunakan kernel RBF dengan nilai hyperparameter $C = 10$, $Epsilon = 0.1$ dan *Gamma* senilai 1. Bahkan pada rasio ini, nilai R^2 juga memiliki peningkatan menjadi 0.887, Begitu juga dengan nilai MAPE dan MSE mengalami

penurunan menjadi 2.71% dan 1.625. Akan tetapi membuktikan adanya perubahan dengan adanya perubahan rasio splitting data.

Pengujian Rasio data ditujukan untuk menguji konsistensi performa model pada beragam proporsi data latih dan uji. Performa model yang konsisten meski proporsi data uji ditingkatkan mengindikasikan model terlatih dengan baik sehingga mampu generalisasi dengan akurat pada data baru. Dalam hal ini, pengujian rasio data yang terdapat pada Lampiran 1 dibuat untuk membantu memvalidasi kemampuan model untuk menghadapi variasi dalam distribusi data uji. Model yang memiliki rata-rata MAPE rendah dan standar deviasi yang rendah cenderung lebih dapat diandalkan dalam memprediksi data baru, karena kemampuannya untuk menghasilkan perkiraan yang konsisten dan akurat di berbagai situasi pengujian. MAPE memberikan pengukuran kesalahan relatif dalam bentuk persentase yang mudah dipahami, sensitif terhadap perbedaan magnitudo kesalahan, dan memperhatikan proporsi kesalahan relatif terhadap nilai aktual. Rata-rata MAPE yang rendah dan standar deviasi yang rendah akan menunjukkan kemampuan model untuk menghasilkan perkiraan yang konsisten dan akurat di berbagai situasi pengujian, memvalidasi generalisasi model pada data baru secara efektif.

Tabel 4. 4 Rata-rata dan standar deviasi MAPE per skenario

	%MAPE	
	Rata-Rata	Standar Deviasi
Skenario 1	4.58%	0.0174
Skenario 2	4.60%	0.0173
Skenario 3	4.50%	0.0175



Gambar 4. 12 Rata-rata MAPE per skenario

Pada pengujian skenario 3, dengan pengujian rasio 70:30 menunjukkan hasil rata-rata MAPE sebesar 4.58% dan standar deviasi sebesar 1.74. Sedangkan pengujian skenario 2, dengan pengujian rasio 80:20 menunjukkan hasil rata-rata MAPE sebesar 4.60% dan standar deviasi sebesar 1.74. Dan terakhir pada pengujian skenario 3, dengan pengujian rasio 90:10 menunjukkan hasil rata-rata MAPE sebesar 4.50% dan standar deviasi sebesar 1.76. Berdasarkan hasil tersebut, dapat disimpulkan bahwa model yang terbaik adalah model pada skenario 3 yaitu menggunakan rasio 90:10 yang ditunjukkan dengan rata-rata dan standar deviasi MAPE yang rendah. Dengan nilai rata-rata MAPE yang dihasilkan sebesar 4.58% yang menunjukkan bahwa antara nilai aktual dan nilai prediksi memiliki selisih yang bernilai kecil. Semakin kecil nilai MAPE, maka semakin kecil pula jarak antara nilai yang diprediksi oleh model dengan nilai aktualnya. Sehingga model prediksi pada skenario 1 dengan menggunakan nilai hyperparameter $C = 10$, $Epsilon = 0.1$ dan $Gamma$ senilai 1 memiliki performa yang baik. Selain itu,

dibuktikan dengan nilai standar deviasi yang kecil, yang menunjukkan bahwa hasil yang dihasilkan oleh model bernilai stabil.

Akan tetapi ketiga model memiliki kinerja yang stabil dan konsisten dalam memprediksi data uji pada proporsi data latih yang berbeda-beda (70:30, 80:20, dan 90:10). Meskipun ada sedikit variasi dalam standar deviasi MAPE antar skenario, peningkatan ini tidak signifikan sekitar 0.1% dan model dapat diandalkan untuk memberikan estimasi yang akurat pada data uji, tidak hanya pada satu proporsi tertentu. Oleh karena itu, hasil pengujian menunjukkan bahwa model telah terlatih dengan baik dan mampu generalisasi dengan efektif pada data baru, tanpa terlalu dipengaruhi oleh perubahan proporsi data latih dan uji.

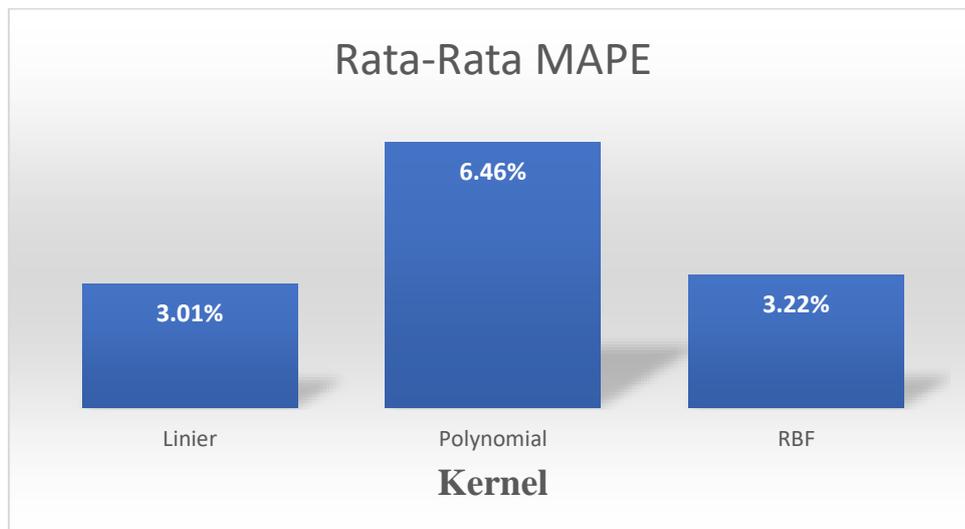
Selain menggunakan perbedaan pada rasio data yang digunakan, pada penelitian ini juga menggunakan 3 kernel yang berbeda. Jenis kernel ini yang nantinya akan menentukan bentuk transformasi data ke dimensi lainnya yang lebih tinggi. Secara umum, berdasarkan hasil pengujian jenis kernel yang menghasilkan nilai MAPE yang rendah secara berurutan adalah kernel RBF, Linier dan *Polynomial*. Kernel RBF memberikan hasil terbaik dengan nilai MAPE yang paling rendah, MSE yang lebih kecil, dan R-squared yang lebih tinggi dibandingkan dengan kernel linier dan *Polynomial*. Hal ini disebabkan oleh kemampuan kernel RBF dalam menangani pola non-linear yang kompleks pada data gambar medis. Dengan memetakan data ke dalam ruang fitur tak terhingga, kernel RBF mampu menyesuaikan pemisahan kelas dengan lebih baik tanpa perlu penyetelan parameter derajat seperti pada kernel *Polynomial*. kernel linier memberikan performa yang lebih baik daripada kernel *Polynomial* dengan nilai MAPE dan MSE yang lebih

rendah serta R-squared yang lebih tinggi. Meskipun tidak mampu menangani pola non-linear dengan baik seperti kernel RBF, kernel linier masih efektif untuk data yang dapat dipisahkan secara linier. Kernel linier memberikan interpretasi yang mudah dan komputasi yang lebih efisien dibandingkan dengan kernel *Polynomial*. Sedangkan, kernel *Polynomial* menunjukkan hasil yang paling rendah dalam hal MAPE dan MSE, serta nilai R-squared yang lebih rendah dibandingkan dengan kernel lainnya. Hal ini disebabkan oleh sensitivitas kernel *Polynomial* terhadap pemilihan derajat *Polynomial* yang tepat.

Akan tetapi, untuk menganalisis kernel yang memiliki performa terbaik, dibuktikan melalui pengujian yang terdapat pada Lampiran 2 untuk konsistensi performa kernel. Kernel yang memiliki konsistensi performa, ketika parameter yang digunakan berubah, menunjukkan kemampuan kernel mampu melakukan generalisasi yang baik pada data yang baru. Kernel yang memiliki rata-rata dan standar deviasi mape yang rendah menunjukkan bahwa kernel tersebut konsisten dalam melakukan prediksi sehingga hasil prediksinya dalam kondisi stabil.

Tabel 4. 5 Rata-rata dan standar deviasi MAPE setiap kernel pada skenario 1

	Skenario 1	
	Rata-Rata	Standar Deviasi
Kernel Linier	3.01%	0.000054
Kernel <i>Polynomial</i>	6.46%	0.005438
Kernel RBF	3.22%	0.007823

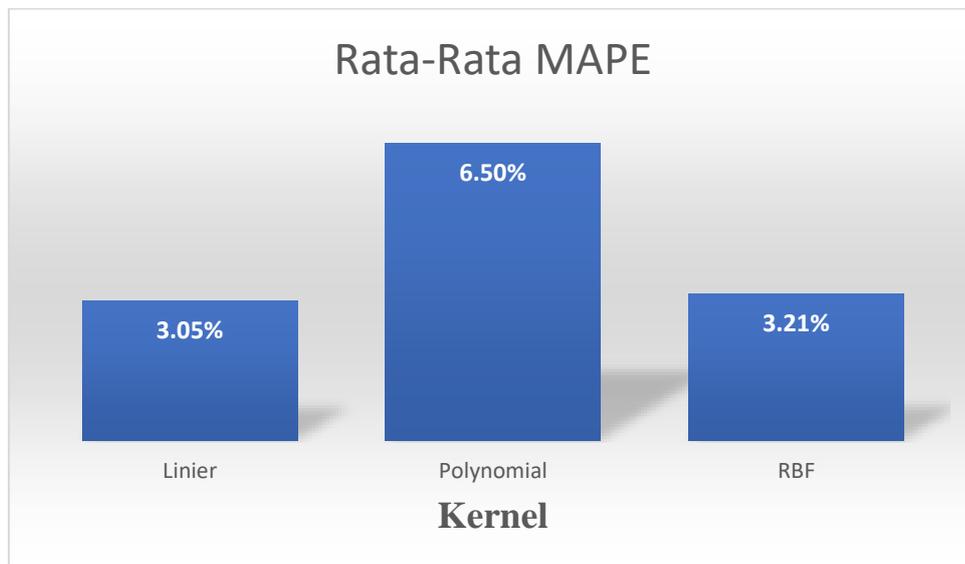


Gambar 4. 13 Rata-rata MAPE setiap kernel pada skenario 1

Pada skenario 1 dengan rasio splitting data 70:30, kernel Linier menunjukkan performa yang sangat baik dengan rata-rata MAPE yang rendah (3.01%) dan standar deviasi MAPE yang sangat kecil (0.000054). Sedangkan pada Kernel *Polynomial* pada skenario ini menunjukkan rata-rata MAPE yang lebih tinggi (6.46%) dibandingkan Kernel Linier. Pada Kernel RBF, juga menunjukkan performa yang baik dengan rata-rata MAPE yang rendah (3.22%), meskipun sedikit lebih tinggi daripada Linear Kernel.

Tabel 4. 6 Rata-rata dan standar deviasi MAPE setiap kernel pada skenario 2

	Skenario 2	
	Rata-Rata	Standar Deviasi
Kernel Linier	3.05%	0.000059
Kernel <i>Polynomial</i>	6.50%	0.005048
Kernel RBF	3.21%	0.006630

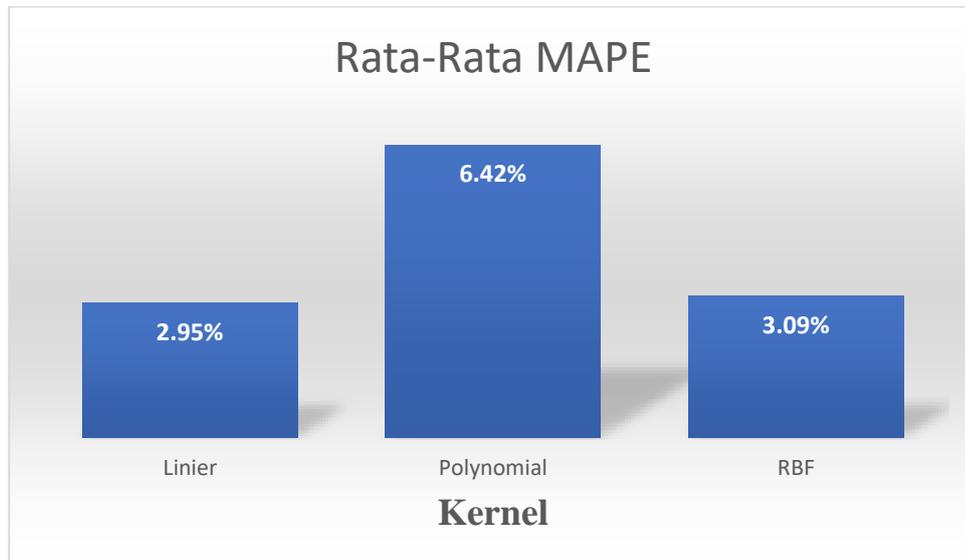


Gambar 4. 14 Rata-rata MAPE setiap kernel pada skenario 2

Pada skenario 2 dengan rasio splitting data 80:20, kernel Linier terus menunjukkan performa yang sangat baik dengan rata-rata MAPE yang rendah (3.05%) dan standar deviasi MAPE yang sangat kecil (0.000059). Sedangkan pada Kernel *Polynomial* pada skenario ini menunjukkan rata-rata MAPE yang lebih tinggi (6.50%) dibandingkan Kernel Linier. Pada Kernel RBF, juga menunjukkan performa yang baik dengan rata-rata MAPE yang rendah (3.21%), meskipun sedikit lebih tinggi daripada Linear Kernel.

Tabel 4. 7 Rata-rata dan standar deviasi MAPE setiap kernel pada skenario 3

	Skenario 3	
	Rata-Rata	Standar Deviasi
Kernel Linier	2.95%	0.000018
Kernel <i>Polynomial</i>	6.42%	0.000008
Kernel RBF	3.09%	0.000005



Gambar 4. 15 Rata-rata MAPE setiap kernel pada skenario 3

Pada skenario 3 dengan rasio splitting data 70:30, menegaskan Kembali bahwa kernel Linier menunjukkan performa yang sangat baik dengan rata-rata MAPE yang rendah (2.95%) dan standar deviasi MAPE yang sangat kecil (0.000018). Sedangkan pada Kernel *Polynomial* pada skenario ini masih menunjukkan rata-rata MAPE yang lebih tinggi (6.42%) dibandingkan Kernel Linier. Pada Kernel RBF, juga menunjukkan performa yang baik dengan rata-rata MAPE yang rendah (3.09%), meskipun sedikit lebih tinggi daripada Linear Kernel.

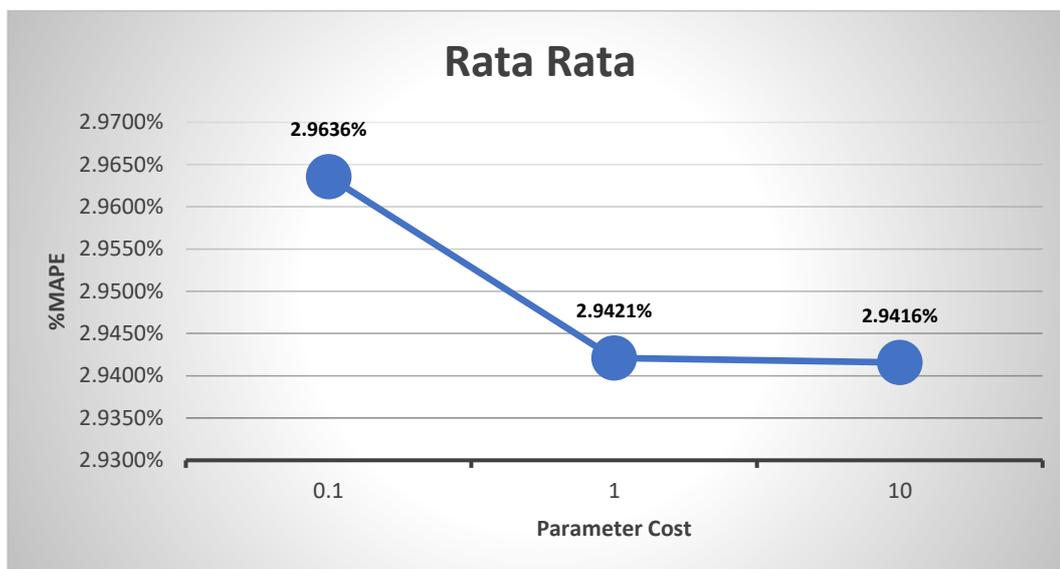
Meskipun Kernel RBF memiliki nilai MAPE yang terendah pada setiap skenario dan nilai rata-rata MAPE juga cenderung rendah dalam beberapa skenario, akan tetapi nilai standar deviasi MAPE yang lebih tinggi menunjukkan variasi performa yang lebih besar. Sehingga dapat disimpulkan bahwa, Kernel Linier secara konsisten menunjukkan performa yang baik dengan nilai rata-rata MAPE rendah dan stabilitas yang tinggi.

Dalam SVR, nilai *Cost* berfungsi sebagai parameter yang mengontrol kompromi antara kesalahan pada data pelatihan dan kompleksitas model. Semakin besar nilai *C*, semakin kecil margin hyperplane yang dihasilkan, sehingga model menjadi lebih ketat terhadap data pelatihan dan mungkin lebih akurat. Namun, hal ini juga meningkatkan risiko *overfitting*, di mana model terlalu memperhatikan detail dari data pelatihan dan mungkin tidak dapat umum. Sebaliknya, nilai *C* yang lebih kecil menghasilkan margin yang lebih besar dan model yang lebih umum, namun mungkin kurang akurat terhadap data pelatihan. Dalam konteks ini, penggunaan nilai $C=10$ yang merupakan nilai *C* tertinggi pada hyperparameter pengujian, terbukti efektif karena menghasilkan model yang sensitif dalam mengurangi kesalahan pada data pelatihan dan pengujian.

Untuk menganalisis nilai *Cost* yang terbaik pada pengujian ini, dapat dibuktikan yang terdapat pada Lampiran 3 untuk melihat konsistensi nilai rata-rata MAPE dan standar deviasi pada seitan kernel dan skenario yang terbaik yaitu skenario 3.

Tabel 4. 8 Rata-rata dan standar deviasi MAPE nilai *Cost* pada Kernel Linier

<i>Cost</i>	Kernel Linier	
	Rata-Rata	Standar Deviasi
0.1	2.9636%	0.000018
1	2.9421%	0.000008
10	2.9416%	0.000005

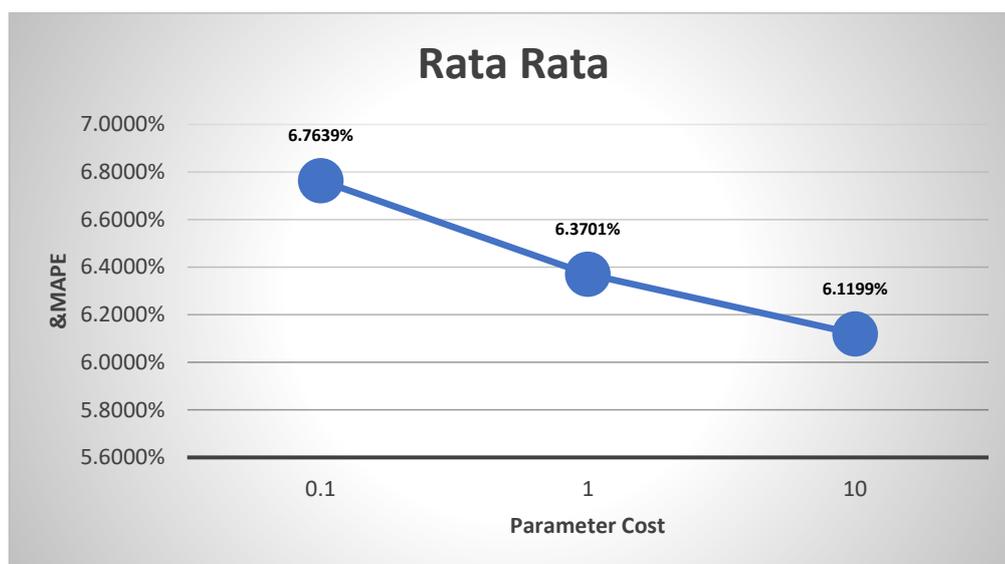


Gambar 4. 16 Rata-rata MAPE nilai *Cost* pada Kernel Linier

Pada jenis kernel Linear dengan $Cost = 0.1$, nilai rata-rata MAPE sebesar 2.96% dengan standar deviasi MAPE yang sangat rendah, hanya 0.000018. Hal ini menunjukkan bahwa model Linear dengan $Cost = 0.1$ memberikan performa yang baik dalam memprediksi data dengan tingkat kesalahan yang rendah. Ketika nilai $Cost$ ditingkatkan menjadi 1, rata-rata MAPE sedikit menurun menjadi 2.94%, tetapi standar deviasi MAPE juga tetap sangat rendah, hanya 0.000008. Ini menunjukkan bahwa perubahan nilai $Cost$, tidak terlalu berpengaruh dalam meningkatkan kinerja model Linear. Dengan nilai $Cost$ yang lebih tinggi (10), rata-rata MAPE tetap stabil di 2.94% dengan standar deviasi MAPE yang semakin rendah, yaitu 0.000005. Hal ini menunjukkan bahwa model Linear dapat mempertahankan performa yang konsisten bahkan dengan nilai $Cost$ yang lebih tinggi, menunjukkan bahwa kompleksitas model yang lebih tinggi tidak diperlukan untuk mencapai tingkat prediksi yang baik.

Tabel 4. 9 Rata-rata dan standar deviasi MAPE nilai *Cost* pada Kernel Polynomial

<i>Cost</i>	Kernel Polynomial	
	Rata-Rata	Standar Deviasi
0.1	6.7639%	0.004493
1	6.3701%	0.005499
10	6.1199%	0.005593

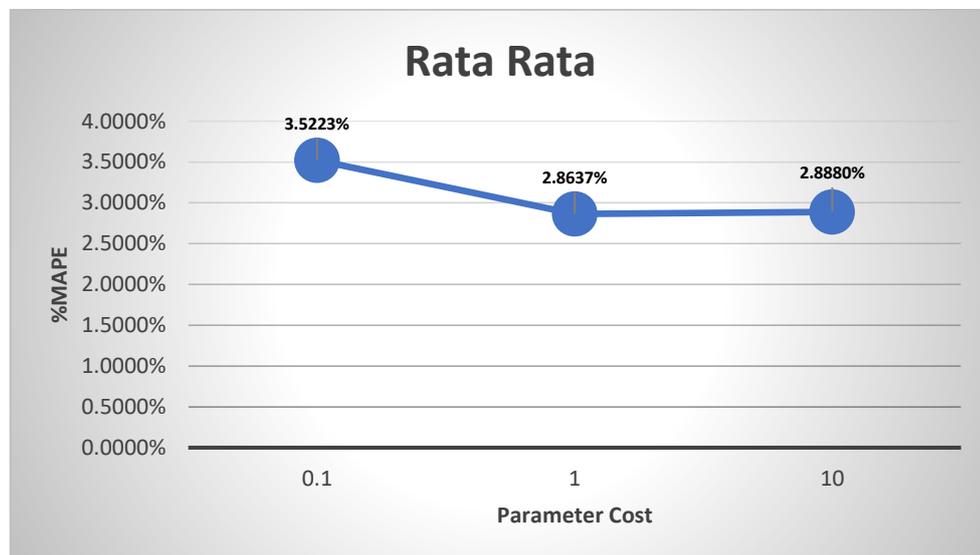
Gambar 4. 17 Rata-rata MAPE nilai *Cost* pada Kernel Polynomial

Pada jenis kernel *Polynomial* dengan *Cost* = 0.1, rata-rata MAPE mencapai 6.76% dengan standar deviasi MAPE sebesar 0.004493. Model *Polynomial* dengan *Cost* rendah cenderung memiliki tingkat kesalahan yang lebih tinggi dan variasi prediksi yang lebih besar. Ketika nilai *Cost* ditingkatkan menjadi 1, rata-rata MAPE sedikit menurun menjadi 6.37%, tetapi standar deviasi MAPE juga meningkat menjadi 0.005499. Hal ini menunjukkan bahwa peningkatan *Cost* memperbaiki sedikit performa model *Polynomial* namun dengan peningkatan variasi dalam prediksi. Dengan nilai *Cost* yang lebih tinggi (10), rata-rata MAPE menjadi 6.12% dengan standar deviasi MAPE yang cenderung stabil di sekitar 0.005593. Meskipun

peningkatan *Cost* membantu memperbaiki performa model *Polynomial*, tingkat kesalahan prediksi masih cukup tinggi.

Tabel 4. 10 Rata-rata dan standar deviasi MAPE nilai *Cost* pada Kernel RBF

<i>Cost</i>	Kernel RBF	
	Rata-Rata	Standar Deviasi
0.1	3.5223%	0.009053
1	2.8637%	0.001157
10	2.8880%	0.002098



Gambar 4. 18 Rata-rata MAPE nilai *Cost* pada Kernel RBF

Dengan nilai *Cost* yang lebih tinggi (10), rata-rata MAPE menjadi 6.12% dengan standar deviasi MAPE yang cenderung stabil di sekitar 0.005593. Meskipun peningkatan *Cost* membantu memperbaiki performa model *Polynomial*, tingkat kesalahan prediksi masih cukup tinggi. Ketika nilai *Cost* ditingkatkan menjadi 1, terjadi sedikit perubahan sekitar 0.7% dalam performa model RBF dengan rata-rata MAPE yang turun menjadi 2.86% dan standar deviasi MAPE yang turun menjadi 0.001157. Hal ini menunjukkan bahwa peningkatan *Cost* secara positif memengaruhi performa dan konsistensi prediksi model RBF. Dengan nilai *Cost*

yang lebih tinggi (10), performa model RBF semakin meningkat dengan rata-rata MAPE yang tetap rendah di 2.89% dan standar deviasi MAPE yang stabil di sekitar 0.002098. Hal ini menunjukkan bahwa nilai *Cost* yang tinggi membantu meningkatkan kinerja dan konsistensi model RBF dalam melakukan prediksi.

Dapat disimpulkan bahwa penyesuaian nilai *Cost* pada masing-masing jenis kernel memiliki dampak yang berbeda terhadap performa dan konsistensi model. Kernel RBF menunjukkan peningkatan performa yang signifikan dengan peningkatan *Cost*, sementara Kernel Linear tetap stabil dan konsisten bahkan dengan nilai *Cost* yang rendah. Kernel *Polynomial*, meskipun mendapatkan sedikit peningkatan dengan *Cost* yang lebih tinggi, masih memiliki tingkat kesalahan prediksi yang tinggi dan variasi yang signifikan. Penyesuaian parameter seperti *Cost* dapat menjadi strategi penting dalam memilih dan mengoptimalkan jenis kernel yang sesuai

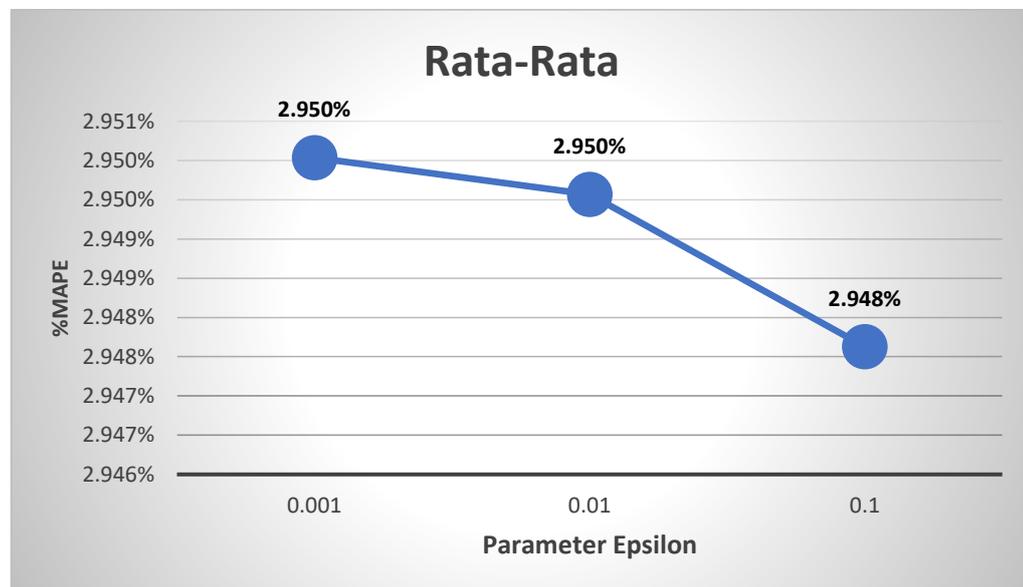
Selain nilai *Cost*, terdapat juga parameter *Epsilon* yang penting terutama dalam kernel RBF. Nilai *Epsilon* mengontrol lebar margin pada model, yaitu jarak antara hyperplane dan titik-titik pendukung (support vectors). Semakin kecil nilai *Epsilon*, maka margin akan lebih ketat di sekitar titik-titik pendukung, yang membantu menyesuaikan model secara tepat terhadap variasi data. Namun, nilai *Epsilon* yang terlalu kecil juga dapat membuat model terlalu fokus pada detail data pelatihan dan berisiko *overfitting*.

Untuk menganalisis nilai *Epsilon* yang terbaik pada pengujian ini, dapat dibuktikan yang terdapat pada Lampiran 4 untuk mengetahui konsistensi nilai rata-

rata MAPE dan standar deviasi pada seitan kernel dan skenario yang terbaik yaitu skenario 3.

Tabel 4. 11 Rata-rata dan standar deviasi MAPE nilai *Epsilont* pada Kernel Linier

<i>Epsilon</i>	Kernel Linier	
	Rata-Rata	Standar Deviasi
0.001	2.950%	0.00011
0.01	2.950%	0.00010
0.1	2.948%	0.00009

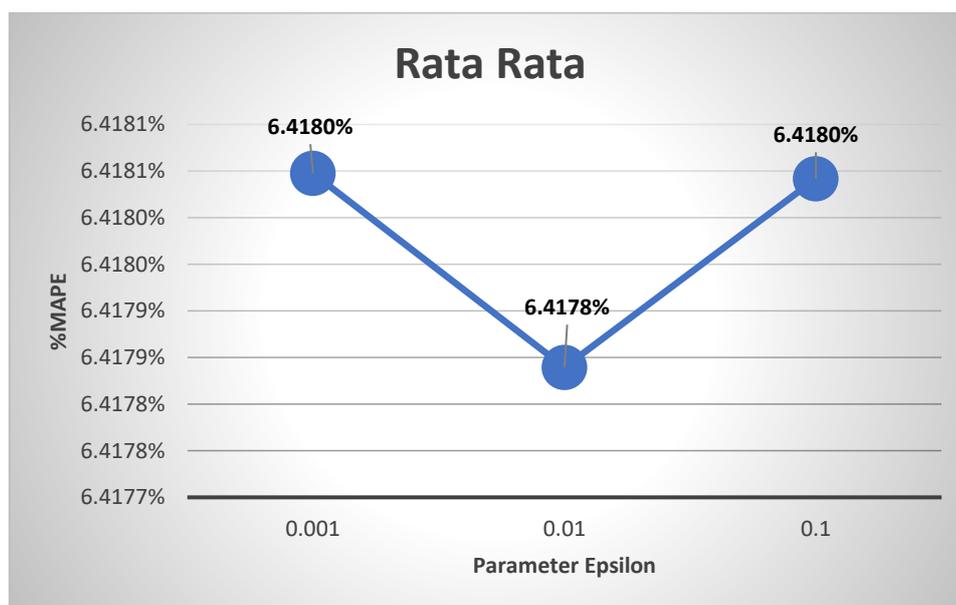


Gambar 4. 19 Rata-rata MAPE berdasarkan perubahan nilai *Epsilont* pada Kernel Linier

Pada kernel Linier, hyperparameter dengan nilai *Epsilon* = 0.001 menghasilkan performa prediksi yang baik dan konsisten dengan rata-rata MAPE sekitar 2.950% dan standar deviasi MAPE sekitar 0.00011. Ketika nilai *Epsilon* ditingkatkan menjadi 0.01 dan 0.1, rata-rata MAPE masih tetap rendah di sekitar 2.950% dan 2.948% dengan standar deviasi MAPE yang semakin rendah. Hal ini menunjukkan bahwa performa dan konsistensi prediksi model Linear tetap baik bahkan dengan nilai *Epsilon* yang lebih tinggi.

Tabel 4. 12 Rata-rata dan standar deviasi MAPE nilai *Epsilon* pada Kernel Polynomial

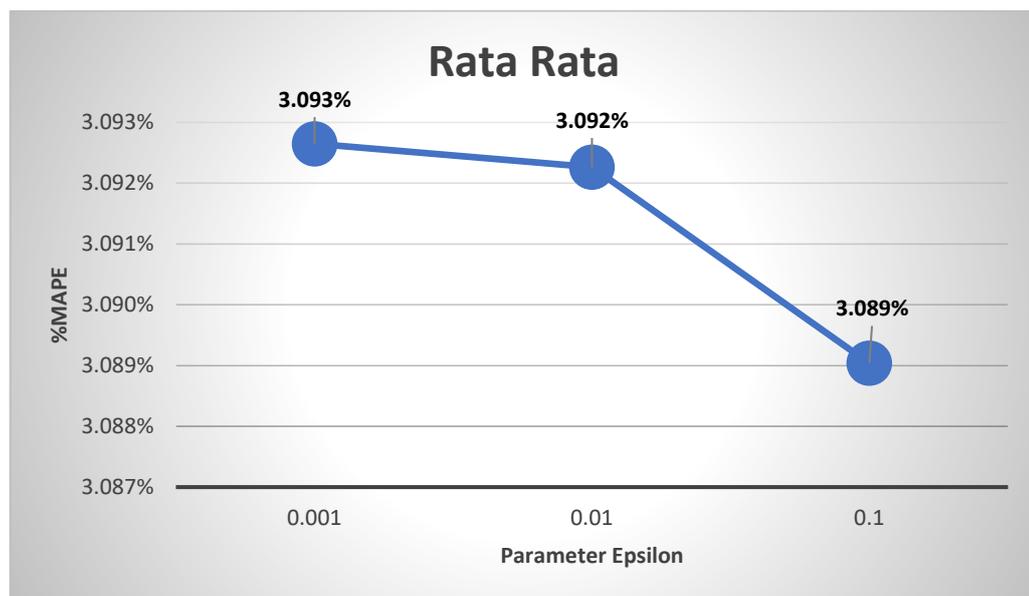
<i>Epsilon</i>	Kernel Polynomial	
	Rata-Rata	Standar Deviasi
0.001	6.4180%	0.00585
0.01	6.4178%	0.00585
0.1	6.4180%	0.00585

Gambar 4. 20 Rata-rata MAPE berdasarkan perubahan nilai *Epsilon* pada Kernel Polynomial

Sementara itu, pada kernel *Polynomial* dengan nilai *Epsilon* yang terendah yaitu 0.001, nilai rata-rata MAPE yang lebih tinggi sekitar 6.4180% dengan standar deviasi MAPE yang cukup tinggi. Ketika nilai *Epsilon* sedikit ditingkatkan menjadi 0.01, rata-rata MAPE tetap stabil di sekitar 6.4178%, tetapi standar deviasi MAPE juga tetap tinggi. Akan tetapi pada nilai *Epsilon* yang lebih tinggi (0.1), rata-rata MAPE mengalami sedikit kenaikan dan masih tetap tinggi yaitu 6.4180% dengan standar deviasi MAPE yang stabil. Hal ini menunjukkan bahwa performa model *Polynomial* tidak banyak berubah dengan perubahan *Epsilon*.

Tabel 4. 13 Rata-rata dan standar deviasi MAPE nilai *Epsilon* pada Kernel RBF

<i>Epsilon</i>	Kernel RBF	
	Rata-Rata	Standar Deviasi
0.001	3.093%	0.00585
0.01	3.092%	0.00585
0.1	3.089%	0.00585

Gambar 4. 21 Rata-rata MAPE berdasarkan perubahan nilai *Epsilon* pada Kernel RBF

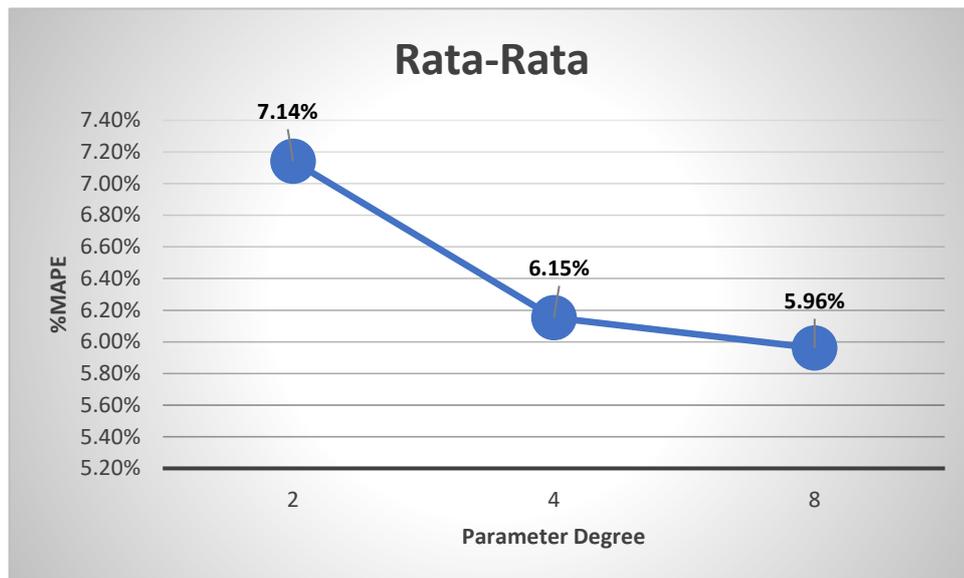
Pada jenis kernel RBF dengan $Epsilon = 0.001$, rata-rata MAPE cukup tinggi sekitar 3.093% dengan standar deviasi MAPE yang cukup tinggi. Ketika nilai *Epsilon* sedikit ditingkatkan menjadi 0.01, rata-rata MAPE tetap stabil di sekitar 3.092%, tetapi standar deviasi MAPE juga tetap tinggi. Dengan nilai *Epsilon* yang lebih tinggi (0.1), rata-rata MAPE sedikit lebih rendah di sekitar 3.089% dengan standar deviasi MAPE yang stabil. Hal ini menunjukkan bahwa performa model RBF sedikit lebih baik dengan *Epsilon* yang lebih tinggi, namun variasi prediksi tetap tinggi.

Dari penjelasan di atas, dapat disimpulkan bahwa nilai *Epsilon* memiliki dampak yang berbeda tergantung pada jenis kernel yang digunakan. Kernel Linear menunjukkan performa yang stabil dan konsisten dengan perubahan *Epsilon*, sedangkan Kernel *Polynomial* dan RBF cenderung memiliki tingkat kesalahan yang lebih tinggi dan variasi yang lebih besar, terlepas dari nilai *Epsilon* yang digunakan. Oleh karena itu, penting untuk memilih nilai *Epsilon* yang tepat untuk memastikan keseimbangan yang baik antara generalisasi dan ketepatan prediksi pada model yang dikembangkan.

Pada kernel *Polynomial*, hyperparameter yang digunakan tidak hanya nilai *Cost* dan *Epsilon* saja, hyperparameter *Degree* juga digunakan pada pengujian penelitian ini. Berikut ini analisis hasil pengujian berdasarkan pada nilai rata-rata dan standar deviasi MAPE yang terdapat pada Lampiran 6 untuk mengetahui kestabilan dan konsistensinya.

Tabel 4. 14 Rata-rata dan standar deviasi MAPE nilai *Degree* pada Kernel *Polynomial*

<i>Degree</i>	Kernel <i>Polynomial</i>	
	Rata-Rata	Standar Deviasi
2	7.14%	0.0019
4	6.15%	0.0034
8	5.96%	0.0027



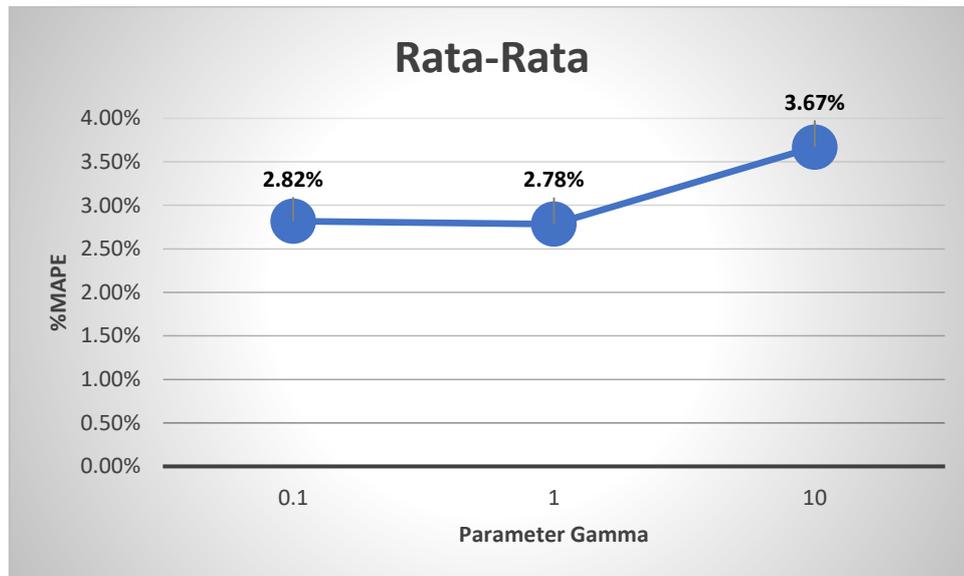
Gambar 4. 22 Rata-rata MAPE berdasarkan perubahan nilai Degree pada Kernel Polynomial

Dengan $Degree = 2$, rata-rata MAPE adalah 7.14% dengan standar deviasi MAPE 0.0019. Model *Polynomial* dengan $Degree$ rendah cenderung memiliki tingkat kesalahan yang cukup tinggi namun dengan variasi prediksi yang relatif rendah. Jika menggunakan nilai $Degree = 4$, rata-rata MAPE menurun menjadi 6.15% namun standar deviasi MAPE meningkat menjadi 0.0034. Peningkatan $Degree$ membantu memperbaiki performa model *Polynomial* namun dengan peningkatan variasi dalam prediksi. Sedangkan jika menggunakan nilai $Degree = 8$, rata-rata MAPE turun menjadi 5.96% dengan standar deviasi MAPE yang relatif rendah (0.0027). Meskipun demikian, tingkat kesalahan prediksi semakin rendah dengan peningkatan $Degree$. Dapat disimpulkan bahwa, Penyesuaian nilai $Degree$ pada kernel *Polynomial* memiliki dampak yang signifikan sekitar 1.1% terhadap performa dan variasi model. Peningkatan $Degree$ cenderung meningkatkan performa dengan mengurangi tingkat kesalahan prediksi

Sementara itu, hyperparameter *Gamma* juga memainkan peran penting dalam kernel RBF. Nilai *Gamma* mengontrol jangkauan pengaruh dari setiap titik data terhadap pembentukan hyperplane. Semakin tinggi nilai *Gamma*, semakin sempit radius dari fungsi RBF yang digunakan untuk menghitung kesamaan antara pasangan data. Hal ini membuat model lebih sensitif terhadap data pelatihan dan mungkin mengarah pada pembentukan model yang lebih kompleks. Pemilihan nilai *Gamma* yang tepat sangat bergantung pada karakteristik data; nilai *Gamma* yang terlalu tinggi dapat menyebabkan *overfitting*, sementara nilai yang terlalu rendah dapat menghasilkan model yang terlalu umum (*underfitting*). Berikut ini analisis hasil pengujian yang terdapat pada Lampiran 6 untuk berdasarkan pada nilai rata-rata dan standar deviasi MAPE untuk mengetahui kestabilan dan konsistensinya.

Tabel 4. 15 Rata-rata dan standar deviasi MAPE nilai Gamma pada Kernel RBF

<i>Gamma</i>	Kernel RBF	
	Rata-Rata	Standar Deviasi
0.1	2.82%	0.0006
1	2.78%	0.0006
10	3.67%	0.0080



Gambar 4. 23 Rata-rata MAPE berdasarkan perubahan nilai *Gamma* pada Kernel RBF

Dengan $\Gamma = 0.1$, rata-rata MAPE adalah 2.82% dengan standar deviasi MAPE 0.0006. Model RBF dengan Γ rendah menunjukkan tingkat kesalahan yang rendah dan variasi prediksi yang stabil. Sedangkan untuk $\Gamma = 1$, rata-rata MAPE turun menjadi 2.78% dengan standar deviasi MAPE yang tetap rendah (0.0006). Pemilihan Γ yang sedang memberikan hasil yang baik dengan tingkat kesalahan prediksi yang rendah. Dan terakhir pada $\Gamma = 10$, rata-rata MAPE meningkat menjadi 3.67% dengan standar deviasi MAPE yang tinggi (0.0080). Peningkatan Γ secara tidak terlalu signifikan sekitar 0.8% mempengaruhi performa dan variasi prediksi model RBF, menyebabkan peningkatan yang tidak diinginkan dalam tingkat kesalahan prediksi. Dapat disimpulkan bahwa, penyesuaian nilai Γ pada kernel RBF memiliki dampak yang tidak signifikan terhadap performa dan variasi model. Γ yang rendah cenderung memberikan tingkat kesalahan yang rendah dan variasi prediksi yang stabil. Pemilihan Γ yang tepat seperti $\Gamma = 1$ memberikan hasil

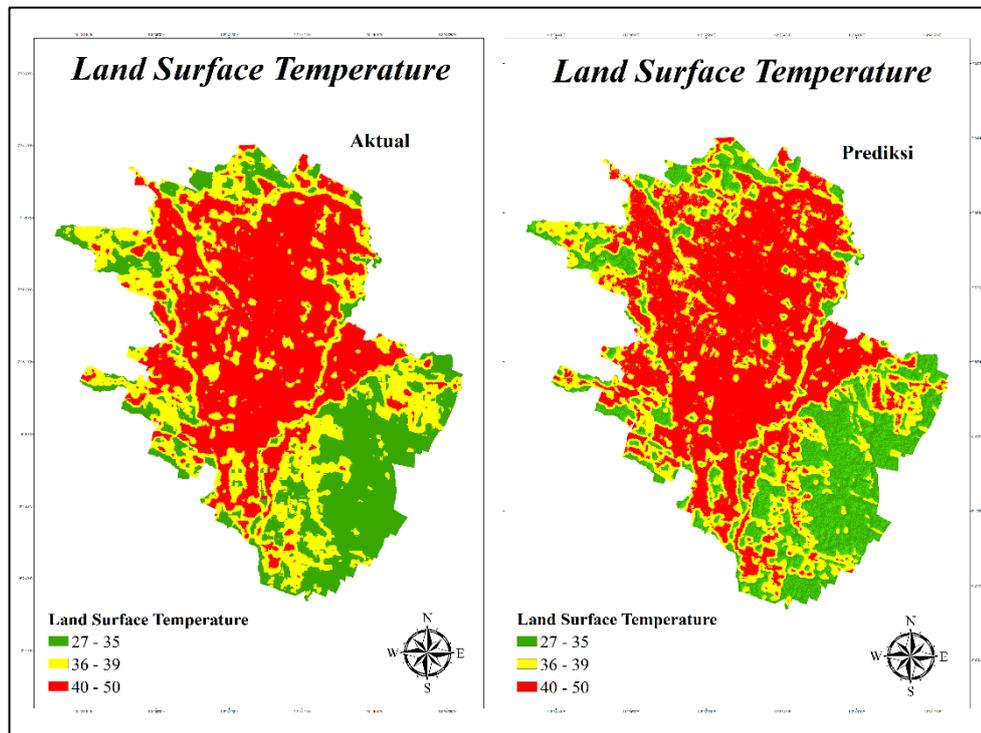
terbaik dengan tingkat kesalahan prediksi yang rendah dan standar deviasi yang rendah pula. Namun, *Gamma* yang terlalu tinggi seperti $\text{Gamma} = 10$ dapat menyebabkan peningkatan yang tidak diinginkan dalam tingkat kesalahan prediksi dan variasi.

4.6 Visualisasi Hasil Prediksi

Setelah mengetahui rasio, kernel dan hyperparameter yang terbaik serta bersifat konsisten yaitu menggunakan rasio 90:10 dengan menggunakan kernel linier dan nilai hyperparameter $C = 10$, $E = 0.1$. kemudian dilakukan denormalisasi untuk mengembalikan nilai hasil. Proses ini akan mengubah nilai hasil prediksi yang telah dinormalisasi menggunakan *Z-Score* ke dalam skala nilai yang sesungguhnya (suhu dalam °Celcius) sehingga dapat dibandingkan secara langsung dengan data aktual yang sudah ada sebelumnya. Berikut ini perbandingan data aktual dan hasil prediksi yang ditunjukkan pada tabel 4.19 beserta perbandingan visualisasi citranya yang ditunjukkan pada gambar 4.15.

Tabel 4. 16 Perbandingan Data Aktual dan Hasil Prediksi

No	LST (°C)	
	Data Aktual	Data Prediksi
1	35.4	38.2
2	41.6	37.9
3	33.1	36.1
...
1454	31.8	30.7
1455	34.1	38.0



Gambar 4. 24 Perbandingan citra LST aktual dan hasil prediksi

Perbedaan yang terlihat antara citra aktual Land Surface Temperature (LST) dan hasil prediksi dapat dijelaskan bahwa citra hasil prediksi menunjukkan luasnya daerah yang masuk dalam kategori suhu tinggi (ditunjukkan dengan warna merah) lebih banyak daripada yang sebenarnya diamati dalam citra aktual. Meskipun demikian, rentang suhu yang diprediksi tidak jauh berbeda, menunjukkan bahwa meskipun model cenderung memperkirakan suhu yang lebih tinggi secara relatif di berbagai daerah, dibuktikan adanya perbedaan antara suhu tertinggi dan terendah yang diprediksi tidak begitu besar. Perbedaan ini dikarenakan adanya karakteristik data yang digunakan dalam pelatihan model, berupa variabel-variabel yang digunakan menunjukkan keberagaman kondisi lingkungan, serta penerapan metode SVR dan penggunaan kernel dan parameter digunakan dalam proses prediksi.

4.7 Integrasi Islam

Dengan mendasarkan penelitian ini pada prinsip-prinsip agama melalui integrasi islam yaitu berdasarkan Al-Quran dan hadist, diharapkan mampu menekankan pentingnya perlindungan lingkungan dan kesadaran akan peran manusia dalam menjaga bumi sebagai amanah dari Allah.

4.7.1 Muamalah Mu'allah

Dalam mengamalkan wujud dari muamalah mu'allah yaitu dengan bertaqwa kepada Allah dan memperhatikan apa yang telah diperbuat serta memperhatikan hari esok merupakan wujud dari muamalah mu'allah seperti tertera pada surat Al-Hasyr : 18 yang berbunyi.

يَا أَيُّهَا الَّذِينَ آمَنُوا اتَّقُوا اللَّهَ وَلْتَنْظُرْ نَفْسٌ مَّا قَدَّمَتْ لِغَدٍ وَاتَّقُوا اللَّهَ إِنَّ اللَّهَ خَبِيرٌ بِمَا تَعْمَلُونَ ۝١

“Wahai orang-orang yang beriman! Bertakwalah kepada Allah dan hendaklah setiap orang memperhatikan apa yang telah diperbuatnya untuk hari esok (akhirat), dan bertakwalah kepada Allah. Sungguh, Allah Mahateliti terhadap apa yang kamu kerjakan.” (Q.S. Al-Hasyr : 18).

Menurut tafsir al madinah al-munawwarah, Allah memerintahkan hamba-hamba-Nya yang beriman untuk mentaati segala perintah-Nya dan menjaUHI segala larangan-Nya, dan hendaklah setiap mereka mencermati kebaikan apa yang telah dia siapkan untuk menghadapi hari kiamat. Kemudian Allah mengulangi perintah-Nya agar mereka bertakwa kepada Allah, untuk menegaskan betapa pentingnya ketakwaan. Allah Maha Mengetahui segala perbuatan kalian di dunia.

Dari tafsir diatas dapat dijelaskan pentingnya introspeksi diri dan muhasabah. Setiap manusia diharapkan untuk selalu mengkaji dirinya sendiri dengan selalu

mentaati perintahNya dan jika terdapat kesalahan sebelumnya, hendaknya segera berusaha untuk memperbaikinya dengan melepaskan diri dari dosa, bertaubat dengan sungguh-sungguh, dan menjauh dari segala hal yang dapat mengantarkan pada kesalahan sebelumnya. Dalam konteks prediksi fenomena UHI ini mengajarkan untuk selalu bertaqwa kepada Allah dengan memperhatikan segala dampak dari perbuatan manusia untuk kedepannya baik didunia dan di akhirat kelak. Dengan menjaga Amanah Allah yang sudah diberikan, berupa lingkungan yang indah serta terjaga. Ini merupakan bentuk ketaqwaan kepada Allah. Dengan mempertimbangkan dampak aktivitas dan perbuatan manusia untuk perlindungan lingkungan di masa depan, yang menjadi tanggung jawab manusia sebagai al aziz. Dengan adanya prediksi fenomena UHI diharapkan mampu menjadi jembatan untuk perencanaan tata Kelola kota yang baik, dengan mempertimbangkan aspek aspek yang berpengaruh terhadap lingkungan kota khususnya untuk mengatasi adanya fenomena UHI.

4.7.2 Muamalah Mu'annas

Diharapkan penelitian ini dapat membantu pemerintahan kota serta pihak lainnya untuk saling membantu mengatasi adanya fenomena UHI di kota malang. Dalam QS Al-Maidah pada ayat 2 dijelaskan bahwa: .

...وَتَعَاوَنُوا عَلَى الْبِرِّ وَالتَّقْوَىٰ وَلَا تَعَاوَنُوا عَلَى الْإِثْمِ وَالْعُدْوَانِ وَاتَّقُوا اللَّهَ إِنَّ اللَّهَ شَدِيدُ الْعِقَابِ ۚ

"..Dan tolong-menolonglah kamu dalam berbuat kebaikan dan perbuatan takwa, dan jangan tolong-menolong dalam berbuat dosa dan pelanggaran."(QS. Al-Maidah : 2).

Ibnu Katsir menjelaskan Allah memerintahkan seluruh hambaNya yang mengaku beriman untuk saling tolong-menolong dalam melakukan hal kebaikan dan menjauhi setiap larangannya yang berujung pada perbuatan dosa. Allah mengharamkan manusia untuk saling tolong-menolong dalam hal buruk yang dapat mengakibatkan kerusakan, keburukan, maksiat, dan perilaku haram lainnya.

Salah satu contoh contoh yang baik yang telah disabdakan oleh Rasulullah:

انصُرْ أَحَاكَ ظَالِمًا أَوْ مَظْلُومًا قَالُوا يَا رَسُولَ اللَّهِ هَذَا نَنْصُرُهُ مَظْلُومًا فَكَيْفَ نَنْصُرُهُ ظَالِمًا قَالَ تَأْخُذُ فَوْقَ يَدَيْهِ

“Bantulah saudaramu, baik dalam keadaan sedang berbuat zhalim atau sedang teraniaya. Ada yang bertanya: “Wahai Rasulullah, kami akan menolong orang yang teraniaya. Bagaimana menolong orang yang sedang berbuat zhalim?” Beliau menjawab: “Dengan menghalanginya melakukan kezhaliman. Itulah bentuk bantuanmu kepadanya.” [HR. al-Bukhâri]

Orang berilmu membantu orang lain dengan ilmunya. Orang kaya membantu dengan kekayaannya. Dan hendaknya kaum Muslimin menjadi satu tangan dalam membantu orang yang membutuhkan. Oleh karena itu, perbuatan tolong-menolong dalam kebaikan diharapkan mampu menjadikan manusia menjadi manusia yang bermanfaat bagi manusia lainnya, dan sebaik-baiknya manusia adalah manusia yang bermanfaat bagi sekitarnya seperti pada. Hadis yang telah diriwayatkan oleh Imam Ahmad:

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

Syeikh Ali bin Hasan Al-Halabi dalam kitab Ahkamusy Syita’ Fis Sunnatil Muthahharah menjelaskan bahwa Melakukan dan mempercayai prediksi suatu fenomena itu diperbolehkan, akan tetapi dengan syarat kepercayaan hanya untuk

melakukan evaluasi unrtuk mempersiapkan fenomena yang akan datang, akan tetapi tidak boleh percaya dengan utuh serta mengabarkan bahwa peristiwa yang telah diprediksikan sebelumnya pasti terjadi

Menurut tafsir tersebut, mempercayai prediksi fenomena seperti *Urban Heat Island* (UHI) diperbolehkan sebagai langkah untuk mempersiapkan diri dan melakukan evaluasi terhadap dampak lingkungan kedepannya. Namun, penting untuk tidak menganggap hasil prediksi tersebut sebagai sesuatu yang pasti akan terjadi di masa depan. Hal ini karena meyakini secara mutlak atas sesuatu yang belum terjadi merupakan tindakan yang mendahului kuasa Allah dan termasuk pada perbuatan syirik. Dalam Islam, keyakinan terhadap takdir Allah merupakan prinsip fundamental. Meskipun kita dapat merencanakan dan mengantisipasi berbagai fenomena berdasarkan ilmu pengetahuan dan penelitian, akhirnya keputusan mutlak tetaplah di tangan Allah. Oleh karena itu, penting untuk berusaha menjaga keseimbangan antara usaha manusia khususnya dalam mengatasi fenomena UHI serta kekuasaan dan takdir Allah.

4.7.3 Muamalah Mu'alam

Fenomena kerusakan yang terjadi di bumi ini tidak hanya disebabkan oleh faktor alam dan takdir Allah saja, namun juga faktor yang disebabkan oleh manusia itu sendiri sangat berpengaruh, seperti contohnya peristiwa banjir yang disebabkan oleh saluran air yang terhambat dikarenakan adanya sampah yang dibuang sembarangan dan dihasilkan oleh manusia itu sendiri serta akibat lainnya dari penebangan serta pembakaran hutan yang dapat mengurangi daerah resapan air oleh tanah. Kemudian peristiwa tanah longsor yang diakibatkan oleh faktor paling

dominan dari penambangan ataupun pengikisan batu bukit oleh manusia. contoh lainnya pada fenomena UHI yang diakibatkan oleh perubahan lahan alami menjadi lahan yang terbangun dan kedap air, sehingga mengakibatkan ketidaksimbangan alam yang ditunjukkan dengan kenaikan suhu di permukaan yang menjadi tanda bahwa adanya fenomena UHI. Berikut adalah salah satu ayat Qur'an yang berhubungan yaitu Q.S Ar-Rum:41-42 :

ظَهَرَ الْفَسَادُ فِي الْبَرِّ وَالْبَحْرِ بِمَا كَسَبَتْ أَيْدِي النَّاسِ لِيُذِيقَهُمْ بَعْضَ الَّذِي عَمِلُوا لَعَلَّهُمْ يَرْجِعُونَ ٤١
 قُلْ سِيرُوا فِي الْأَرْضِ فَانظُرُوا كَيْفَ كَانَ عَاقِبَةُ الَّذِينَ مِنْ قَبْلَ ۚ كَانُوا أَكْثَرُهُمْ مُشْرِكِينَ ٤٢

“Telah tampak 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). Katakanlah: “Adakanlah perjalanan di muka bumi dan perhatikanlah bagaimana kesudahan orang-orang yang terdahulu. kebanyakan dari mereka itu adalah orang-orang yang mempersekutukan (Allah).” (QS. Ar Rum : 41-42).

Dalam tafsir Ibnu Katsir dijelaskan bahwa ayat ini mengingatkan manusia agar tidak berbuat kerusakan di muka bumi setelah Allah memberikan nikmat dan rezeki kepada mereka. Allah memerintahkan agar manusia menggunakan nikmat tersebut dengan baik dan tidak menyalahgunakannya sehingga menimbulkan kerusakan dan kerusakan yang dilakukan serta diakibatkan dari manusia sendiri telah terjadi sejak dahulu, merupakan bagian dari peringatan dari Allah agar manusia selalu ingat akan akibat dari perbuatannya dan selalu berusaha untuk menjaga keseimbangan dan kelestarian lingkungan..

Dalam ayat lain, yaitu pada QS. Al-Baqarah : 60 :

﴿ وَإِذِ اسْتَسْقَىٰ مُوسَىٰ لِقَوْمِهِ ۖ فَقُلْنَا اضْرِبْ بِعَصَاكَ الْحَجَرَ ۖ فَانفَجَرَتْ مِنْهُ اثْنَتَا عَشْرَةَ عَيْنًا ۗ قَدْ عَلِمَ كُلُّ أُنَاسٍ مَشْرِبَهُمْ ۖ كُلُوا وَاشْرَبُوا مِنْ رِزْقِ اللَّهِ وَلَا تَعْتُوا فِي الْأَرْضِ مُفْسِدِينَ ۗ ٦٠ ﴾

“Dan (ingatlah) ketika Musa memohon air untuk kaumnya, lalu Kami berfirman, “Pukullah batu itu dengan tongkatmu!” Maka memancarlah daripadanya dua belas mata air. Setiap suku telah mengetahui tempat minumnya (masing-masing). Makan dan minumlah dari rezeki (yang diberikan) Allah, dan janganlah kamu melakukan kejahatan di bumi dengan berbuat kerusakan.”(QS. Al-Baqarah : 60).

Dalam tafsir yang diriwayatkan oleh Ibnu Katsir bahwa ayat ini menceritakan kisah Bani Israil yang tidak bersyukur atas nikmat yang Allah berikan kepada mereka. Mereka bahkan melakukan kerusakan dan memilih cara yang mereka anggap lebih baik daripada apa yang telah Allah tetapkan. Ini menunjukkan bahwa manusia sering tidak menghargai nikmat Allah dan malah menyebabkan kerusakan di bumi..

Berdasarkan tafsir diatas, yang dicontohkan melalui bani israil yang melakukan kerusakan. Jika dibandingkan pada zaman ini, manusia juga melakukan kerusakan alam. Banyak sekali contoh nyata yang sekarang mulai dirasakan oleh manusia sendiri. Diantaranya, Lahan vegetasi seringkali dikonversi menjadi lahan yang terbangun, ditandai dengan pembangunan bangunan tinggi di perkotaan dan penggunaan fasilitas yang berdampak negatif seperti penggunaan bahan kimia berbahaya dan polusi udara. Perubahan ini mengakibatkan hilangnya keseimbangan ekosistem serta meningkatkan suhu kota yang menjadi tanda terjadinya fenomena UHI. Manusia perlu mengambil pelajaran dari ayat tersebut untuk bertanggung jawab dalam memelihara bumi sesuai amanah Allah dan menghindari tindakan yang merusak lingkungan demi kepentingan sesaat.

BAB V

KESIMPULAN DAN SARAN

Bab ini akan menjelaskan mengenai kesimpulan dari hasil pengujian yang telah dilakukan pada penelitian prediksi urbanheat island berdasarkan data penginderaan jauh satelit menggunakan support vector regression di Kota Malang dengan mempertimbangkan faktor-faktor penentu fenomena UHI. Selain itu, peneliti juga akan menyampaikan saran-saran yang dapat menjadi referensi bagi penelitian-penelitian selanjutnya guna menghasilkan kajian yang lebih baru dan lebih baik di masa mendatang.

5.1 Kesimpulan

Penelitian ini dilakukan untuk mendapatkan hasil akhir yaitu performa terbaik untuk memprediksi UHI di Kota Malang dengan menggunakan SVR. Pengujian yang dilakukan ditujukan untuk mendapatkan hyperparameter dan kernel yang paling optimal untuk digunakan pada SVR berdasarkan persentase rata-rata dan standar deviasi MAPE pada setiap percobaan. Setelah dilakukan pengujian Model SVR terbaik pada penelitian ini adalah model pada skenario 3 dengan menggunakan kernel Linier dengan nilai hyperparameter *Cost* sebesar 10 dan *Epsilon* senilai 0.1. Berdasarkan perbandingan dari Rata-rata dan standar deviasi MAPE pada skenario 3 dengan Rata-rata dan standar deviasi sebesar 4.50% dan 1.76, kernel linier dengan Rata-rata dan standar deviasi sebesar 2.95% dan 0.000018, nilai *Cost* = 10 dengan Rata-rata dan standar deviasi sebesar 2.941% dan 0.000005, serta nilai *Epsilon* = 0.1 dengan Rata-rata dan standar deviasi sebesar 2.948% dan 0.000009. Hasil yang

telah dianalisis sebelumnya, menunjukkan bagaimana perbandingan hasil dari variasi hyperparameter yang digunakan. Kernel yang digunakan adalah kernel linier, polynomial dan RBF dengan menggunakan tuning parameter. Rata-rata MAPE pada kernel Linier lebih rendah dibandingkan dengan kernel RBF yang menunjukkan bahwa kernel linier penggunaannya lebih optimal, walaupun kernel RBF menghasilkan nilai error yang lebih baik dibandingkan dengan kernel linier dan polynomial.

5.2 Saran

Saran yang dapat penulis sampaikan untuk penelitian selanjutnya adalah sebagai berikut:

1. Pada penelitian ini dilakukan prediksi UHI berdasarkan 7 variabel penentu UHI, penelitian selanjutnya diharapkan menambahkan penerapan korelasi variabel untuk mengetahui faktor mana yang sangat berpengaruh terhadap fenomena UHI.
2. Penambahan variabel yang digunakan untuk memprediksi UHI pada penelitian selanjutnya.
3. Metode yang digunakan dalam penelitian ini adalah Support Vector Regression, penelitian selanjutnya dapat menggunakan metode lainnya yang diharapkan mampu memberikan hasil yang lebih baik.

DAFTAR PUSTAKA

- Addas, A. (2023). Machine Learning Techniques to Map the Impact of *Urban Heat Island*: Investigating the City of Jeddah. *Land*, 12(6). <https://doi.org/10.3390/land12061159>
- Al Kafy, A., Abdullah-Al-Faisal, Al Rakib, A., Akter, K. S., Rahaman, Z. A., Jahir, D. M. A., Subramanyam, G., Michel, O. O., & Bhatt, A. (2021). The operational role of remote sensing in assessing and predicting land use/land cover and seasonal land surface temperature using machine learning algorithms in Rajshahi, Bangladesh. *Applied Geomatics*, 13(4), 793–816. <https://doi.org/10.1007/s12518-021-00390-3>
- Bokaie, M., Zarkesh, M. K., Arasteh, P. D., & Hosseini, A. (2016). Assessment of *Urban Heat Island* based on the relationship between land surface temperature and Land Use/ Land Cover in Tehran. *Sustainable Cities and Society*, 23, 94–104. <https://doi.org/10.1016/j.scs.2016.03.009>
- Bozkir, A. S., Nefeslioglu, H. A., Kartal, O., Sezer, E. A., & Gokceoglu, C. (2019). Geological strength index (GSI) determination by local image descriptors and machine learning methods. *Human-Computer Interaction*, November 2019, 175–210.
- Evy Sulistianingsih, S. S. M. (2018). Prediksi Nilai Tukar Dolar Amerika Serikat Terhadap Rupiah Dengan Metode Support Vector Regression (Svr). *Bimaster : Buletin Ilmiah Matematika, Statistika Dan Terapannya*, 8(1), 1–10. <https://doi.org/10.26418/bbimst.v8i1.30503>
- Fitria, R., Kim, D., Baik, J., & Choi, M. (2019). Impact of Biophysical Mechanisms on *Urban Heat Island* Associated with Climate Variation and Urban Morphology. *Scientific Reports*, 9(1), 1–13. <https://doi.org/10.1038/s41598-019-55847-8>
- Fuladlu, K., Riza, M., & İlkan, M. (2018). *the Effect of Rapid Urbanization on the Physical Modification of Urban Area*. 5. http://coolparramatta.com.au/about_us
- Furuya, M. T. G., Furuya, D. E. G., de Oliveira, L. Y. D., da Silva, P. A., Cicerelli, R. E., Gonçalves, W. N., Junior, J. M., Osco, L. P., & Ramos, A. P. M. (2023). A machine learning approach for mapping surface *Urban Heat Island* using environmental and socioeconomic variables: a case study in a medium-sized Brazilian city. *Environmental Earth Sciences*, 82(13), 1–14. <https://doi.org/10.1007/s12665-023-11017-8>
- Heizer, J., & Render, B. (2020). Principles of Operations Management: Sustainability and Supply Chain Management, Enhanced EBook, Global Edition. *Pearson Education*, 1, 1–768.

https://cir.nii.ac.jp/crid/1130000797204243968%0Ahttps://www.google.co.id/books/edition/_/zKc5EAAAQBAJ?hl=en&kptab=overview

- Henrique, B. M., Sobreiro, V. A., & Kimura, H. (2018). Stock price prediction using support vector regression on daily and up to the minute prices. *Journal of Finance and Data Science*, 4(3), 183–201. <https://doi.org/10.1016/j.jfds.2018.04.003>
- Hosseinalizadeh, M., Kariminejad, N., Chen, W., Pourghasemi, H. R., Alinejad, M., Mohammadian Behbahani, A., & Tiefenbacher, J. P. (2019). Spatial modelling of gully headcuts using UAV data and four best-first decision classifier ensembles (BFTree, Bag-BFTree, RS-BFTree, and RF-BFTree). *Geomorphology*, 329(2018), 184–193. <https://doi.org/10.1016/j.geomorph.2019.01.006>
- Kavitha, S., Varuna, S., & Ramya, R. (2017). A comparative analysis on linear regression and support vector regression. *Proceedings of 2016 Online International Conference on Green Engineering and Technologies, IC-GET 2016*. <https://doi.org/10.1109/GET.2016.7916627>
- Kusumadewi, T., Maryunani, Surjono, Arif, Y. M., Samudro, H., Samudro, G., & Mangkoedihardjo, S. (2023). Urban Phytoarchitecture Design Options: Greenspace Orientation and Tree Species Intensification. *Journal of Advanced Research in Applied Sciences and Engineering Technology*, 31(1), 183–196. <https://doi.org/10.37934/araset.31.1.183196>
- Lestari, M. P., Witarasyah, D. J., Hamami, F., Telkom, U., Regression, S. V., Absolute, M., & Error, P. (2021). Peramalan Pertambahan Pasien Covid-19 Menggunakan Support Vector Regression Forecasting Growth of Covid-19 Patients Using Support. *E-Proceeding of Engineering*, 8(5), 9497–9507.
- Li, F., Yigitcanlar, T., Nepal, M., Nguyen, K., & Dur, F. (2023). Machine learning and remote sensing integration for leveraging urban sustainability: A review and framework. *Sustainable Cities and Society*, 96(March), 104653. <https://doi.org/10.1016/j.scs.2023.104653>
- Li, J., Sun, R., Liu, T., Xie, W., & Chen, L. (2021). Prediction models of *Urban Heat Island* based on landscape patterns and anthropogenic heat dynamics. *Landscape Ecology*, 36(6), 1801–1815. <https://doi.org/10.1007/s10980-021-01246-2>
- Liu, S., Zhang, J., Li, J., Li, Y., Zhang, J., & Wu, X. (2021). Simulating and mitigating extreme *Urban Heat Island* effects in a factory area based on machine learning. *Building and Environment*, 202(June), 108051. <https://doi.org/10.1016/j.buildenv.2021.108051>
- Mathew, A., Khandelwal, S., & Kaul, N. (2016). Spatial and temporal variations of *Urban Heat Island* effect and the effect of percentage impervious surface area and elevation on land surface temperature: Study of Chandigarh city, India. *Sustainable Cities and Society*, 26, 264–277.

<https://doi.org/10.1016/j.scs.2016.06.018>

- Mathew, A., Sreekumar, S., Khandelwal, S., & Kumar, R. (2019). Prediction of land surface temperatures for surface *Urban Heat Island* assessment over Chandigarh city using support vector regression model. *Solar Energy*, 186(June 2018), 404–415. <https://doi.org/10.1016/j.solener.2019.04.001>
- Maulana, N. D., Setiawan, B. D., & Dewi, C. (2019). Implementasi Metode Support Vector Regression (SVR) Dalam Peramalan Penjualan Roti (Studi Kasus : Harum Bakery). *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 3(3), 2986–2995.
- Nainggolan, Y. C., Sasmito, B., Sukmono, A., Amaliana, D. R. Y. P. A. S., Muzaky, H., Jaelani, L. M., Ardi, I. R., Lubis, M. S., Fitrianiingsih, Y., Setioningrum, D., Risdiyanto, I., Kasus, S., Semarang, K., García Reyes, L. E., Syamsudin, F., Lestari, S., Novianto, A., Syahtriawan, Q. Z., Kusumawardani, D., ... Liu, Q. (2020). Analisis Kontributor Dominan Terhadap Fenomena *Urban Heat Island* di Kota Medan. *Skripsi: Institut Pertanian Bogor. Bogor (ID)*, 3(1), 1689–1699.
<https://repository.ipb.ac.id/handle/123456789/40861>
<https://repository.ipb.ac.id/handle/123456789/48333>
[https://repository.ipb.ac.id/bitstream/123456789/11005/1/Nur Ikhwan Khusaini_E2008_abstract.pdf](https://repository.ipb.ac.id/bitstream/123456789/11005/1/Nur%20Ikhwan%20Khusaini_E2008_abstract.pdf)
<https://repository.ipb.ac.id/handle/123456789/62420>
- Nouval, M., Wahid, I., & Setyono, D. A. (2023). *Faktor Penyebab Terkuat Urban Heat Island Di Kawasan Sekitar Kampus Kota Malang*. 12(April), 157–166.
- Nurmahaludin. (2014). Perbandingan Algoritma Particle Swarm Optimization dan Regresi Pada Peramalan Waktu Beban Puncak. *Jurnal Poros Teknik*, 6(2).
- Odindi, J. O., Bangamwabo, V., & Mutanga, O. (2015). Assessing the value of urban green spaces in mitigating multi-seasonal urban heat using MODIS land surface temperature (LST) and landsat 8 data. *International Journal of Environmental Research*, 9(1), 9–18.
- Orrù, G., Pettersson-Yeo, W., Marquand, A. F., Sartori, G., & Mechelli, A. (2012). Using Support Vector Machine to identify imaging biomarkers of neurological and psychiatric disease: A critical review. *Neuroscience and Biobehavioral Reviews*, 36(4), 1140–1152. <https://doi.org/10.1016/j.neubiorev.2012.01.004>
- Purwanto, A. (2015). Pemanfaatan Citra Landsat 8 Untuk Identifikasi Normalized Difference Vegetation Index (Ndvi) Di Kecamatan Silat Hilir Kabupaten Kapuas Hulu. *Edukasi*, 13(1), 27–36.
- 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). <https://doi.org/10.12962/j23373520.v12i2.111596>

- Ren, T., Zhou, W., & Wang, J. (2021). Beyond intensity of *Urban Heat Island* effect: A continental scale analysis on land surface temperature in major Chinese cities. *Science of the Total Environment*, 791, 148334. <https://doi.org/10.1016/j.scitotenv.2021.148334>
- Sannigrahi, S., Bhatt, S., Rahmat, S., Uniyal, B., Banerjee, S., Chakraborti, S., Jha, S., Lahiri, S., Santra, K., & Bhatt, A. (2018). Analyzing the role of biophysical compositions in minimizing urban land surface temperature and urban heating. *Urban Climate*, 24(September), 803–819. <https://doi.org/10.1016/j.uclim.2017.10.002>
- Shi, H., Xian, G., Auch, R., Gallo, K., & Zhou, Q. (2021). *Urban Heat Island* and its regional impacts using remotely sensed thermal data—a review of recent developments and methodology. *Land*, 10(8). <https://doi.org/10.3390/land10080867>
- Smith, I. A., Winbourne, J. B., Tieskens, K. F., Jones, T. S., Bromley, F. L., Li, D., & Hutyra, L. R. (2021). A Satellite-Based Model for Estimating Latent Heat Flux From Urban Vegetation. *Frontiers in Ecology and Evolution*, 9(August). <https://doi.org/10.3389/fevo.2021.695995>
- Stewart, I. D., Krayenhoff, E. S., Voogt, J. A., Lachapelle, J. A., Allen, M. A., & Broadbent, A. M. (2021). Time Evolution of the Surface *Urban Heat Island*. *Earth's Future*, 9(10). <https://doi.org/10.1029/2021EF002178>
- Sun, Y., Gao, C., Li, J., Wang, R., & Liu, J. (2019). Quantifying the Effects of Urban Form on Land Surface Temperature in Subtropical High-Density Urban Areas Using Machine Learning. *Remote Sensing*, 11(8), 959. <https://doi.org/10.3390/rs11080959>
- Syamdermawan, W., & Kurniawan, S. E. B. (2012). Pengaruh Ruang Terbuka Hijau Terhadap Kualitas Lingkungan Pada Perumahan Menengah Atas. *Teknologi Dan Kejuruan*, 35(1), 81. www.halomalang.com
- Tian, L., Yang, J., & Jin, C. (2023). Dynamic changes in land cover and its effect on *Urban Heat Islands*. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17, 2386–2395. <https://doi.org/10.1109/JSTARS.2023.3342988>
- Unal Cilek, M., & Cilek, A. (2021). Analyses of land surface temperature (LST) variability among local climate zones (LCZs) comparing Landsat-8 and ENVI-met model data. *Sustainable Cities and Society*, 69(October 2020), 102877. <https://doi.org/10.1016/j.scs.2021.102877>
- Wang, R., Hou, H., Murayama, Y., & Morimoto, T. (2022). A Three-Dimensional Investigation of Spatial Relationship between Building Composition and Surface *Urban Heat Island*. *Buildings*, 12(8). <https://doi.org/10.3390/buildings12081240>
- Yumna, A., & Muhamad, L. (2020). Analisis Perubahan Distribusi *Urban Heat*

Island (UHI) di Kota Surabaya Menggunakan Citra Satelit Landsat Multitempora. *Jurnal Teknik ITS*, 9(2).

- Zhang, F., & O'Donnell, L. J. (2019). Support vector regression. In *Machine Learning: Methods and Applications to Brain Disorders*. Elsevier Inc. <https://doi.org/10.1016/B978-0-12-815739-8.00007-9>
- Zhang, X., Estoque, R. C., & Murayama, Y. (2017). An *Urban Heat Island* study in Nanchang City, China based on land surface temperature and social-ecological variables. *Sustainable Cities and Society*, 32, 557–568. <https://doi.org/10.1016/j.scs.2017.05.005>
- Zhang, Y., Zhang, J., Zhang, X., Zhou, D., & Gu, Z. (2021). Analyzing the characteristics of UHI (*Urban Heat Island*) in summer daytime based on observations on 50 sites in 11 LCZ (local climate zone) types in Xi'an, China. *Sustainability (Switzerland)*, 13(1), 1–14. <https://doi.org/10.3390/su13010083>
- Zhang, Z., Zhou, J., Tan, P., Pang, Y., Rivkin, A. C., Kirchgessner, M. A., Williams, E., Lee, C. T., Liu, H., Franklin, A. D., Miyazaki, P. A., Bartlett, A., Aldridge, A. I., Vu, M., Boggeman, L., Fitzpatrick, C., Nery, J. R., Castanon, R. G., Rashid, M., ... Callaway, E. M. (2021). Epigenomic diversity of cortical projection neurons in the mouse brain. *Nature*, 598(7879), 167–173. <https://doi.org/10.1038/s41586-021-03223-w>
- Zheng, Y., Li, W., Fang, C., Feng, B., Zhong, Q., & Zhang, D. (2023). Investigating the Impact of Weather Conditions on *Urban Heat Island* Development in the Subtropical City of Hong Kong. *Atmosphere*, 14(2). <https://doi.org/10.3390/atmos14020257>

LAMPIRAN

Lampiran I Pengujian Setiap Skenario

1. Skenario 1 (Rasio 70:30)

No	Kernel	C	Epsilon	Degree	Gamma	MAPE	
1.	Linier	0.1	0.001			3.02%	
2.			0.01			3.02%	
3.			0.1			3.02%	
4.		1	0.001			3.00%	
5.			0.01			3.00%	
6.			0.1			3.01%	
7.		10	0.001			3.01%	
8.			0.01			3.01%	
9.			0.1			3.01%	
10.	Polynomial	0.1	0.001	2		7.42%	
11.			0.01			7.42%	
12.			0.1			7.41%	
13.		1	0.001			7.11%	
14.			0.01			7.11%	
15.			0.1			7.11%	
16.		10	0.001	6.79%			
17.			0.01	6.79%			
18.			0.1	6.79%			
19.		0.1	0.001	4		6.70%	
20.						0.01	6.70%
21.						0.1	6.70%
22.			1			0.001	6.04%
23.						0.01	6.04%
24.						0.1	6.05%
25.		10	0.001	5.84%			
26.			0.01	5.84%			
27.			0.1	5.83%			
28.	0.1	0.001	8	6.40%			
29.				0.01	6.40%		
30.				0.1	6.40%		
31.	1	0.001		6.02%			
32.		0.01		6.02%			
33.		0.1		6.02%			
34.	10	0.001	5.82%				
35.		0.01	5.82%				
36.		0.1	5.83%				

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
37.	RBF	0.1	0.001		0.1	2.97%
38.			0.01			2.97%
39.			0.1			2.97%
40.		1	0.001			2.84%
41.			0.01			2.84%
42.			0.1			2.83%
43.		10	0.001			2.82%
44.			0.01			2.82%
45.			0.1			2.83%
46.		0.1	0.001		2.93%	
47.			0.01		2.93%	
48.			0.1		2.94%	
49.		1	0.001		2.80%	
50.			0.01		2.80%	
51.			0.1		2.80%	
52.		10	0.001		2.79%	
53.			0.01		2.79%	
54.			0.1		2.78%	
55.		0.1	0.001		5.38%	
56.			0.01		5.38%	
57.			0.1		5.38%	
58.		1	0.001		3.19%	
59.			0.01		3.19%	
60.			0.1		3.19%	
61.		10	0.001		3.32%	
62.			0.01		3.31%	
63.			0.1		3.29%	
Rata-Rata						4.58%
Standar Deviasi						0.01744541

2. Skenario 2 (Rasio 80:20)

No	Kernel	C	Epsilon	Degree	Gamma	MAPE	
1.	Linier	0.1	0.001			3.06%	
2.			0.01			3.06%	
3.			0.1			3.05%	
4.		1	0.001			3.04%	
5.			0.01			3.04%	
6.			0.1			3.04%	
7.		10	0.001			3.04%	
8.			0.01			3.04%	
9.			0.1			3.04%	
10.	Polynomial	0.1	0.001	2		7.38%	
11.			0.01			7.38%	
12.			0.1			7.38%	
13.		1	0.001			7.10%	
14.			0.01			7.10%	
15.			0.1			7.10%	
16.		10	0.001			6.80%	
17.			0.01			6.80%	
18.			0.1			6.80%	
19.		0.1	0.001			4	6.73%
20.			0.01				6.73%
21.			0.1				6.72%
22.			0.001	6.13%			
23.			0.01	6.13%			
24.			0.1	6.13%			
25.		10	0.001	8		5.94%	
26.			0.01			5.94%	
27.			0.1			5.93%	
28.		0.1	0.001			6.48%	
29.			0.01			6.48%	
30.			0.1			6.48%	
31.		1	0.001			6.10%	
32.			0.01			6.10%	
33.			0.1			6.08%	
34.		10	0.001			5.87%	
35.			0.01			5.87%	
36.			0.1			5.87%	

No	Kernel	C	Epsilon	Degree	Gamma	MAPE		
37.	RBF	0.1	0.001		0.1	3.00%		
38.			0.01			3.00%		
39.			0.1			3.01%		
40.		1	0.001			2.88%		
41.			0.01			2.88%		
42.			0.1			2.88%		
43.		10	0.001			2.87%		
44.			0.01			2.87%		
45.			0.1			2.88%		
46.		0.1	0.001		2.97%			
47.			0.01		2.97%			
48.			0.1		2.97%			
49.		1	0.001		2.87%			
50.			0.01		2.87%			
51.			0.1		2.86%			
52.		10	0.001		2.81%			
53.			0.01		2.81%			
54.			0.1		2.80%			
55.		0.1	0.001		5.04%			
56.			0.01		5.04%			
57.			0.1		5.04%			
58.		1	0.001		3.16%			
59.			0.01		3.16%			
60.			0.1		3.15%			
61.		10	0.001		3.30%			
62.			0.01		3.30%			
63.			0.1		3.28%			
Rata-Rata						4.60%		
Standar Deviasi						0.017387199		

3. Skenario 3 (Rasio 90:10)

No	Kernel	C	Epsilon	Degree	Gamma	MAPE	
1.	Linier	0.1	0.001			2.97%	
2.			0.01			2.96%	
3.			0.1			2.96%	
4.		1	0.001			2.94%	
5.			0.01			2.94%	
6.			0.1			2.94%	
7.		10	0.001			2.94%	
8.			0.01			2.94%	
9.			0.1			2.94%	
10.	Polynomial	0.1	0.001	2		7.37%	
11.			0.01			7.37%	
12.			0.1			7.37%	
13.		1	0.001			7.14%	
14.			0.01			7.14%	
15.			0.1			7.15%	
16.		10	0.001			6.91%	
17.			0.01			6.91%	
18.			0.1			6.91%	
19.		4	0.1	0.001			6.62%
20.				0.01			6.62%
21.				0.1			6.61%
22.			1	0.001			6.05%
23.				0.01			6.05%
24.				0.1			6.04%
25.			10	0.001			5.79%
26.				0.01			5.79%
27.				0.1			5.80%
28.		8	0.1	0.001			6.30%
29.				0.01			6.30%
30.				0.1			6.31%
31.			1	0.001			5.92%
32.				0.01			5.92%
33.				0.1			5.92%
34.			10	0.001			5.66%
35.				0.01			5.66%
36.				0.1			5.66%

No	Kernel	C	Epsilon	Degree	Gamma	MAPE		
37.	RBF	0.1	0.001		0.1	2.90%		
38.			0.01			2.90%		
39.			0.1			2.90%		
40.		1	0.001			2.79%		
41.			0.01			2.79%		
42.			0.1			2.79%		
43.		10	0.001			2.77%		
44.			0.01			2.77%		
45.			0.1			2.76%		
46.		0.1	0.001		2.87%			
47.			0.01		2.86%			
48.			0.1		2.86%			
49.		1	0.001		2.78%			
50.			0.01		2.78%			
51.			0.1		2.77%			
52.		10	0.001		2.72%			
53.			0.01		2.71%			
54.			0.1		2.71%			
55.		0.1	0.001		4.80%			
56.			0.01		4.80%			
57.			0.1		4.81%			
58.		1	0.001		3.03%			
59.			0.01		3.03%			
60.			0.1		3.02%			
61.		10	0.001		3.19%			
62.			0.01		3.19%			
63.			0.1		3.16%			
Rata-Rata						4.50%		
Standar Deviasi						0.017557364		

Lampiran II Pengujian Kernel Setiap Skenario

1. Skenario 1 (Rasio 70:30)

- **Kernel Linier**

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
1.	Linier	0.1	0.001			2.97%
2.			0.01			2.96%
3.			0.1			2.96%
4.		1	0.001			2.94%
5.			0.01			2.94%
6.			0.1			2.94%
7.		10	0.001			2.94%
8.			0.01			2.94%
9.			0.1			2.94%
Rata-Rata						3.01%
Standar Deviasi						0.000054

- **Kernel Polynomial**

No	Kernel	C	Epsilon	Degree	Gamma	MAPE	
10.	Polynomial	0.1	0.001	2		7.37%	
11.			0.01			7.37%	
12.			0.1			7.37%	
13.		1	0.001			7.14%	
14.			0.01			7.14%	
15.			0.1			7.15%	
16.		10	0.001	6.91%			
17.			0.01	6.91%			
18.			0.1	6.91%			
19.		Polynomial	0.1	0.001		4	6.62%
20.				0.01			6.62%
21.				0.1			6.61%
22.			1	0.001			6.05%
23.				0.01			6.05%
24.				0.1			6.04%
25.			10	0.001		5.79%	
26.				0.01		5.79%	
27.				0.1		5.80%	
28.	0.1	0.001	8	6.30%			

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
29.			0.01			6.30%
30.			0.1			6.31%
31.			1			0.001
32.		0.01				5.92%
33.		0.1				5.92%
34.		10	0.001			5.66%
35.			0.01			5.66%
36.			0.1			5.66%
Rata-Rata						6.46%
Standar Deviasi						0.005438

- **Kernel RBF**

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
37.	RBF	0.1	0.001		0.1	2.90%
38.			0.01			2.90%
39.			0.1			2.90%
40.		1	0.001			2.79%
41.			0.01			2.79%
42.			0.1			2.79%
43.		10	0.001			2.77%
44.			0.01			2.77%
45.			0.1			2.76%
46.		0.1	0.001		2.87%	
47.			0.01		2.86%	
48.			0.1		2.86%	
49.		1	0.001		2.78%	
50.			0.01		2.78%	
51.			0.1		2.77%	
52.		10	0.001		2.72%	
53.			0.01		2.71%	
54.			0.1		2.71%	
55.		0.1	0.001		4.80%	
56.			0.01		4.80%	
57.			0.1		4.81%	
58.		1	0.001		3.03%	
59.			0.01		3.03%	

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
60.		10	0.1			3.02%
61.			0.001			3.19%
62.			0.01			3.19%
63.			0.1			3.16%
Rata-Rata						3.22%
Standar Deviasi						0.007823

2. Skenario 2 (Rasio 80:20)

- **Kernel Linier**

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
1.	Linier	0.1	0.001			2.97%
2.			0.01			2.96%
3.			0.1			2.96%
4.		1	0.001			2.94%
5.			0.01			2.94%
6.			0.1			2.94%
7.		10	0.001			2.94%
8.			0.01			2.94%
9.			0.1			2.94%
Rata-Rata						3.05%
Standar Deviasi						0.000059

- **Kernel Polynomial**

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
10.	Polynomial	0.1	0.001	2		7.37%
11.			0.01			7.37%
12.			0.1			7.37%
13.		1	0.001			7.14%
14.			0.01			7.14%
15.			0.1			7.15%
16.		10	0.001	6.91%		
17.			0.01	6.91%		
18.			0.1	6.91%		
19.		0.1	0.001	4		6.62%
20.			0.01			6.62%

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
21.		1	0.1	8		6.61%
22.			0.001			6.05%
23.			0.01			6.05%
24.			0.1			6.04%
25.		10	0.001			5.79%
26.			0.01			5.79%
27.			0.1			5.80%
28.		0.1	0.001			6.30%
29.			0.01			6.30%
30.			0.1			6.31%
31.		1	0.001			5.92%
32.			0.01			5.92%
33.			0.1			5.92%
34.		10	0.001			5.66%
35.			0.01			5.66%
36.			0.1			5.66%
Rata-Rata						6.50%
Standar Deviasi						0.005048

- **Kernel RBF**

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
37.	RBF	0.1	0.001		0.1	2.90%
38.			0.01			2.90%
39.			0.1			2.90%
40.		1	0.001			2.79%
41.			0.01			2.79%
42.			0.1			2.79%
43.		10	0.001		2.77%	
44.			0.01		2.77%	
45.			0.1		2.76%	
46.		0.1	0.1		0.001	2.87%
47.					0.01	2.86%
48.					0.1	2.86%
49.			1		0.001	2.78%
50.					0.01	2.78%
51.					0.1	2.77%

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
52.		10	0.001		10	2.72%
53.			0.01			2.71%
54.			0.1			2.71%
55.		0.1	0.001			4.80%
56.			0.01			4.80%
57.			0.1			4.81%
58.		1	0.001			3.03%
59.			0.01			3.03%
60.			0.1			3.02%
61.		10	0.001			3.19%
62.			0.01			3.19%
63.			0.1			3.16%
Rata-Rata						3.21%
Standar Deviasi						0.006630

3. Skenario 3 (Rasio 90:10)

- **Kernel Linier**

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
1.	Linier	0.1	0.001			2.97%
2.			0.01			2.96%
3.			0.1			2.96%
4.		1	0.001			2.94%
5.			0.01			2.94%
6.			0.1			2.94%
7.		10	0.001			2.94%
8.			0.01			2.94%
9.			0.1			2.94%
Rata-Rata						2.95%
Standar Deviasi						0.000018

- **Kernel Polynomial**

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
10.	Polynomial	0.1	0.001	2		7.37%
11.			0.01			7.37%

- **Kernel RBF**

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
37.	RBF	0.1	0.001		0.1	2.90%
38.			0.01			2.90%
39.			0.1			2.90%
40.		1	0.001			2.79%
41.			0.01			2.79%
42.			0.1			2.79%
43.		10	0.001			2.77%
44.			0.01			2.77%
45.			0.1			2.76%
46.		0.1	0.001		2.87%	
47.			0.01		2.86%	
48.			0.1		2.86%	
49.		1	0.001		2.78%	
50.			0.01		2.78%	
51.			0.1		2.77%	
52.		10	0.001		2.72%	
53.			0.01		2.71%	
54.			0.1		2.71%	
55.		0.1	0.001		4.80%	
56.			0.01		4.80%	
57.			0.1		4.81%	
58.		1	0.001		3.03%	
59.			0.01		3.03%	
60.			0.1		3.02%	
61.		10	0.001		3.19%	
62.			0.01		3.19%	
63.			0.1		3.16%	
Rata-Rata						3.09%
Standar Deviasi						0.000005

Lampiran III Pengujian Hyperparameter *Cost* Pada Skenario 3

- **Kernel Linier dan $C = 0.1$**

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
1.	Linier	0.1	0.001			2.97%
2.			0.01			2.96%
3.			0.1			2.96%
Rata-Rata						2.9636%
Standar Deviasi						0.000018

- **Kernel Linier dan $C = 1$**

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
4.		1	0.001			2.94%
5.			0.01			2.94%
6.			0.1			2.94%
Rata-Rata						2.9421%
Standar Deviasi						0.000008

- **Kernel Linier dan $C = 10$**

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
7.		10	0.001			2.94%
8.			0.01			2.94%
9.			0.1			2.94%
Rata-Rata						2.9416%
Standar Deviasi						0.000005

- **Kernel *Polynomial* dan $C = 0.1$**

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
10.	<i>Polynomial</i>	0.1	0.001	2		7.374%
11.			0.01			7.373%
12.			0.1			7.375%
19.			0.001	4		6.616%
20.			0.01			6.615%
21.			0.1			6.608%

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
28.			0.001	8		6.303%
29.			0.01			6.304%
30.			0.1			6.308%
Rata-Rata						6.7639%
Standar Deviasi						0.004493

- **Kernel *Polynomial* dan C = 1**

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
10.	<i>Polynomial</i>	1	0.001	2		7.143%
11.			0.01			7.143%
12.			0.1			7.146%
19.			0.001	4		6.050%
20.			0.01			6.049%
21.			0.1			6.044%
28.			0.001	8		5.917%
29.			0.01			5.916%
30.			0.1			5.922%
Rata-Rata						6.3701%
Standar Deviasi						0.005499

- **Kernel *Polynomial* dan C = 10**

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
10.	<i>Polynomial</i>	10	0.001	2		6.907%
11.			0.01			6.907%
12.			0.1			6.907%
19.			0.001	4		5.793%
20.			0.01			5.794%
21.			0.1			5.798%
28.			0.001	8		5.659%
29.			0.01			5.659%
30.			0.1			5.656%
Rata-Rata						6.1199%
Standar Deviasi						0.005593

- **Kernel RBF dan C = 0.1**

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
37.	RBF	0.1	0.001		0.1	2.901%
38.			0.01			2.901%
39.			0.1			2.903%
46.			0.001		1	2.865%
47.			0.01			2.864%
48.			0.1			2.860%
55.			0.001		10	4.798%
56.			0.01			4.798%
57.			0.1			4.811%
Rata-Rata						3.5223%
Standar Deviasi						0.009053

- **Kernel RBF dan C = 1**

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
37.	RBF	1	0.001		0.1	2.788%
38.			0.01			2.788%
39.			0.1			2.791%
46.			0.001		1	2.776%
47.			0.01			2.777%
48.			0.1			2.773%
55.			0.001		10	3.029%
56.			0.01			3.029%
57.			0.1			3.023%
Rata-Rata						2.8637%
Standar Deviasi						0.001157

- **Kernel RBF dan C = 10**

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
37.	RBF	10	0.001		0.1	2.768%
38.			0.01			2.768%
39.			0.1			2.763%
46.			0.001		1	2.715%
47.			0.01			2.714%
48.			0.1			2.714%

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
55.			0.001		10	3.193%
56.			0.01			3.191%
57.			0.1			3.164%
Rata-Rata						2.8880%
Standar Deviasi						0.002098

Lampiran IV Pengujian Hyperparameter *Epsilon* Pada Skenario 3

- **Kernel Linier dan E = 0.001**

No	Kernel	Epsilon	Cost	Degree	Gamma	MAPE
1.	Linier	0.001	0.1			2.97%
2.			1			2.96%
3.			10			2.96%
Rata-Rata						2.950%
Standar Deviasi						0.00011

- **Kernel Linier dan E = 0.01**

No	Kernel	Epsilon	Cost	Degree	Gamma	MAPE
4.	Linier	0.001	0.1			2.94%
5.			1			2.94%
6.			10			2.94%
Rata-Rata						2.950%
Standar Deviasi						0.00010

- **Kernel Linier dan E = 0.1**

No	Kernel	Epsilon	Cost	Degree	Gamma	MAPE
7.	Linier	0.001	0.1			2.94%
8.			1			2.94%
9.			10			2.94%
Rata-Rata						2.948%
Standar Deviasi						0.00009

- **Kernel *Polynomial* dan E = 0.001**

No	Kernel	Epsilon	Cost	Degree	Gamma	MAPE			
10.	<i>Polynomial</i>	0.001	0.1	2		7.374%			
11.				4		6.616%			
12.				8		6.303%			
19.			1	2		7.143%			
20.				4		6.050%			
21.				8		5.917%			
28.			10	2		6.907%			
29.				4		5.793%			
30.				8		5.659%			
Rata-Rata						6.4180%			
Standar Deviasi						0.00585			

- **Kernel *Polynomial* dan E = 0.01**

No	Kernel	Epsilon	Cost	Degree	Gamma	MAPE			
10.	<i>Polynomial</i>	0.01	0.1	2		7.373%			
11.				4		6.615%			
12.				8		6.304%			
19.			1	2		7.143%			
20.				4		6.049%			
21.				8		5.916%			
28.			10	2		6.907%			
29.				4		5.794%			
30.				8		5.659%			
Rata-Rata						6.4178%			
Standar Deviasi						0.00585			

- **Kernel *Polynomial* dan E = 0.1**

No	Kernel	Epsilon	Cost	Degree	Gamma	MAPE
10.	<i>Polynomial</i>	0.1	0.1	2		7.375%
11.				4		6.608%
12.				8		6.308%
19.			1	2		7.146%
20.				4		6.044%

No	Kernel	Epsilon	Cost	Degree	Gamma	MAPE
21.			10	8		5.922%
28.				2		6.907%
29.				4		5.798%
30.				8		5.656%
Rata-Rata						6.4180%
Standar Deviasi						0.00585

- **Kernel RBF dan E = 0.001**

No	Kernel	Epsilon	Cost	Degree	Gamma	MAPE
10.	RBF	0.001	0.1		0.1	2.901%
11.					1	2.865%
12.					10	4.798%
19.			1		0.1	2.788%
20.					1	2.776%
21.					10	3.029%
28.			10		0.1	2.768%
29.					1	2.715%
30.					10	3.193%
Rata-Rata						3.093%
Standar Deviasi						0.00619

- **Kernel RBF dan E = 0.01**

No	Kernel	Epsilon	Cost	Degree	Gamma	MAPE
10.	RBF	0.001	0.1		0.1	2.901%
11.					1	2.864%
12.					10	4.798%
19.			1		0.1	2.788%
20.					1	2.777%
21.					10	3.029%
28.			10		0.1	2.768%
29.					1	2.714%
30.					10	3.191%
Rata-Rata						3.092%
Standar Deviasi						0.00619

- **Kernel *RBF* dan $E = 0.1$**

No	Kernel	<i>Epsilon</i>	<i>Cost</i>	<i>Degree</i>	<i>Gamma</i>	MAPE
10.	<i>RBF</i>	0.1	0.1		0.1	2.903%
11.					1	2.860%
12.					10	4.811%
19.			1		0.1	2.791%
20.					1	2.773%
21.					10	3.023%
28.			10		0.1	2.763%
29.					1	2.714%
30.					10	3.164%
Rata-Rata						3.089%
Standar Deviasi						0.00623

Lampiran V Pengujian Hyperparameter *Degree* Pada Skenario 3

- **Kernel *Polynomial* dan $D = 2$**

No	Kernel	<i>C</i>	<i>Epsilon</i>	<i>Degree</i>	<i>Gamma</i>	MAPE
10.	<i>Polynomial</i>	0.1	0.001	2		7.374%
11.			0.01			7.143%
12.			0.1			6.907%
13.		1	0.001			7.373%
14.			0.01			7.143%
15.			0.1			6.907%
16.		10	0.001			7.375%
17.			0.01			7.146%
18.			0.1			6.907%
Rata-Rata						7.14%
Standar Deviasi						0.0019

- **Kernel *Polynomial* dan $D = 4$**

No	Kernel	<i>C</i>	<i>Epsilon</i>	<i>Degree</i>	<i>Gamma</i>	MAPE
10.	<i>Polynomial</i>	0.1	0.001	4		6.616%
11.			0.01			6.050%
12.			0.1			5.793%
13.		1	0.001			6.615%

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
14.		10	0.01			6.049%
15.			0.1			5.794%
16.			0.001			6.608%
17.			0.01			6.044%
18.			0.1			5.798%
Rata-Rata						6.15%
Standar Deviasi						0.0034

- **Kernel *Polynomial* dan D = 8**

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
10.	<i>Polynomial</i>	0.1	0.001	8		6.303%
11.			0.01			5.917%
12.			0.1			5.659%
13.		1	0.001			6.304%
14.			0.01			5.916%
15.			0.1			5.659%
16.		10	0.001			6.308%
17.			0.01			5.922%
18.			0.1			5.656%
Rata-Rata						5.96%
Standar Deviasi						0.0027

Lampiran VI Pengujian Hyperparameter *Gamma* Pada Skenario 3

- **Kernel *RBF* dan *Gamma* = 0.1**

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
10.	<i>RBF</i>	0.1	0.001		0.1	2.901%
11.			0.01			2.788%
12.			0.1			2.768%
13.		1	0.001			2.901%
14.			0.01			2.788%
15.			0.1			2.768%
16.		10	0.001			2.903%
17.			0.01			2.791%
18.			0.1			2.763%

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
Rata-Rata						2.82%
Standar Deviasi						0.0006

- **Kernel RBF dan Gamma = 1**

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
10.	<i>RBF</i>	0.1	0.001		1	2.865%
11.			0.01			2.776%
12.			0.1			2.715%
13.		1	0.001			2.864%
14.			0.01			2.777%
15.			0.1			2.714%
16.		10	0.001			2.860%
17.			0.01			2.773%
18.			0.1			2.714%
Rata-Rata						2.78%
Standar Deviasi						0.0006

- **Kernel RBF dan Gamma = 10**

No	Kernel	C	Epsilon	Degree	Gamma	MAPE
10.	<i>RBF</i>	0.1	0.001		10	4.798%
11.			0.01			3.029%
12.			0.1			3.193%
13.		1	0.001			4.798%
14.			0.01			3.029%
15.			0.1			3.191%
16.		10	0.001			4.811%
17.			0.01			3.023%
18.			0.1			3.164%
Rata-Rata						3.67%
Standar Deviasi						0.0080