

**PEMODELAN KASUS DEFORESTASI DI INDONESIA MENGGUNAKAN
METODE *GEOGRAPHICALLY AND TEMPORALLY WEIGHTED
REGRESSION (GTWR)***

SKRIPSI



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

Disusun Oleh
**M. IMRON
H92219050**

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

2023

PERNYATAAN KEASLIAN

Saya yang bertanda tangan di bawah ini,

Nama : M. IMRON

NIM : H92219050

Program Studi : Matematika

Angkatan : 2019

Menyatakan bahwa saya tidak melakukan plagiat dalam penulisan skripsi saya yang berjudul "PEMODELAN KASUS DEFORESTASI DI INDONESIA MENGGUNAKAN METODE *GEOGRAPHICALLY AND TEMPORALLY WEIGHTED REGRESSION (GTWR)*". Apabila suatu saat nanti terbukti saya melakukan tindakan plagiat, maka saya bersedia menerima sanksi yang telah ditetapkan.

Demikian pernyataan keaslian ini saya buat dengan sebenar-benarnya.

Surabaya, 13 Juli 2023

Yang menyatakan,



M. IMRON
NIM. H92219050

LEMBAR PERSETUJUAN PEMBIMBING

Skripsi oleh

Nama : M. IMRON
NIM : H92219050
Judul Skripsi : PEMODELAN KASUS DEFORESTASI DI INDONESIA
MENGUNAKAN METODE *GEOGRAPHICALLY AND
TEMPORALLY WEIGHTED REGRESSION (GTWR)*

telah diperiksa dan disetujui untuk diujikan.

Pembimbing I



Ahmad Hanif Asyhar, M.Si
NIP. 198601232014031001

Pembimbing II



Wika Dianita Utami, M.Sc
NIP. 199206102018012003

Mengetahui,
Ketua Program Studi Matematika
UIN Sunan Ampel Surabaya



Yuniar Farida, M.T
NIP. 197905272014032002

PENGESAHAN TIM PENGUJI SKRIPSI

Skripsi oleh

Nama : M. IMRON
NIM : H92219050
Judul Skripsi : PEMODELAN KASUS DEFORESTASI DI
INDONESIA MENGGUNAKAN METODE
*GEOGRAPHICALLY AND TEMPORALLY WEIGHTED
REGRESSION (GTWR)*

Telah dipertahankan di depan Tim Penguji
pada tanggal 13 Juli 2023

Mengesahkan,
Tim Penguji

Penguji I


Putrouc Keumala Intan, M.Si
NIP. 198805282018012001

Penguji II


Dr. Abdulloh Hamid, M.Pd
NIP. 198508282014031003

Penguji III


Ahmad Hanif Asyhar, M.Si
NIP. 198601232014031001

Penguji IV


Wika Dianita Utami, M.Sc
NIP. 199206102018012003

Mengetahui,

Dekan Fakultas Sains dan Teknologi
UIN Sunan Ampel Surabaya



Saepul Hamdani, M.Pd
NIP. 196507312000031002



UIN SUNAN AMPEL
SURABAYA

KEMENTERIAN AGAMA
UNIVERSITAS ISLAM NEGERI SUNAN AMPEL SURABAYA
PERPUSTAKAAN

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

LEMBAR PERNYATAAN PERSETUJUAN PUBLIKASI
KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS

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

Nama : M. Imron
NIM : 1193219050
Fakultas/Jurusan : Sains dan Teknologi / Matematika
E-mail address : imron4838@gmail.com

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

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

yang berjudul :

Pemodelan kasus Deforestasi di Indonesia
Menggunakan Metode Geographically and
Temporally Weighted Regression (GTWR)

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

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

Demikian pernyataan ini yang saya buat dengan sebenarnya.

Surabaya, 13 Juli 2023

Penulis

(M. Imron)
nama terang dan tanda tangan

DAFTAR ISI

HALAMAN JUDUL	i
PENGESAHAN TIM PENGUJI SKRIPSI	ii
LEMBAR PERSETUJUAN PEMBIMBING	iii
PENGESAHAN TIM PENGUJI SKRIPSI	iv
izin skripsi	v
MOTTO	vi
HALAMAN PERSEMBAHAN	vii
KATA PENGANTAR	viii
DAFTAR ISI	x
DAFTAR TABEL	xiii
DAFTAR GAMBAR	xv
ABSTRAK	xvi
ABSTRACT	xvii
I PENDAHULUAN	1
1.1. Latar Belakang Masalah	1
1.2. Rumusan Masalah	11
1.3. Tujuan Penelitian	11
1.4. Manfaat Penelitian	12
1.5. Batasan Masalah	12
1.6. Sistematika Penulisan	13
II TINJAUAN PUSTAKA	15
2.1. Deforestasi	15
2.2. Data Spasial	16
2.3. Standarisasi Data (<i>Z-Score</i>)	16
2.4. Regresi Linear	17
2.4.1. Pendugaan Parameter Regresi Linear	19
2.4.2. Uji Simultan	20

2.4.3. Uji Parsial	22
2.5. Deteksi Multikolinearitas	23
2.6. Uji Asumsi Klasik	24
2.6.1. Uji Asumsi Identik (homoskedastisitas) Residual	24
2.6.2. Uji Asumsi Independen (Autokorelasi) Residual	25
2.6.3. Uji Asumsi Normalitas (Normal Distribution) Residual	26
2.7. Uji Heterogenitas Spasial dan Temporal	27
2.7.1. Uji Heterogenitas Spasial	27
2.7.2. Uji Heterogenitas Temporal	28
2.8. Model <i>Geographically Weighted Regression</i> (GWR)	28
2.8.1. <i>Bandwidth</i> dan Fungsi Pembobot Kernel Model (GWR)	30
2.9. Model <i>Geographically and Temporally Weighted Regression</i> (GTWR) 32	
2.9.1. Estimasi Model <i>Geographically and Temporally Weighted Regression</i> (GTWR)	33
2.10. Jarak Spasial-Temporal	37
2.11. Pengujian Dugaan Model <i>Geographically and Temporally Weighted Regression</i> (GTWR)	41
2.11.1. Uji Kesesuaian Model GTWR <i>Goodness of Fit</i>	41
2.11.2. Uji Parsial Model GTWR	43
2.12. Kriteria Pemilihan Model Terbaik	44
2.12.1. <i>Akaike Information Criterion</i> (AIC)	44
2.12.2. Koefisien Determinasi R^2	45
2.13. Menjaga Lingkungan dilihat dari sisi Keislaman	46
III METODE PENELITIAN	50
3.1. Jenis Penelitian	50
3.2. Sumber Data dan Variabel Penelitian	50
3.3. Tahapan Penelitian	51
IV HASIL DAN PEMBAHASAN	54
4.1. Analisis Deskriptif Variabel Penelitian	54
4.2. Standarisasi Data (Z-Score)	66
4.3. Deteksi Multikolinearitas	66

4.4. Pemodelan Menggunakan Regresi Linier Berganda	67
4.5. Uji Simultan Model Regresi Linear	70
4.6. Uji Parsial Model Regresi Linear	71
4.7. Uji Asumsi Klasik	72
4.7.1. Uji Homoskedestisitas Residual Regresi Linear	72
4.7.2. Uji Autokorelasi Residual Regresi Linear	72
4.7.3. Uji Normalitas Residual Regresi Linear	73
4.8. Uji Heterogenitas Spasial dan Temporal	74
4.9. Pemodelan Model <i>Geographically and Temporally Weighted Regression</i> (GTWR)	76
4.10. Estimasi Parameter Model <i>Geographically and Temporally Weighted Regression</i> (GTWR)	79
4.11. Uji Kesesuaian <i>Goodness Of Fit</i> Model GTWR (<i>Geographically and Temporally Weighted Regression</i>)	81
4.12. Uji Parsial Model GTWR (<i>Geographically and Temporally Weighted Regression</i>)	81
4.13. Perbandingan Kebaikan Model GTWR (<i>Geographically and Temporally Weighted Regression</i>)	89
4.14. Peta Variabel Signifikan Model GTWR	90
4.15. Relevansi Keislaman Terhadap Hasil Analisis GTWR (<i>Geographically and Temporally Weighted Regression</i>)	96
V PENUTUP	101
5.1. Kesimpulan	101
5.2. Saran	103
DAFTAR PUSTAKA	104
A LAMPIRAN	117

DAFTAR TABEL

2.1	Tabel analisis varians	22
2.2	Tabel keputusan Durbin-Watson	26
3.1	Variabel-variabel penelitian	51
4.1	Nilai Rataan, Standar Deviasi, Min dan Max Data Deforestasi Indonesia tahun 2017-2020	55
4.2	Analisis Deskriptif Variabel Bebas Penelitian tahun 2017-2020 . . .	58
4.3	Data Standarisasi Z-Score	66
4.4	Variabel VIF	67
4.5	Uji Simultan	70
4.6	Uji Parsial	71
4.7	Uji Homoskedastisitas	72
4.8	Uji Normalitas	74
4.9	Uji Heterogenitas spasial	75
4.10	Nilai parameter pada masing-masing model	76
4.11	Matriks Pembobot W_{ij} Kernel <i>Fixed Gaussian</i> Provinsi Aceh	77
4.12	Matriks Pembobot W_{ij} Kernel <i>Fixed Bisquare</i> Provinsi Aceh	78
4.13	Estimasi Parameter Model GTWR dengan Kernel <i>Fixed Gaussian</i> .	79
4.14	Estimasi Parameter Model GTWR dengan Kernel <i>Fixed Bisquare</i> . .	80
4.15	Hasil Uji Kecocokan Model GTWR dengan OLS	81
4.16	Variabel Signifikan dalam Model GTWR Tahun 2017	82
4.17	Variabel Signifikan dalam Model GTWR Tahun 2018	83
4.18	Variabel Signifikan dalam Model GTWR Tahun 2019	84
4.19	Variabel Signifikan dalam Model GTWR Tahun 2020	85
4.20	Pengelompokkan Provinsi Model GTWR <i>Fixed Gaussian</i> Berdasarkan Signifikansi Variabel	86

4.21 Pengelompokan Provinsi Model GTWR <i>Fixed Bisquare</i> Berdasarkan Signifikansi Variabel	88
4.22 Perbandingan Kebaikan Model	89



UIN SUNAN AMPEL
S U R A B A Y A

DAFTAR GAMBAR

1.1	Peta Sebaran Deforestasi Indonesia tahun 2020	3
2.1	<i>Ilustrasi Jarak Spatiotemporal</i>	37
3.1	Alur Penelitian GTWR	51
4.1	<i>Deforestasi Indonesia 2017</i>	55
4.2	<i>Deforestasi Indonesia 2018</i>	56
4.3	<i>Deforestasi Indonesia 2019</i>	57
4.4	<i>Deforestasi Indonesia 2020</i>	58
4.5	<i>Sebaran Luas Perkebunan Kelapa Sawit 2017-2020</i>	59
4.6	<i>Sebaran PDRB Pertambangan 2017-2020</i>	60
4.7	<i>Sebaran Luas Hutan 2017-2020</i>	61
4.8	<i>Sebaran Produksi Kayu Bulat 2017-2020</i>	62
4.9	<i>Sebaran Jumlah Penduduk 2017-2020</i>	63
4.10	<i>Sebaran Luas Perkebunan Kopi 2017-2020</i>	64
4.11	<i>Sebaran Presentase Penduduk Miskin 2017-2020</i>	65
4.12	<i>QQ-Plot Residual</i>	74
4.13	<i>Box-Plot Deforestasi</i>	75
4.14	<i>Peta Variabel Signifikan model GTWR Fixed Bisquare tahun 2017-2020</i>	91
4.15	<i>Peta Variabel Signifikan model GTWR Fixed Gaussian tahun 2017-2020</i>	94

ABSTRAK

PEMODELAN KASUS DEFORESTASI DI INDONESIA MENGGUNAKAN METODE *GEOGRAPHICALLY AND TEMPORALLY WEIGHTED REGRESSION (GTWR)*

Hutan Indonesia merupakan salah satu yang terluas di dunia. Kasus eksploitasi terhadap hutan di Indonesia yang menyebabkan kasus deforestasi meningkat dengan tinggi. Kasus deforestasi merupakan peralihan dengan permanen fungsi asli dari hutan yang berdampak meningkatnya suhu permukaan bumi dan atmosfer sehingga dapat mengganggu siklus hidrologi, misalnya deforestasi di Kalimantan yang tiap tahunnya mengalami kasus deforestasi. Deforestasi tiap daerah disebabkan oleh faktor yang berbeda tergantung kondisi geografis. Penelitian ini dilakukan bertujuan memodelan dan menganalisis terhadap faktor-faktor yang diasumsikan menjadi penyebab kasus deforestasi di Indonesia menggunakan metode *Geographically And Temporally Weighted Regression (GTWR)* dengan fungsi pembobot yaitu *fixed Gaussian* dan *fixed Bisquare*. Penelitian menggunakan data deforestasi Indonesia dari tahun 2017 hingga tahun 2020 yang diperoleh dari Badan Pusat Statistik (BPS). Pembentukan model memerlukan parameter awal yaitu $\tau, \lambda, \mu, d_{ij}^{ST}$ dan W_{ij} yang didapat melalui *Cross Validasi* minimum. Hasil analisis menunjukkan bahwa model GTWR dengan fungsi pembobot kernel *fixed Gaussian* didominasi oleh variabel signifikan yaitu luas perkebunan kelapa sawit (X_1), PDRB pertambangan (X_2), luas hutan (X_3), jumlah populasi/penduduk (X_5), luas perkebunan kopi (X_6), dan persentase penduduk miskin (X_7) dan kernel *fixed Bisquare* didominasi oleh luas perkebunan kelapa sawit (X_1), PDRB pertambangan (X_2), luas hutan (X_3) luas perkebunan kopi (X_6). Kebaikan model GTWR dinilai lebih baik dari model Regresi Linear dengan nilai koefisien determinasi (R^2) berturut-turut sebesar 79.74% dan 87.85% dan AIC berturut-turut sebesar 573.192 dan 606.8902 sehingga disimpulkan metode GTWR dapat memberikan pemahaman yang lebih baik tentang faktor-faktor yang mempengaruhi kasus deforestasi di Indonesia tahun 2017-2020.

Kata kunci: Deforestasi, *Geographically and Temporally Weighted Regression (GTWR)*, kernel *Gaussian*, kernel *Bisquare*.

ABSTRACT

MODELING DEFORESTATION CASES IN INDONESIA USING GEOGRAPHICALLY AND TEMPORALLY WEIGHTED REGRESSION (GTWR) METHOD

Indonesia's forests are among the largest in the world. The exploitation of forests in Indonesia has caused deforestation cases to increase at a high rate. Deforestation is a permanent change in the original function of the forest that has an impact on increasing the earth's surface temperature and atmosphere so that it can disrupt the hydrological cycle, for example deforestation in Kalimantan which experiences deforestation cases every year. Deforestation in each region is caused by different factors depending on geographical conditions. This study was conducted to model and analyze the factors that are assumed to be the cause of deforestation cases in Indonesia using the GTWR method with weighting functions namely fixed Gaussian and fixed Bisquare. The study used Indonesian deforestation data from 2017 to 2020 obtained from the Badan Pusat Statistik (BPS). Model building requires initial parameters namely τ , λ , μ , d_{ij}^{ST} and W_{ij} obtained through minimum cross validation. The results of the analysis show that the GTWR model with the kernel weighting function *fixed Gaussian* is dominated by significant variables, namely oil palm plantation area (X_1), mining PDRB (X_2), forest area (X_3), population (X_5), coffee plantation area (X_6), and percentage of poor population (X_7) and the *fixed Bisquare* kernel is dominated by oil palm plantation area (X_1), mining GRDP (X_2), forest area (X_3) coffee plantation area (X_6). The goodness of the GTWR model is considered better than the Linear Regression model with a coefficient of determination (R^2) value of 79.74% and 87.85% respectively and AIC of 573.192 and 606.8902 so it is concluded that the GTWR method can provide a better understanding of the factors that affect deforestation cases in Indonesia in 2017-2020.

Keywords: Deforestasi, *Geographically-Temporally Weighted Regression* (GTWR), *gaussian* kernel, *bisquare* kernel.

BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Deforestasi telah menjadi isu global yang menarik perhatian banyak negara di seluruh dunia, termasuk Indonesia. Deforestasi mengacu pada proses pengurangan luas tutupan hutan di suatu wilayah. Hutan memiliki peran yang krusial dalam mempertahankan keseimbangan lingkungan hidup dan kehidupan manusia di bumi. Secara umum, hutan dapat dibagi menjadi dua kategori, yakni hutan alami dan hutan buatan. Hutan alami terbentuk secara spontan tanpa intervensi manusia, sedangkan hutan buatan dibuat oleh manusia dengan tujuan tertentu seperti penghijauan, konservasi, dan produksi. Hutan memainkan peran penting dalam menjaga keseimbangan alam dengan berbagai fungsi di antaranya sebagai penyangga kehidupan, pengatur iklim, penghasil oksigen, sumber pangan dan bahan obat-obatan, serta sebagai habitat bagi flora dan fauna yang beraneka ragam. Hutan juga memiliki peran sosial yang penting sebagai sumber bahan bakar, air, dan makanan bagi masyarakat yang tinggal di sekitarnya. Di sisi ekonomi, hutan berperan sebagai sumber pendapatan melalui produk hasil hutan. (Pradana et al., 2022; Jamaludin et al., 2022).

Di Indonesia, hutan terdiri dari beberapa jenis seperti hutan konservasi, hutan produksi, dan hutan lindung. Sayangnya, kondisi hutan di Indonesia saat ini menunjukkan penurunan yang signifikan. Berdasarkan data yang dirilis oleh Kementerian Lingkungan Hidup dan Kehutanan, luas hutan Indonesia pada tahun

2020 hanya mencapai 88,2 juta hektar atau sekitar 53% dari luas total wilayah Indonesia, yang menurun drastis dari 120 juta hektar pada tahun 1990. Fenomena ini disebabkan oleh berbagai faktor seperti pengambilan kayu secara massal, perubahan penggunaan lahan, dan bencana alam (KLHK, 2020).

Hutan Indonesia yang kehilangan fungsi utamanya memiliki dampak besar pada deforestasi di Indonesia. Tingginya tingkat deforestasi di Indonesia dapat memperburuk keadaan lingkungan dan berdampak negatif pada masyarakat, terutama masyarakat yang menggantungkan hidup dari hutan. Ketika hutan ditebang atau terbakar, tidak hanya terjadi kerusakan ekosistem dan hilangnya habitat satwa liar, tetapi juga dapat menyebabkan terjadinya banjir dan longsor di daerah sekitarnya, juga berdampak pada perubahan iklim global karena karbon yang tersimpan dalam hutan akan dilepaskan ke atmosfer dan menyebabkan peningkatan emisi gas rumah kaca. Menurut studi yang dilakukan oleh Greenpeace Indonesia pada tahun 2019, Indonesia merupakan penyumbang emisi karbon terbesar kelima di dunia, dan deforestasi menjadi salah satu penyebab utama peningkatan emisi tersebut (Adrianto et al., 2020; Greenpeace, 2019).

Fenomena ini tercermin dalam ayat ke-41 dari surat Ar-Rum dalam Al-Qur'an :

ظَهَرَ الْفَسَادُ فِي الْبَرِّ وَالْبَحْرِ بِمَا كَسَبَتْ أَيْدِي النَّاسِ لِيُذِيقَهُمْ بَعْضَ الَّذِي
عَمِلُوا لَعَلَّهُمْ يَرْجِعُونَ ﴿٤١﴾

Artinya : *Telah tampak kerusakan di darat dan di laut disebabkan perbuatan tangan manusia. (Melalui hal itu) Allah membuat mereka merasakan sebagian dari (akibat) perbuatan mereka agar mereka kembali (ke jalan yang benar) (Q.S A-Rum (30) : 41)*

Ayat di atas menjadi bukti bahwa Allah telah mengatur semua hal di bumi ini, salah satunya hukum sebab akibat. Kerusakan lingkungan yang terjadi di bumi seperti deforestasi tidak lain adalah hal yang disebabkan oleh penghuni bumi sendiri, dilakukan oleh tangan manusia dan dampaknya akan menghampiri manusia juga sebagai teguran bagi manusia yang berpikir sehingga dapat kembali menjalankan tugasnya sebagai khalifah di muka bumi.

Banyak faktor yang menyebabkan terjadinya deforestasi hutan di Indonesia antara lain banyaknya wilayah hutan yang hilang akibat pertambangan, penebangan wilayah hutan yang kemudian dijadikan lahan perkebunan misalnya perkebunan sawit dan kopi, peningkatan produksi kayu bulat, kemudian kemiskinan dimana hasil hutan menjadi sumber pendapatan alternatif, terutama ketika opsi pekerjaan yang layak tidak tersedia.

Berikut peta sebaran kasus deforestasi tahun 2020 dengan data acuan dari Badan Pusat Statistik (BPS) Indonesia.



Gambar 1.1 Peta Sebaran Deforestasi Indonesia tahun 2020

Pada **Gambar (1.1)** semakin muda warna yang dihasilkan maka merepresentasikan angka reforestasi yang lebih besar daripada angka deforestasi, begitupun sebaliknya untuk warna yang semakin gelap menandakan daerah tersebut mengalami deforestasi yang tinggi. Salah satu provinsi dengan angka deforestasi yang tinggi adalah Provinsi Kalimantan. Dari tahun 2000 hingga 2020

Kalimantan terus mengalami deforestasi. Data dari Kementerian Lingkungan Hidup dan Kehutanan menunjukkan bahwa pada tahun 2020, luas hutan di Provinsi Kalimantan hanya mencapai 21,7 juta hektar, mengalami penurunan dari 30,2 juta hektar pada tahun 1990. Deforestasi pada daerah ini terjadi akibat eksploitasi yang tinggi terhadap hutan dengan merubah fungsi permanen hutan menjadi perkebunan sawit, dan perluasan lahan tambang yang mana terlihat dari tingginya PDRB hasil pertambangan daerah kalimantan, notabennya dua hal ini akan terus dilakukan karena masih menjadi pilar atau tonggak perekonomian Indonesia saat ini, juga meningkat sejalan dengan tingginya pembukaan lahan baik itu *project* pembangunan Ibu Kota Negara (IKN) ataupun pembukaan lahan pemukiman penduduk (Salsabila and Nurwati, 2020; Ayuningtyas, 2022; Gunarso et al., 2013).

Selanjutnya, hutan Riau merupakan hutan terluas ketiga di Indonesia akan tetapi dari tahun 2013 hingga 2019 terus menyumbang angka deforestasi yang tinggi. Provinsi Riau tahun 2020 juga penyumbang deforestasi, dengan adanya pengalihan lahan hutan menjadi perkebunan sawit dan kebakaran hutan, untuk kebakaran hutan mencapai 81.126 hektar dimana umumnya disebabkan oleh aktivitas manusia seperti pembukaan lahan untuk perkebunan atau kegiatan pertanian. (Setiawan et al., 2021).

Di daerah lain misalnya di daerah Papua, deforestasi disebabkan oleh faktor kemiskinan masyarakat lokal yang memanfaatkan hutan sebagai sumber penghasilan. Terlihat adanya peningkatan angka deforestasi yang cukup signifikan di wilayah-wilayah yang ditinggali oleh masyarakat adat yang masih hidup dalam keadaan kurang sejahtera secara ekonomi. Dampak dari deforestasi tersebut tentu sangat merugikan bagi lingkungan sekitar dan juga memperparah kondisi hidup masyarakat adat yang sebagian besar bergantung pada hasil alam yang tersedia di

hutan (Miettinen et al., 2019). Selain itu, faktor kemiskinan juga menjadi penyebab terjadinya *illegal logging* dan *illegal mining* di daerah-daerah terpencil yang rawan kemiskinan, seperti di wilayah Sulawesi Tengah. Perlu diingat bahwa kemiskinan merupakan faktor yang kompleks dan berdampak besar pada keberlanjutan hutan. Oleh karena itu, penanganan kemiskinan perlu dilakukan secara komprehensif dan berkelanjutan agar dapat mengurangi tekanan terhadap hutan dan memastikan keberlangsungan sumber daya alam bagi generasi mendatang (Rhamdhani et al., 2020).

Tindakan mencari jalan keluar atas suatu masalah merupakan suatu tugas yang Allah berikan kepada kita, sesuai dengan kalamullah yang termuat pada surah kedua dalam Al-Qur'an ayat ke 30 :

وَإِذْ قَالَ رَبُّكَ لِلْمَلَائِكَةِ إِنِّي جَاعِلٌ فِي الْأَرْضِ خَلِيفَةً قَالُوا أَتَجْعَلُ فِيهَا مَنْ
يُفْسِدُ فِيهَا وَيَسْفِكُ الدِّمَاءَ وَنَحْنُ نُسَبِّحُ بِحَمْدِكَ وَنُقَدِّسُ لَكَ قَالَ إِنِّي أَعْلَمُ
مَا لَا تَعْلَمُونَ ﴿٣٠﴾

Artinya : *(Ingatlah) ketika Tuhanmu berfirman kepada para malaikat, “Aku hendak menjadikan khalifah¹³ di bumi.” Mereka berkata, “Apakah Engkau hendak menjadikan orang yang merusak dan menumpahkan darah di sana, sedangkan kami bertasbih memuji-Mu dan menyucikan nama-Mu?” Dia berfirman, “Sesungguhnya Aku mengetahui apa yang tidak kamu ketahui.” (Q.S Al-Baqarah (2) : 30)*

Berdasarkan ayat tersebut, dapat ditarik kesimpulan bahwa manusia memiliki tugas dan tanggung jawab dalam menyelesaikan masalah. Pandangan malaikat terhadap manusia sebagai perusak tidaklah sepenuhnya benar, karena Allah Swt mengetahui potensi manusia sebagai *problem solver* bahkan dalam

hal-hal yang belum diketahui oleh malaikat. Hal ini sejalan dengan hadis Nabi Saw.

عَنْ أَنَسٍ أَنَّ رَسُولَ اللَّهِ -صَلَّى اللَّهُ عَلَيْهِ وَسَلَّمَ يَقُولُ مَا مِنْ مُسْلِمٍ يَغْرِسُ غَرْسًا أَوْ يَزْرَعُ زَرْعًا فَيَأْكُلُ مِنْهُ طَيْرٌ أَوْ إِنْسَانٌ إِلَّا كَانَ لَهُ صَدَقَةٌ

(رواه البخاري رقم 2320, ومسلم رقم 1553)

Artinya : “*Dari sahabat Anas ra, Rasulullah Saw bersabda, ‘Tiada seorang muslim yang menanam pohon atau menebar bibit tanaman, lalu (hasilnya) dimakan oleh burung atau manusia, melainkan ia akan bernilai sedekah bagi penanamnya.’*”

(HR Bukhari No. 2320, Muslim No. 1553)

Hadis yang disampaikan oleh Bukhari dan Muslim mengingatkan tentang pentingnya menanam pohon dan berkontribusi dalam menjaga keberlangsungan sumber daya alam. Dalam konteks penanganan deforestasi, tindakan menanam pohon adalah salah satu jalan keluar yang dapat membantu memulihkan hutan yang rusak dan memastikan keberlangsungan lingkungan hidup. Dengan menanam pohon, kita dapat membantu mengurangi tekanan terhadap hutan dan menjaga keanekaragaman hayati serta mengurangi dampak perubahan iklim. Selanjutnya dapat dilihat pula kaidah fikih yang berkaitan dengan ini.

الضَّرَرُ يُزَالُ

Artinya : “*Kemudharatan harus dihilangkan*”

Dalam konteks lingkungan, kaidah *kemudharatan* mengimplikasikan bahwa manusia harus mempertimbangkan dampak dari tindakan yang menyebabkan kemudharatan seperti kegiatan illegal logging dan illegal mining

terhadap lingkungan dan keberlangsungan sumber daya alam. Dengan meminimalkan dampak negatif dari tindakan manusia terhadap lingkungan, dapat mencegah terjadinya kerusakan pada ekosistem dan memastikan keberlangsungan sumber daya alam bagi generasi mendatang. Oleh karena itu, kaidah *kemudharatan* sangat penting dalam mengatur hubungan manusia dengan lingkungan dan sumber daya alam. Salah satu teknik yang dapat digunakan untuk mengalisis masalah ini yaitu teknik statistik.

Ilmu statistik menawarkan penyelesaian dalam bentuk regresi linier untuk menganalisis pengaruh atau konektivitas variabel bebas terhadap variabel terikat (Debataraja et al., 2021). Umumnya, variabel yang tergantung pada variabel bebas dilambangkan dengan Y, sementara variabel bebas dilambangkan dengan X. Apabila regresi linier hanya melibatkan satu variabel bebas, maka disebut sebagai regresi linier sederhana. Namun, jika terdapat lebih dari satu variabel bebas dalam regresi, maka disebut sebagai regresi linier berganda. Hal ini merupakan konvensi umum dalam analisis regresi (Rath et al., 2020). Regresi linier memberikan informasi lokal yang cukup baik ketika data tidak memuat efek lokasi (*spasial*). Namun, model regresi linier bersifat global dan tidak dapat menangkap perbedaan heterogenitas dari setiap lokasi (Khoeriyah and Hajarisman, 2021). Oleh karena itu, diperlukan teknik analisis yang lebih canggih untuk menangani data dengan efek spasial.

Data spasial merujuk pada data yang dipengaruhi oleh lokasi atau koordinat geografis tertentu, sehingga dapat direpresentasikan dalam bentuk peta (Pan et al., 2020). Dalam kasus deforestasi di Indonesia, di mana faktor spasial menjadi pengaruh yang signifikan pada setiap provinsi, maka diperlukan metode analisis yang dapat menangani heterogenitas pada tiap wilayah, yaitu regresi

spasial. Salah satu pengembangan dari regresi spasial adalah *Geographically Weighted Regression* (GWR), yang mampu mengakomodasi pengaruh lokasi atau wilayah pada data, dan menggunakan matriks pembobot untuk memperhitungkan jarak antar data tanpa memperhatikan variabel waktu dalam pengamatan (Kalang and Eboy, 2021; Saputra and Radam, 2022). Matriks pembobot merupakan matriks diagonal dengan elemen diagonalnya yang mewakili fungsi pembobot pada setiap titik lokasi. Pembobotan memiliki peran penting dalam analisis karena merepresentasikan jarak antar titik pengamatan satu dengan titik pengamatan lainnya, di mana semakin dekat jaraknya, semakin besar nilai pembobotnya (Marizal and Atiqah, 2022).

Fungsi pembobot dipengaruhi oleh ukuran yang disebut sebagai *bandwidth*, yang digunakan untuk mengatur jarak pengaruh pada analisis. Pembobot Kernel terdiri dari dua jenis, yaitu *fixed* kernel dan *adaptive* kernel. Pada *fixed* kernel, *bandwidth* optimal memiliki nilai yang sama pada setiap lokasi. Pada *adaptive* kernel, *bandwidth* optimal dapat berbeda pada tiap lokasi (Purhadi et al., 2021). Salah satu kernel yang termasuk dalam *Fixed* kernel adalah kernel *Fixed Gaussian* dan kernel *Fixed Bisquare*, yang keduanya menghasilkan bobot fungsi yang berbeda-beda. Pada *gaussian*, bobot fungsi akan semakin menurun ketika jarak semakin jauh, sedangkan pada *Fixed Bisquare* jika titik data atau lokasi tidak berada pada daerah *bandwidth* maka bobot akan diberi nilai nol (0) (Ulfie Safitri and Amaliana, 2021).

Metode *Geographically Weighted Regression* (GWR) dapat memperhatikan dan mengekstrak efek lokasi atau geometris dalam suatu analisis pada satu waktu. Namun, ketika data yang diberikan memiliki efek waktu atau periode, menggunakan metode GWR untuk menganalisis data tersebut dibutuhkan metode

yang lebih presisi. Data deforestasi dipengaruhi oleh efek waktu, di mana terdapat perubahan dari tahun ke tahun, baik mengalami penurunan maupun kenaikan. Oleh karena itu, diperlukan metode pengujian yang lebih informatif guna mendapatkan hasil yang lebih tepat dan akurat. Metode yang dapat digunakan dalam mempertimbangkan heterogenitas data lokasi dan waktu, serta dapat menangkap efek ketidakstasioneran data dari sisi wilayah atau lokasi maupun dari sisi temporal secara simultan adalah *Geographically and Temporally Weighted Regression* (GTWR). Dengan menggunakan metode GTWR, model hasil analisis dapat lebih representatif dibandingkan dengan hanya menggunakan model spasial atau geografis saja (Sholihin et al., 2017; Hu, 2022).

Penelitian menggunakan metode *Geographically and Temporally Weighted Regression* (GTWR) untuk memecahkan masalah terkait persentase penduduk miskin di Provinsi Jawa Timur. Penelitian tersebut melibatkan tiga variabel bebas, yaitu angka partisipasi sekolah umur 16-18 tahun, tingkat pengangguran, dan morbiditas. Dalam penelitian tersebut, dilakukan penggunaan dua jenis fungsi pembobot, yaitu *gaussian* dan *bisquare*, dan diperoleh nilai koefisien determinasi atau R^2 sebesar 98,994% dan 99,987% (Harianto et al., 2021).

Penelitian lain yang memanfaatkan GTWR adalah studi mengenai angka kematian balita yang dilakukan oleh Conita dan Tuti Purwaningsih. Studi ini melibatkan 11 variabel dan menggunakan kernel *gaussian*. Hasil penelitian menyatakan hanya 4 variabel bebas yang signifikan dan digunakan dalam model GTWR. Hasil tingkat kebaikan model yang diperoleh adalah MSE 1,084% dan R^2 53% (Conita and Purwaningsih, 2018). Selanjutnya, Dongling Bai dkk melakukan penelitian terkait emisi CO_2 di China menggunakan pembobot *gaussian*. Studi ini menghasilkan nilai koefisien determinasi sebesar 99,13% dan AIC sebesar

-937,491 (Bai et al., 2022). Terakhir, penelitian lain mengenai deforestasi pada Pulau Sumatera tahun 2011-2019 menggunakan RGTWR yang melibatkan 5 variabel bebas. Hasil penelitian menyatakan 4 variabel yang signifikan dalam model yaitu kepadatan penduduk, jumlah luas jalan dalam kilometer, jumlah PDRB hasil pertanian, dan jumlah luas kebakaran hutan. Studi ini menghasilkan R^2 sebesar 65% (Putra and Oktora, 2022).

Penelitian lain yang memanfaatkan *Geographically and Temporally Weighted Regression* (GTWR) untuk memodelkan deforestasi hutan lindung di Indonesia oleh Thea Zulfa Adiningrum. Penelitian tersebut hanya menggunakan enam variabel bebas, dan hanya tiga di antaranya yang signifikan dalam memprediksi variabel terikat dan dapat dijadikan model GTWR. Variabel bebas yang digunakan adalah jumlah perkebunan sawit, jumlah luas pemukiman, dan jumlah lahan non-hutan di kawasan hutan lindung. Pembobot *gaussian* digunakan dalam model ini menghasilkan nilai koefisien determinasi R^2 sebesar 0,158 untuk regresi OLS. Sedangkan, untuk *Geographically and Temporally Weighted Regression* (GTWR), nilai koefisien determinasi R^2 yang dihasilkan lebih optimal dari regresi OLS, yaitu sebesar 0,251 (Adiningrum et al., 2018).

Berdasarkan uraian di atas, akan dilakukan penelitian menggunakan analisis *Geographically and Temporally Weighted Regression* (GTWR) yang akan diberikan fungsi pembobot kernel *Fixed Gaussian* dan kernel *Fixed Bisquare* untuk membangun model penyelesaian masalah deforestasi di Indonesia. Tujuannya adalah untuk memberikan estimasi parameter yang berbeda-beda pada tiap wilayah atau lokasi. Hal ini diharapkan dapat menghasilkan model yang lebih optimal dalam memodelkan data deforestasi di Indonesia.

1.2. Rumusan Masalah

Berdasarkan penjelasan latar belakang yang telah disampaikan, pernyataan masalah dalam penelitian ini adalah sebagai berikut:

1. Bagaimana membangun model GTWR terhadap kasus deforestasi pada setiap provinsi di Indonesia dengan mempertimbangkan keragaman spasial-temporal pada tahun 2017-2020 menggunakan pembobot kernel *Fixed Gaussian* dan kernel *Fixed Bisquare*?
2. Bagaimana melakukan pengelompokan dan menentukan faktor-faktor yang berpengaruh terhadap kasus deforestasi pada setiap provinsi di Indonesia dalam tahun 2017-2020 menggunakan pembobot kernel *Fixed Gaussian* dan kernel *Fixed Bisquare*?
3. Bagaimana hasil perbandingan kebaikan model GTWR dengan pembobot kernel *Fixed Gaussian* dan kernel *Fixed Bisquare* dalam memodelkan kasus deforestasi di Indonesia pada tahun 2017-2020?

1.3. Tujuan Penelitian

Penelitian ini bertujuan untuk mencapai tujuan-tujuan berikut berdasarkan pernyataan masalah yang telah ditetapkan:

1. Membangun model GTWR terhadap kasus deforestasi pada setiap provinsi di Indonesia dengan mempertimbangkan keragaman spasial-temporal pada tahun 2017-2020 menggunakan pembobot kernel *Fixed Gaussian* dan kernel *Fixed Bisquare*.
2. Melakukan pengelompokan dan menentukan faktor-faktor yang berpengaruh terhadap kasus deforestasi pada setiap provinsi di Indonesia dalam tahun

2017-2020 menggunakan pembobot kernel *Fixed Gaussian* dan kernel *Fixed Bisquare*.

3. Membandingkan kebaikan model GTWR dengan pembobot kernel *Fixed Gaussian* dan kernel *Fixed Bisquare* dalam memodelkan kasus deforestasi di Indonesia pada tahun 2017-2020.

1.4. Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat sebagai berikut:

1. Memberikan referensi dan sumber informasi yang berguna dalam memahami faktor-faktor yang mempengaruhi kasus deforestasi di Indonesia pada tahun 2017-2020 dengan menggunakan model GTWR.
2. Memberikan kontribusi dalam pengembangan metode analisis spasial-temporal dan model GTWR yang dapat diterapkan pada studi-studi lain dalam domain yang serupa.

1.5. Batasan Masalah

Penelitian ini memiliki beberapa batasan sebagai berikut:

1. Data sekunder yang digunakan adalah data deforestasi di Indonesia dari 34 provinsi selama periode tahun 2017-2020 yang diperoleh dari Badan Pusat Statistik (BPS) Indonesia. Variabel terikat adalah kasus deforestasi, sedangkan variabel bebas yang digunakan adalah luas perkebunan kelapa sawit, PDRB pertambangan, luas hutan di Indonesia dari 34 provinsi, jumlah produksi kayu bulat, jumlah populasi/penduduk dari 34 provinsi, panjang jalan provinsi, luas perkebunan kopi, dan persentase penduduk miskin. Data longitude dan latitude digunakan sebagai koordinat titik.

2. Penelitian ini berfokus pada penggunaan model GTWR dengan dua jenis pembobot kernel, yaitu kernel *Fixed Gaussian* dan kernel *Fixed Bisquare*.
3. Analisis dilakukan terhadap data spasial-temporal deforestasi di Indonesia pada tingkat provinsi, sehingga hasil penelitian ini tidak dapat langsung diterapkan pada skala yang lebih kecil, seperti tingkat kabupaten atau kecamatan.

1.6. Sistematika Penulisan

Sistematika penulisan untuk penelitian ini terdiri dari 5 bab, yaitu:

1. Bab I

Bab ini berisi latar belakang masalah penelitian, yang menjelaskan alasan mengapa penelitian ini dilakukan, serta rumusan masalah yang akan dijawab dalam penelitian. Selain itu, dijelaskan juga tujuan penelitian, manfaat penelitian, dan batasan masalah yang menjadi fokus penelitian. Bab ini juga menjelaskan tentang sistematika penulisan yang digunakan dalam penelitian.

2. Bab II

Bab ini memaparkan teori-teori yang digunakan dalam penelitian, mulai dari definisi deforestasi hingga metode penelitian yang digunakan, yaitu Geographically and Temporally Weighted Regression (GTWR).

3. Bab III

Bab ini menjelaskan jenis penelitian yang dilakukan, sumber data yang digunakan, serta tahapan-tahapan yang dilakukan dalam penelitian.

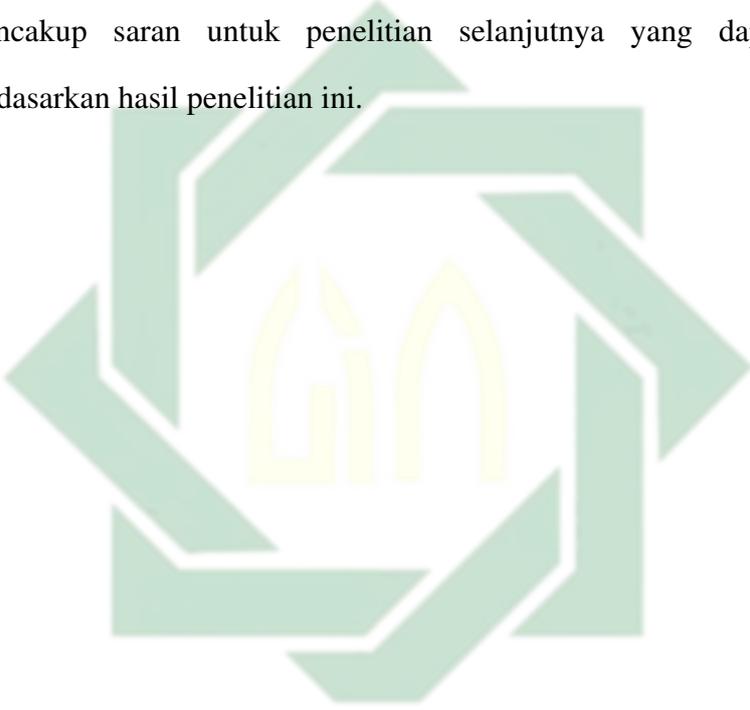
4. Bab IV

Bab ini berisi hasil dari penelitian terhadap data deforestasi di Indonesia

dengan menggunakan metode GTWR. Bab ini mencakup analisis deskriptif data dan pembentukan model GTWR.

5. Bab V

Bab ini berisi kesimpulan dari hasil penelitian yang dilakukan, yaitu analisis deforestasi di Indonesia menggunakan metode GTWR. Bab ini juga mencakup saran untuk penelitian selanjutnya yang dapat dilakukan berdasarkan hasil penelitian ini.



UIN SUNAN AMPEL
S U R A B A Y A

BAB II

TINJAUAN PUSTAKA

Pada bab ini, akan dijelaskan teori tentang deforestasi. Selanjutnya, akan dibahas teori mengenai metode penelitian yang meliputi pemahaman data spasial, standarisasi data, regresi linier berganda, serta uji asumsi klasik yang dilakukan. Kemudian, akan dijelaskan uji dependensi spasial dan uji heterogenitas spasial. Selain itu, metode Geographically Weighted Regression (GWR) juga akan dijelaskan secara teoritis. Terakhir, akan dibahas teori dari metode Geographically and Temporally Weighted Regression (GTWR).

2.1. Deforestasi

Umumnya deforestasi dapat diartikan dengan tindakan yang dilakukan oleh manusia terhadap hutan dengan mengkonversikan fungsi utama hutan secara permanen menjadi lahan non-hutan (Poor et al., 2019). Dampak yang diberikan oleh deforestasi secara ekologi sangat tinggi dimana hutan dengan keanekaragaman hayati yang tinggi akan mengalami penurunan yang signifikan, terganggunya siklus hidrologi, rusaknya rantai makanan sehingga dapat menyebabkan kepunahan, rusaknya kesuburan tanah hingga terjadi penurunan kualitas air tanah (Ardhana, 2016). Dilihat dari gangguan intensitas yang diberikan, deforestasi dibagi menjadi beberapa kelompok yaitu :

1. Deforestasi Ringan, dikategorikan deforestasi ringan misalnya pohon yang roboh akibat sambaran petir, tanah longsor, atau pohon yang mati secara alami.

2. Deforestasi Menengah, yang termasuk dalam kategori ini misalnya eksploitasi hutan dengan sistem silvikultur tebang pilih, kebakaran hutan, serta perubahan fungsi hutan menjadi lahan pertanian tradisional
3. Deforestasi Habis, semua tindakan yang menyebabkan fungsi hutan hilang masuk dalam kategori ini. Misalnya perluasan pemukiman, penebangan hutan liar, merubah hutan menjadi lahan pertanian, perkebunan, dan lainnya.

2.2. Data Spasial

Data Spasial merupakan suatu data dengan referensi utama suatu koordinat atau letak geografis. Uniknya data spasial memiliki 2 bagian penting yaitu informasi mengenai lokasi dan informasi yang memuat atribut (deskriptif) (Supuwingsih, N. N., Januhari, N. N. U., Suniantara, I. K. P., & Hanief, 2022).

1. Lokasi merupakan suatu informasi spasial yang termuat koordinat baik koordinat lintang utara, lintang selatan, bujur barat, bujur timur atau koordinat dimensi 3 yaitu koordinat XYZ termasuk juga proyeksi. Secara singkat informasi yang memuat lokasi dapat diletakkan di dalamnya sesuatu objek misalnya titik, garis, poligon, ataupun objek 3 dimensi.
2. Atribut adalah informasi lokasi yang memiliki penjelasan berkaitan dengan jenis populasi, jumlah vegetasi, ataupun parameter lain. Umumnya informasi atribut dapat dibuat atau dideskripsikan dalam bentuk tabel, grafik, laporan atau lainnya.

2.3. Standarisasi Data (*Z-Score*)

Standarisasi *Z-Score* adalah suatu metode untuk mentransformasikan data ke dalam skala standar dengan mean (rata-rata) 0 dan standard deviation 1. Metode

ini berguna untuk membandingkan dan mengevaluasi perbedaan antara nilai-nilai dalam dataset yang memiliki skala yang berbeda. Mengubah variabel-variabel dalam dataset menjadi skala yang sama dapat menghilangkan perbedaan dalam satuan dan rentang variabel yang ada, sehingga memungkinkan perbandingan yang lebih objektif dan bermakna antara variabel-variabel.

Rumus *Z-Score*

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

Keterangan :

x : Data aktual variabel penelitian

\bar{x} : Rata-rata nilai aktual

σ : Simpangan baku

Z : Nilai standarisasi

2.4. Regresi Linear

Analisis Regresi adalah suatu metode dalam ilmu statistik yang berkaitan dengan mengamati hubungan suatu variabel terikat Y terhadap suatu variabel bebas X dimana tujuannya mencari nilai estimasi prediksi variabel terikat Y terhadap nilai variabel bebas X yang diberikan. Regresi linear dapat dipecah menjadi 2 macam, yaitu pertama regresi linear sederhana dan regresi linear berganda. Regresi linear sederhana pengukuran hubungan hanya oleh dua variabel saja yaitu variabel bebas dan variabel terikat (Sarathy and Vadhan, 2022). Hubungan pada regresi linear sederhana ini dapat dinyatakan dalam persamaan berikut ini :

$$y = \beta_0 + \beta_1 x + \theta \quad (2.2)$$

dimana β_0 dan β_1 adalah parameter sedangkan θ merupakan eror perhitungan yang diberikan. Keterbatasan model regresi linear sederhana adalah pada bagian variabel yang digunakan dimana hanya 2 variabel (Ahmed et al., 2021). Analisis yang menggunakan lebih dari satu paling sedikit dua variabel X dapat dilakukan dengan memanfaatkan pengembangan regresi linear sederhana yaitu regresi linear berganda (Mawitjere et al., 2022). Persamaan umum dari regresi linear berganda seperti di bawah ini :

$$y = \beta_0 + \beta_1x + \beta_2x + \dots + \beta_zx_z + \theta \quad (2.3)$$

Jika menggunakan data pengamatan sebanyak m dengan variabel bebas sebanyak t maka persamaan estimasi dari analisis linear berganda yang terbentuk adalah seperti berikut :

$$y_i = \beta_0 + \beta_1x_{1i} + \beta_2x_{2i} + \dots + \beta_zx_{zi} + \theta_i = \beta_0 + \sum_{z=1}^t \beta_zx_{zi} + \theta_i \quad (2.4)$$

Keterangan :

y_i : Variabel terikat dengan observasi ke- i , $i = 1, 2, 3, \dots, m$

β_0 : merupakan *intercept* dari model regresi linear berganda

β_z : merupakan koefisien dari variabel bebas ke- z , $z = 1, 2, 3, \dots, t$

x_{zi} : observasi dari variabel bebas ke- z pada data pengamatan ke- i

θ_i : adalah galat yang diperoleh pada data ke- i memenuhi asumsi identik, independen, dan berdistribusi normal dengan mean 0 dan varians konstan ($\theta_i \sim IIDN(0, \sigma^2)$)

Pada persamaan *multiple linear regression* hubungan yang terbentuk antara

variabel Y dan variabel X adalah konstan pada tiap titik lokasi atau geografis (Permai et al., 2021). Selanjutnya Persamaan dapat dinyatakan dalam bentuk matriks.

$$Y = \beta X + \theta \quad (2.5)$$

dimana :

$$\begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ y_4 \\ \vdots \\ y_m \end{bmatrix} = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \beta_2 \\ \beta_3 \\ \vdots \\ \beta_t \end{bmatrix} \times \begin{bmatrix} 1 & x_{11} & x_{12} & x_{13} & \cdots & x_{1t} \\ 1 & x_{21} & x_{22} & x_{23} & \cdots & x_{2t} \\ 1 & x_{31} & x_{32} & x_{33} & \cdots & x_{3t} \\ 1 & x_{41} & x_{41} & x_{42} & \cdots & x_{4t} \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{m1} & x_{m2} & x_{m3} & \cdots & x_{mt} \end{bmatrix} + \begin{bmatrix} \theta_1 \\ \theta_2 \\ \theta_3 \\ \theta_4 \\ \vdots \\ \theta_m \end{bmatrix}$$

Keterangan :

- Y : matriks variabel terikat berukuran $(n \times 1)$
- β : matriks parameter berukuran $((t + 1) \times 1)$ dari variabel bebas
- X : matriks dari variabel bebas dengan ukuran $(n \times (t + 1))$
- θ : matriks galat atau residual ukuran $n \times 1$

2.4.1. Pendugaan Parameter Regresi Linear

Estimasi parameter regresi linear dilambangkan dengan $\hat{\beta}$. Pada analisis regresi linear berganda, parameter model regresi dapat ditaksir menggunakan metode OLS (*Ordinary Least Square*) dengan meminimalkan total kuadrat error $(\sum_{i=1}^m (\theta_i))$ (Shewa and Ugwuowo, 2023; Syahputra and Karim, 2016). Dari Persamaan (2.5) didapat:

$$Y = \beta X + \theta$$

$$\theta = Y - \beta X$$

sehingga dengan memanfaatkan metode OLS estimasi parameter dijabarkan sebagai berikut.

$$\begin{aligned}
 \left(\sum_{i=1}^m (\hat{\theta}_i)^2 \right) &= \hat{\boldsymbol{\theta}}^T \hat{\boldsymbol{\theta}} \\
 &= (\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}})^T (\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}) \\
 &= \mathbf{Y}^T \mathbf{Y} - \mathbf{Y}^T \mathbf{X}\hat{\boldsymbol{\beta}} - \hat{\boldsymbol{\beta}}^T \mathbf{X}^T \mathbf{Y} + \hat{\boldsymbol{\beta}}^T \mathbf{X}^T \mathbf{X}\hat{\boldsymbol{\beta}} \\
 &= \mathbf{Y}^T \mathbf{Y} - 2\hat{\boldsymbol{\beta}}^T \mathbf{X}^T \mathbf{Y} + \hat{\boldsymbol{\beta}}^T \mathbf{X}^T \mathbf{X}\hat{\boldsymbol{\beta}}
 \end{aligned}$$

agar $\hat{\boldsymbol{\theta}}^T \hat{\boldsymbol{\theta}}$ minimum aka diturunkan terhadap $\hat{\boldsymbol{\beta}}^T$ sehingga $\frac{\partial \hat{\boldsymbol{\theta}}^T \hat{\boldsymbol{\theta}}}{\partial \hat{\boldsymbol{\beta}}^T} = 0$, didapat:

$$\begin{aligned}
 \frac{\partial \hat{\boldsymbol{\theta}}^T \hat{\boldsymbol{\theta}}}{\partial \hat{\boldsymbol{\beta}}^T} &= \frac{\partial (\mathbf{Y}^T \mathbf{Y} - 2\hat{\boldsymbol{\beta}}^T \mathbf{X}^T \mathbf{Y} + \hat{\boldsymbol{\beta}}^T \mathbf{X}^T \mathbf{X}\hat{\boldsymbol{\beta}})}{\partial \hat{\boldsymbol{\beta}}^T} \\
 -2\mathbf{X}^T \mathbf{Y} + 2\mathbf{X}^T \mathbf{X}\hat{\boldsymbol{\beta}} &= 0 \\
 2\mathbf{X}^T \mathbf{X}\hat{\boldsymbol{\beta}} &= 2\mathbf{X}^T \mathbf{Y} \\
 \mathbf{X}^T \mathbf{X}\hat{\boldsymbol{\beta}} &= \mathbf{X}^T \mathbf{Y} \\
 \hat{\boldsymbol{\beta}} &= (\mathbf{X}^T \mathbf{X})^{-1} (\mathbf{X}^T \mathbf{Y})
 \end{aligned}$$

Dari hasil penjabaran diatas didapat estimasi parameter untuk regresi linear berganda seperti berikut.

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}^T \mathbf{X})^{-1} (\mathbf{X}^T \mathbf{Y}) \quad (2.6)$$

Persamaan (2.6) merupakan estimator OLS yang terbaik, tidak bias, serta linear

2.4.2. Uji Simultan

Setelah estimasi parameter dilakukan, maka selanjutnya diuji signifikansi dari parameter tersebut. Uji signifikansi terhadap parameter dilakukan dengan

tujuan seberapa layak parameter yang didapat dalam menjelaskan model, juga untuk melihat signifikansi variabel bebas apa saja yang berpengaruh terhadap variabel terikat.

Uji F merupakan salah satu uji dalam melihat signifikansi dari parameter model. Pada uji F serentak dilakukan evaluasi terhadap semua parameter model yang didapat guna melihat seberapa pengaruh parameter β terhadap variabel terikat Y dengan melakukan analisis varians serta memanfaatkan nilai F_{hitung} sebagai statistik uji (Romadhoni et al., 2022; Pamungkas et al., 2016). Berikut ini hipotesis yang digunakan.

$H_0 : \beta_1 = \beta_2 = \dots = \beta_t = 0$ (tidak ada pengaruh secara bersamaan variabel X terhadap variabel Y)

$H_1 : \text{minimal ada 1 } \beta_t \neq 0 \text{ dimana } z = 1, 2, \dots, t$ (ada pengaruh secara bersamaan variabel X terhadap variabel Y)

dengan keputusan tolak H_0 jika nilai $p\text{-value} < \alpha$ atau $F_{hitung} > F_{(\alpha, t, m-t-1)}$

Rumus Statistik Uji :

$$F_{hitung} = \frac{MSR(\text{Mean Square Regression})}{MSE(\text{Mean Square Error})} \quad (2.7)$$

Lebih jelasnya pengujian secara simultan dapat dilihat pada **Tabel (2.1)** di bawah ini.

Tabel 2.1 Tabel analisis varians

No.	Model	df	Sum of square	Mean Square	F_{hitung}
1.	Regression	t	$SSR = \sum_{i=1}^m (\hat{y}_i - \bar{y})^2$	$MSR = \frac{SSR}{t}$	
2.	Residual	$m - t - 1$	$SSE = \sum_{i=1}^m (y_i - \hat{y}_i)^2$	$MSE = \frac{SSE}{m-t-1}$	$F_{hitung} = \frac{MSR}{MSE}$
3.	Total	$m - 1$	$SST = \sum_{i=1}^m (y_i - \bar{y})^2$		

(Sumber: (Pamungkas et al., 2016))

2.4.3. Uji Parsial

Uji parsial atau uji t dilakukan untuk melihat parameter β yang benar-benar memiliki nilai pengaruh terhadap Y, dengan tujuan untuk mendapatkan informasi apakah parameter β jika diuji secara terpisah atau sendiri-sendiri masih dapat mempertahankan pengaruhnya terhadap variabel Y pada model (Azkia and Setiawan, 2022). Hipotesis yang digunakan sebagai berikut.

$H_0 : \beta_z = 0$ dengan $z = 1, 2, 3, 4, \dots, t$ (tidak ada pengaruh secara individu variabel X terhadap terhadap variabel Y)

$H_1 : \text{minimal ada satu } \beta_z \neq 0 \text{ dimana } z = 1, 2, \dots, t \text{ (ada pengaruh secara individu variabel X terhadap terhadap variabel Y)}$

dengan keputusan tolak H_0 jika nilai $p\text{-value} < \alpha$ atau $|t_{hitung}| > t_{(\frac{\alpha}{2}, m-t-1)}$

Rumus statistik uji t :

$$t_{hitung} = \frac{\hat{\beta}_z}{se(\hat{\beta}_z)} \quad (2.8)$$

dimana,

$\hat{\beta}_z$: koefisien regresi ke- z

$se(\hat{\beta}_z)$: standar error dari koefisien $\hat{\beta}_z$

2.5. Deteksi Multikolinearitas

Uji yang harus terpenuhi dalam pembentukan suatu model regresi adalah model harus lulus uji multikolinearitas. Uji ini dilakukan untuk melihat apakah ada atau tidak korelasi antara satu variabel bebas dengan variabel bebas lainnya dalam model, jika ada maka terdapat kasus multikolinearitas. Model yang terbentuk tetapi terdeteksi multikolinearitas maka akan menghasilkan suatu estimasi parameter yang memiliki nilai galat yang tinggi. Kasus multikolinearitas dalam model dapat dideteksi menggunakan hasil dari perhitungan VIF (*Variance Inflation Factor*) dimana kriteria ini akan mendeteksi kasus multikolinearitas pada model regresi yang mengandung dua atau lebih variabel bebas (Mardiatmoko, 2020).

Rumus kriteria VIF :

$$VIF = \frac{1}{1 - R_z^2} \quad (2.9)$$

Dimana R_z^2 adalah koefisien determinasi dengan rentang nilai $0 \leq R^2 \leq 1$ dari satu variabel X_z dengan variabel bebas lainnya dimana $z = 1, 2, 3, \dots, t$.

$$R_z^2 = 1 - \frac{SSR}{SST} = 1 - \frac{\sum_{i=1}^m (\hat{e}_i)}{\sum_{i=1}^m (y_i - \bar{y})^2} \quad (2.10)$$

Nilai $VIF > 10$ menandakan adanya kasus multikolinearitas pada model, jika demikian untuk mengatasi hal ini dapat dikeluarkan variabel bebas yang tidak signifikan pada model dimulai dari variabel bebas yang mengandung nilai VIF tertinggi kemudian dilakukan regresi kembali variabel yang memiliki signifikansi terhadap model.

2.6. Uji Asumsi Klasik

Pada metode OLS (*Ordinary Least Square*) perlu dilakukan uji asumsi klasik atau asumsi dasar pada residual untuk mendapatkan nilai estimasi model regresi yang optimal serta tidak ada bias sehingga model yang terbentuk dapat mendekati keadaan yang sebenarnya.

2.6.1. Uji Asumsi Identik (homoskedastisitas) Residual

Heteroskedastisitas merupakan asumsi pada model regresi dengan tujuan melihat ada atau tidaknya perbedaan varians dari galat atau error antar satu observasi dengan observasi lainnya. Model regresi yang optimal haruslah bersifat identik yang artinya varians residual dari data bersifat homoskedastisitas. Salah satu cara melakukan melihat heteroskedastisitas adalah dengan dilakukan perhitungan menggunakan persamaan Glejser (Nordiansyah et al., 2022). Cara kerja persamaan Glejser adalah dengan meregresikan nilai absolut dari residual terhadap variabel X dengan hipotesis uji seperti berikut.

$H_0 : \sigma_z^2 = 0$ dengan $z = 1, 2, 3, 4, \dots, t$ (residual bersifat homoskedastisitas)

$H_1 : \text{minimal ada satu } \sigma_z^2 \neq 0$ dimana $z = 1, 2, \dots, t$ (ada heteroskedastisitas)

Rumus statistik uji sebagai berikut.

$$F_{\text{statistik}} = \frac{\left(\sum_{i=1}^m \left(|\hat{\theta}_i| - |\bar{\theta}_i| \right)^2 \right)}{t} \div \frac{\left(\sum_{i=1}^m \left(|\theta_i| - |\hat{\theta}_i| \right)^2 \right)}{m - t - 1} \quad (2.11)$$

dengan daerah keputusan : tolak H_0 jika nilai $p\text{-value} < \alpha$ atau

$F_{\text{statistik}} > F_{(\alpha, (t, m-t-1))}$ artinya residual tidak identik atau adanya kasus

heteroskedastisitas.

2.6.2. Uji Asumsi Independen (Autokorelasi) Residual

Selanjutnya asumsi yang harus terpenuhi dalam metode OLS adalah autokorelasi atau asumsi independen yaitu tujuannya untuk melihat ada atau tidaknya korelasi atau hubungan antar residual dengan kata lain residual model haruslah tidak saling independen (Nurhalizah and Sitompul, 2022). Pendeteksian kasus autokorelasi dapat memanfaatkan perhitungan dari persamaan *Durbin-Watson* dengan hipotesis uji sebagai berikut :

$H_0 : \rho = 0$ (tidak ada autokorelasi)

$H_1 : \rho > 0$ (terjadi autokorelasi)

Rumus uji *Durbin-Watson*

$$d = \frac{\sum_{i=2}^m (\theta_i - \theta_{i-1})^2}{\sum_{i=1}^m \theta_i^2} \quad (2.12)$$

dengan,

θ_i : nilai error atau residual ke- i

θ_{i-1} : error dari perhitungan sebelumnya atau $i - 1$

Pengambilan keputusan dengan melihat nilai d berdasarkan tabel *Durbin-Watson* berikut ini.

Tabel 2.2 Tabel keputusan Durbin-Watson

Durbin-Watson Value	Description
< 1.10	Autokorelasi Positif
1.10 – 1.54	Tidak Ada Kesimpulan
1.55 – 2.46	Tidak Ada Autokorelasi
2.47 – 2.90	Tidak Ada Kesimpulan
> 2.90	Autokorelasi Negatif

(Sumber: (Algifari, 1997))

2.6.3. Uji Asumsi Normalitas (Normal Distribution) Residual

Asumsi normalitas terhadap residual dilakukan bertujuan untuk mengetahui bahwa model regresi yang terbentuk tidak bias. Residual yang tidak berdistribusi normal dapat disebabkan oleh adanya *outlier* pada data yang berasal dari populasi tidak normal. Pengecekan kenormalitasan residual dapat dilakukan dengan perhitungan persamaan *Kolmogorov Smirnov*, atau dapat dengan menelaah secara langsung melalui *Probability-probability Plot* (P-P Plot) (Rifky Pontoh and Alfu Imy, 2022). Hipotesis pada uji normalitas adalah seperti berikut.

H_0 : Residual data berdistribusi normal

H_1 : Residual data tidak berdistribusi normal

Rumus *Kolmogorov Smirnov* :

$$D = \max_{1 < i < m} \left(F(Y_i) - \frac{i-1}{m}, \frac{i-1}{m} - F(Y_i) \right) \quad (2.13)$$

dimana $F(Y_i)$ merupakan distribusi kumulatif. Keputusan Tolak H_0 jika

$D > D_\alpha(m)$ dimana $D_\alpha(m)$ merupakan titik kritis dari distribusi D dalam tabel *Kolmogorov Smirnov*. Gagal tolak H_0 jika nilai dari $p\text{-value} > \alpha$ yang menandakan bahwa terima H_0 atau normalitas pada residual terpenuhi.

2.7. Uji Heterogenitas Spasial dan Temporal

Langkah selanjutnya sebelum masuk dalam pemodelan *Geographically weighted regression* ada baiknya dilakukan uji efek spasial dari data.

2.7.1. Uji Heterogenitas Spasial

Uji heterogenitas spasial dilakukan dengan tujuan untuk melihat ada tidaknya persamaan atau perbedaan varians yang dapat menjadi karakteristik tersendiri pada tiap titik lokasi. Efek heterogenitas dapat menyebabkan parameter model regresi yang unik di tiap lokasi yang diamati. Uji yang dapat dilakukan untuk mendeteksi kasus heterogenitas spasial adalah *Breusch-Pagan Test* (Rahmadhana and Utomo, 2022). Uji *Breusch-Pagan* dilakukan dengan memanfaatkan perhitungan sederhana dari *R-Square* (R^2) pada beberapa persamaan yang diregresikan (Putri et al., 2022).

Hipotesis dari uji *Breusch-Pagan* sebagai berikut.

$$H_0 : \sigma_1^2 = \sigma_2^2 = \dots = \sigma_z^2 = \sigma^2 \text{ (Homoskedastisitas)}$$

$$H_1 : \exists z, \sigma_z^2 \neq \sigma^2 \text{ (Heteroskedastisitas)}$$

Rumus *Breusch-Pagan Test*

$$BP = \left(\frac{1}{2}\right) f^T \mathbf{Z} (\mathbf{Z}^T \mathbf{Z})^{-1} \mathbf{Z}^T f \quad (2.14)$$

dimana f merupakan elemen vektor yang dapat dicari dengan cara :

$$f_i = \left(\frac{\theta_i^2}{\sigma^2} - 1 \right)$$

dimana θ_i^2 merupakan sisaan atau residual pengamatan ke- i , $\theta_i = (y_i - \hat{y}_i)$, dan \mathbf{Z} adalah matriks $(m(t+1))$ yang berisi elemen vektor yang telah dinormal bakukan pada tiap titik lokasi pengamatan. keputusan tolak H_0 jika nilai dari $BP > \chi_{\alpha,t}^2$ atau saat nilai $p\text{-value} < \alpha$ yang berarti terdapat efek varians yang berbeda pada tiap lokasi pengamatan.

2.7.2. Uji Heterogenitas Temporal

Pada uji heterogenitas temporal dapat diputuskan dengan beberapa cara yaitu salah satunya dilihat dari deskripsi visual pada *Box-Plot* dimana memberikan ragam kesimetrisan yang digambarkan oleh ukuran *box* dan *outlier* pada tiap waktu pengamatan. Jika ukuran kotak (*box*) besar, menunjukkan ragam data yang signifikan pada waktu tertentu, sedangkan peningkatan jumlah atau nilai ekstrem (*outlier*) menunjukkan adanya variasi yang tidak biasa atau kasus-kasus yang berbeda pada waktu tersebut. Hal ini dapat mengindikasikan adanya heterogenitas temporal dalam data, di mana data pada waktu-waktu tertentu memiliki karakteristik atau pola yang berbeda dari waktu lainnya (Triscowati et al., 2018).

2.8. Model *Geographically Weighted Regression* (GWR)

Motivasi dari kebutuhan untuk mengatasi masalah spasial secara geografis (atau lokal) di perkenalkanlah oleh Fotheringham, Brunsdon, dan Charlton pada tahun 1967 metode *Geographically Weighted Regression* yang mana merupakan pengembangan dari regresi linear klasik. Berbeda dengan regresi linear klasik

dengan penaksiran parameter dari model regresi bersifat global, maka metode *Geographically Weighted Regression* memiliki keuntungan utama yang memungkinkan perkiraan parameter bervariasi di seluruh ruang, yang dapat memberikan cara untuk mengakomodasi konteks spasial dimana titik pengamatan berada (Kurkcuoglu, 2022; Fotheringham et al., 2014). Karena model regresi OLS menyediakan basis untuk *Geographically Weighted Regression*, dengan memasukkan koordinat bujur dan lintang (u_i, v_i) ke Persamaan (2.4), didapat model persamaan *Geographically Weighted Regression* sebagai berikut (Saputra and Radam, 2022).

$$y_i(u_i, v_i) = \beta_0(u_i, v_i) + \sum_{z=1}^t \beta_z(u_i, v_i)x_{zi} + \theta_i; i = 1, 2, 3, \dots, m \quad (2.15)$$

keterangan :

y_i : respon variabel amatan ke- i

(u_i, v_i) : koordinat amatan ke- i

$\beta_0(u_i, v_i)$: *Intercept* parameter GWR

$\beta_z(u_i, v_i)$: koefisien variabel bebas ke- z pada amatan ke- i

x_{zi} : variabel bebas ke- z saat amatan ke- i

θ_i : adalah galat yang diperoleh pada data ke- i memenuhi asumsi identik, independen, dan berdistribusi normal dengan mean 0 dan varians konstan

$$(\theta_i \sim IIDN(0, \sigma^2))$$

Model *Geographically Weighted Regression* dengan variabel terikat Y kemudian ditaksir oleh variabel bebas X akan membentuk estimasi pendugaan parameter yang berbeda tergantung pada titik lokasi dimana pengamatan dilakukan (Kopczewska and Cwiakowski, 2021).

Pendugaan atau estimasi parameter dari model GWR dilakukan dengan menggunakan metode WLS (*Weighted Least Square*) yang mana metode ini merupakan metode OLS yang diberikan pembobot berbeda pada tiap lokasi pengamatan. Estimasi GWR dilambangkan dengan $\hat{\beta}(u_i, v_i)$ dapat dituliskan sebagai berikut.

$$\hat{\beta}(u_i, v_i) = (\mathbf{X}^T \mathbf{W}(u_i, v_i) \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W}(u_i, v_i) \mathbf{Y} \quad (2.16)$$

Estimasi parameter $\hat{\beta}(u_i, v_i)$ adalah stimasi yang tak bias dan konsisten untuk $\beta(u_i, v_i)$

2.8.1. *Bandwidth* dan Fungsi Pembobot Kernel Model (GWR)

GWR mencoba menangkap variasi spasial dengan memasang model regresi pada setiap titik subjek dalam data, memberi bobot pada semua pengamatan yang berdekatan dengan fungsi jarak dari subjek tersebut. Bobot yang lebih dekat dengan subjek memiliki lebih banyak pengaruh pada koefisien regresi yang dihasilkan daripada pengamatan yang lebih jauh, dengan begitu jelaslah bahwa fungsi kernel spasial dan *bandwidth* yang digunakan dalam proses pemasangan model berdampak pada estimasi koefisien GWR (Koç, 2022). Fungsi kernel merupakan fungsi simetris, terbatas, kontinu yang dilambangkan dengan $K(u)$ dan $\int_{-\infty}^{\infty} K(u) du = 1$.

Proses estimasi parameter model GWR pada lokasi pengamatan (u_i, v_i) , membutuhkan fungsi pembobot spasial. Bentuk pembobotan spasial merupakan suatu matriks diagonal dengan elemen-elemen penyusun matriks adalah fungsi pembobot pada tiap lokasi subjek yang diamati dimana konsep dasar yang

digunakan adalah konsep dasar jarak (Permai et al., 2021).

$$w_{ij} = \begin{cases} 1 & , d_{ij} > b \\ 0 & , d_{ij} \leq b \end{cases} \quad (2.17)$$

dimana d_{ij} adalah *euclidean distance* antara amatan lokasi ke- i dengan amatan lokasi ke- j dan b adalah parameter pemulus atau *bandwidth*. nilai d_{ij} didapat dengan cara:

$$d_{ij} = \sqrt{(u_i - u_j)^2 + (v_i - v_j)^2} \quad (2.18)$$

Bandwidth adalah titik terjauh dari radius dalam suatu lingkaran, dimana jumlah pengamatan di setiap titik subjek yang terletak dalam jangkauan memiliki pengaruh dalam membentuk parameter model serta mengontrol peluruhan jarak dalam fungsi pembobotan. Misalnya, dengan meningkatnya *bandwidth*, estimasi parameter dari koefisien GWR mendekati model global sehingga model pengamatan akan semakin halus dengan bias yang besar karena semakin banyak subjek yang berada pada radius b . Di sisi lain, jika *bandwidth* yang lebih kecil digunakan artinya estimasi parameter hanya menggunakan sedikit pengamatan yang hanya berada pada radius b sehingga akan membentuk model yang kasar sebab varians yang semakin besar. Pemilihan fungsi kernel spasial dan (atau) *bandwidth* merupakan langkah penting dalam implementasi GWR (Oshan et al., 2019).

Bandwidth optimum yang diperoleh dari fungsi pembobot kernel akan berbeda pada model regresi di tiap lokasi amatan. Metode yang dapat digunakan dalam menentukan *bandwidth* optimum adalah *CV* (*Cross Validation*) yang

dirumuskan seperti berikut (Hu, 2022).

$$CV(b) = \sum_{i=1}^n (y_i - \hat{y}_{\neq i}(b))^2 \quad (2.19)$$

dengan n adalah jumlah subjek pengamatan, dan $\hat{y}_{\neq i}(b)$ adalah estimasi dari y_i titik di lokasi (u_i, v_i) yang diberi nilai 0 sebab tidak masuk dalam perhitungan estimasi model. Nilai *bandwidth* optimum diambil dari nilai CV(b) yang minimum (Nisa et al., 2022).

Fungsi pembobot kernel yang akan digunakan dalam penelitian ini adalah fungsi pembobot *fixed kernel Gaussian* dan *fixed kernel Bisquare*. Rumus fungsi pembobot *fixed kernel Gaussian* (Damayanti and Agustin Nuriani Sirodj, 2022).

$$w_j(u_i, v_i) = \exp\left(-\frac{1}{2} \left(\frac{d_{ij}}{b}\right)^2\right) \quad (2.20)$$

Rumus fungsi pembobot *fixed kernel Bisquare* (Pan et al., 2022).

$$w_j(u_i, v_j) = \begin{cases} \left(1 - \left(\frac{d_{ij}}{b}\right)\right)^2, & d_{ij} \leq b \\ 0, & d_{ij} > b \end{cases} \quad (2.21)$$

keterangan :

d_{ij} = euclidean distance lokasi i ke lokasi j

b = Bandwidth

2.9. Model Geographically and Temporally Weighted Regression (GTWR)

Efek temporal yang kompleks dapat menyebabkan ketidakstasioneran dalam model, maka dibutuhkan metode yang dapat mengakomodasi bukan hanya efek spasial tetapi juga efek temporal sehingga dikembangkanlah metode GWR menjadi GTWR. Metode GTWR (*Geographically and Temporally weighted*

regression) adalah pembaharuan dari GWR dengan variasi temporal dan menggabungkan heterogenitas spasial dan temporal dalam data sehingga dapat meningkatkan *goodness of fit* dari model. Non stasioneritas spatio temporal dalam estimasi parameter dapat ditangkap dengan menyusun matriks bobot berdasarkan jarak spatiotemporal (Liao et al., 2023). Model GTWR dengan variabel terikat y_i dan variabel bebas sebanyak p untuk setiap lokasi pengamatan (u_i, v_i, t_i) dapat dinyatakan dalam persamaan umum sebagai berikut (Zou et al., 2022).

$$y_i(u_i, v_i, t_i) = \beta_0(u_i, v_i, t_i) + \sum_{z=1}^t \beta_z(u_i, v_i, t_i)x_{zi} + \theta_i; i = 1, 2, 3, \dots, m \quad (2.22)$$

keterangan :

y_i : respon variabel amatan ke- i

$\beta_0(u_i, v_i, t_i)$: *Intercept* parameter GWR

$\beta_z(u_i, v_i, t_i)$: koefisien variabel bebas ke- z pada amatan ke- i

x_{zi} : variabel bebas ke- z saat amatan ke- i

θ_i : sisaan pada amatan ke- i dimana haruslah $(\theta_i \sim IIDN(0, \sigma^2))$

2.9.1. Estimasi Model *Geographically and Temporally Weighted Regression* (GTWR)

Estimasi parameter GTWR dapat dilakukan dengan beberapa cara, misalnya menggunakan MLE (*Maximum Likelihood Estimation*) atau menggunakan metode pengembangan OLS yaitu WLS (*Weighted Least Square*). Metode WLS memberikan pembobot berbeda pada tiap titik lokasi yang menjadi pengamatan (Irawan et al., 2020). Diberikan matriks $\mathbf{W}(u_i, v_i, t_i)$ dengan $w_j(u_i, v_i, t_i)$ merupakan elemen diagonal matriks untuk lokasi (u_i, v_i, t_i) dimana $j = 1, 2, 3, \dots, n$ maka lokasi (u_i, v_i, t_i) ditaksir dengan menambahkan pembobot $w_j(u_i, v_i, t_i)$ ke dalam Persamaan (2.15) diminimumkan *SSE* sehingga didapat

persamaan berikut (Astuti et al., 2018; Sutro et al., 2020).

$$\sum_{j=1}^n w_j(u_i, v_i, t_i) \theta_j^2 = \sum_{j=1}^n w_j(u_i, v_i, t_i) \left(y_j - \beta_0(u_i, v_i, t_i) - \sum_{z=1}^t \beta_z(u_i, v_i, t_i) x_{jz} \right)^2 \quad (2.23)$$

dalam bentuk matriks:

$$\mathbf{X} = \begin{bmatrix} 1 & x_{11} & x_{12} & \dots & x_{1z} \\ 1 & x_{21} & x_{22} & \dots & x_{2z} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{j1} & x_{j2} & \dots & x_{jz} \end{bmatrix}; \mathbf{Y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_j \end{bmatrix}; \boldsymbol{\beta}(u_i, v_i, t_i) = \begin{bmatrix} \beta_0(u_i, v_i, t_i) \\ \beta_1(u_i, v_i, t_i) \\ \vdots \\ \beta_z(u_i, v_i, t_i) \end{bmatrix}$$

dengan ordo matriks \mathbf{X} ($n \times (t+1)$), matriks \mathbf{Y} ($n \times 1$), dan $\boldsymbol{\beta}$ ($(t+1) \times 1$). Maka, persamaan GTWR dalam bentuk matriks adalah sebagai berikut:

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta}$$

Pada persamaan GTWR, bobot \mathbf{W} pada titik koordinat (u_i, v_i, t_i) adalah matriks diagonal dengan elemen bobot $w_1(u_i, v_i, t_i), w_2(u_i, v_i, t_i), \dots, w_j(u_i, v_i, t_i)$. Kemudian, penaksiran parameter model GTWR dengan metode WLS dilakukan dengan menyelesaikan persamaan berikut:

$$\begin{aligned} \boldsymbol{\theta}^T \mathbf{W}(u_i, v_i, t_i) \boldsymbol{\theta} &= [\mathbf{Y} - \mathbf{X}\boldsymbol{\beta}(u_i, v_i, t_i)]^T \mathbf{W}(u_i, v_i, t_i) [\mathbf{Y} - \mathbf{X}\boldsymbol{\beta}(u_i, v_i, t_i)] \\ &= \mathbf{Y}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{Y} - \mathbf{Y}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{X}\boldsymbol{\beta}(u_i, v_i, t_i) \\ &\quad - \boldsymbol{\beta}^T(u_i, v_i, t_i) \mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{Y} \\ &\quad + \boldsymbol{\beta}^T(u_i, v_i, t_i) \mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{X}\boldsymbol{\beta}(u_i, v_i, t_i) \end{aligned} \quad (2.24)$$

karena $\mathbf{X}\boldsymbol{\beta}(u_i, v_i, t_i) = \boldsymbol{\beta}^T(u_i, v_i, t_i) \mathbf{X}^T$, maka persamaan menjadi :

$$\begin{aligned} \boldsymbol{\theta}^T \mathbf{W}(u_i, v_i, t_i) \boldsymbol{\theta} &= \mathbf{Y}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{Y} - 2\boldsymbol{\beta}^T(u_i, v_i, t_i) \mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{Y} \\ &+ \boldsymbol{\beta}^T(u_i, v_i, t_i) \mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{X} \boldsymbol{\beta}(u_i, v_i, t_i) \end{aligned} \quad (2.25)$$

jika $\boldsymbol{\theta}^T \mathbf{W}(u_i, v_i, t_i) \boldsymbol{\theta}$ diturunkan terhadap matriks $\boldsymbol{\beta}^T(u_i, v_i, t_i)$ maka persamaan menghasilkan:

$$\begin{aligned} -2\mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{Y} + 2\mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{X} \boldsymbol{\beta}(u_i, v_i, t_i) &= 0 \\ \mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{X} \boldsymbol{\beta}(u_i, v_i, t_i) &= \mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{Y} \\ (\mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{X} \boldsymbol{\beta}(u_i, v_i, t_i) &= (\mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{Y} \\ \hat{\boldsymbol{\beta}}(u_i, v_i, t_i) &= (\mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{Y} \end{aligned}$$

sehingga estimasi parameter untuk setiap lokasi dari model GTWR berikut (Zhou et al., 2019).

$$\hat{\boldsymbol{\beta}}(u_i, v_i, t_i) = (\mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{Y} \quad (2.26)$$

karena terdapat i lokasi sehingga penaksiran estimasi parameter GTWR ini merupakan taksiran untuk tiap baris dari matriks parameter lokal pada seluruh lokasi amatan, dengan bentuk matriks seperti di bawah ini :

$$\hat{\boldsymbol{\beta}} = \begin{bmatrix} \beta_0(u_1, v_1, t_1) & \beta_1(u_1, v_1, t_1) & \beta_2(u_1, v_1, t_1) & \dots & \beta_z(u_1, v_1, t_1) \\ \beta_0(u_2, v_2, t_2) & \beta_1(u_2, v_2, t_2) & \beta_2(u_2, v_2, t_2) & \dots & \beta_z(u_2, v_2, t_2) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \beta_0(u_i, v_i, t_i) & \beta_1(u_i, v_i, t_i) & \beta_2(u_i, v_i, t_i) & \dots & \beta_z(u_i, v_i, t_i) \end{bmatrix}$$

selanjutnya pada Persamaan (2.26), estimasi dari $\hat{\boldsymbol{\beta}}(u_i, v_i, t_i)$ haruslah bersifat tak bias, sehingga dapat dibuktikan bahwa:

$$\begin{aligned}
E \left[\widehat{\beta}(u_i, v_i, t_i) \right] &= E \left[(\mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{Y} \right] \\
&= (\mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) E[\mathbf{Y}] \\
&= (\mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{X} \beta(u_i, v_i, t_i) \\
&= \mathbf{I} \beta(u_i, v_i, t_i) \\
&= \beta(u_i, v_i, t_i)
\end{aligned}$$

Karena $E \left[\widehat{\beta}(u_i, v_i, t_i) \right] = \beta(u_i, v_i, t_i)$ maka terbukti bahwa $\widehat{\beta}(u_i, v_i, t_i)$ bersifat tak bias untuk bentuk $\beta(u_i, v_i, t_i)$. Selanjutnya dimisalkan $l = (u_i, v_i, t_i)$ matriks *covarian* dari estimasi $\widehat{\beta}(u_i, v_i, t_i)$ adalah sebagai berikut:

$$\begin{aligned}
Cov[\beta l] &= Cov \left[(\mathbf{X}^T \mathbf{W} l \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W} l \mathbf{Y} \right] \\
&= \left((\mathbf{X}^T \mathbf{W} l \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W} l \right) Cov[\mathbf{Y}] \left((\mathbf{X}^T \mathbf{W} l \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W} l \right)^T \\
&= (\mathbf{X}^T \mathbf{W} l \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W} l (\sigma^2 \mathbf{I}) \mathbf{W} l \mathbf{X} (\mathbf{X}^T \mathbf{W} l \mathbf{X})^{-1} \\
&= \mathbf{C} \mathbf{C}^T \sigma^2
\end{aligned}$$

dimana $\mathbf{C} = (\mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W}(u_i, v_i, t_i)$

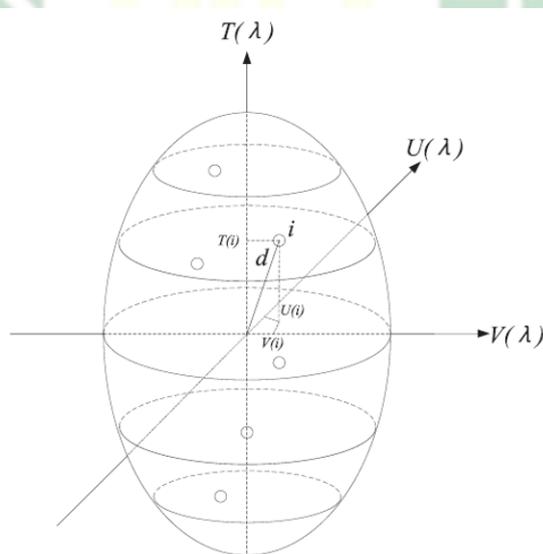
Dengan penaksiran parameter untuk tiap lokasi i dengan jumlah variabel bebas p dari model GTWR sangat mirip dengan penaksiran GWR yang menggunakan WLS maka dapat ditulis dalam persamaan berikut (Bai et al., 2022).

$$\widehat{\beta}(u_i, v_i, t_i) = (\mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{Y} \quad (2.27)$$

dimana $\mathbf{W}(u_i, v_i, t_i) = \text{diagonal} [w_{i1}, w_{i2}, \dots, w_{im}]$ dan m sebagai jumlah data pengamatan. Elemen diagonal $w_{ij} (1 \leq j < m)$ merupakan fungsi jarak spasial (u, v) dan temporal pada waktu t yang sesuai dengan pembobotan pada lokasi i yang berdekatan. Oleh karena itu model GTWR sangat bergantung pada ketepatan fungsi jarak spasial dan temporal w_{ij} .

2.10. Jarak Spasial-Temporal

Jika setiap sumbu koordinat memiliki efek skala yang sama pada jarak di sistem koordinat ruang-waktu, maka sistem koordinat dapat ditarik oleh bola dengan radius tertentu. Jarak dapat didefinisikan sebagai jarak euclidean, namun ruang dan waktu biasanya diukur satuan yang berbeda, yaitu jarak ruang menggunakan meter atau kilometer dan waktu menggunakan jam atau hari. Oleh karena itu, asumsikan bahwa setiap sumbu koordinat memiliki efek skala yang sama tidak valid. Melihat kompleksitas efek ukuran dari berbagai posisi lokasi dan waktu, untuk menghitung interval temporal dan spasial antara titik regresi data yang telah terukur maka diadopsi sistem kerja koordinat ellipsoidal (Ma et al., 2018).



Gambar 2.1 *Ilustrasi Jarak Spatiotemporal*

(Sumber:(Ma et al., 2018))

Gambar (2.1) menunjukkan model jarak titik spasial-temporal observasi i . $(u(\lambda), v(\lambda))$ adalah koordinat pengamatan dimana titik observasi i berada, dan $t(\mu)$ adalah waktu ketika observasi i diukur. Dengan demikian, secara sederhana

dan dengan metode langsung untuk menghitung jarak ruang-waktu adalah dengan mengintegrasikan waktu secara langsung ke dalam jarak spasial. Bidang $(u(\lambda), v(\lambda))$ menunjukkan dimensi spasial, sedangkan sumbu vertikal $t(\mu)$ menunjukkan dimensi sementara. Pengamatan dalam bidang $(u(\lambda), v(\lambda))$ yang sama mewakili observasi i diukur di lokasi yang berbeda pada waktu yang sama. Titik-titik dengan ordinat yang sama menunjukkan perjalanan di lokasi yang sama pada waktu yang berbeda. Mirip dengan persamaan jarak euclidean 3D yaitu $d^2 = x^2 + y^2 + z^2$, sehingga jarak spasial-temporal dapat didefinisikan secara langsung menambahkan jarak temporal ke fungsi jarak spatiotemporal (Liu et al., 2020).

Diberikan d^S adalah jarak spasial dan d^T adalah jarak temporal, sehingga bentuk jarak spasial-temporal dapat dikembangkan sebagai berikut:

$$d_{ij}^{ST} = d_S^2 \oplus d_T^2 \quad (2.28)$$

dengan \oplus representatif dari operator penjumlahan fungsi yang berbeda. Misalkan " + " dipilih dalam menggabungkan d_{ij}^S dan d_{ij}^T dimana $(d_{ij}^S)^2 = (u_i - u_j)^2 + (v_i - v_j)^2$ dan $(d_{ij}^T)^2 = (t_i - t_j)^2$, akibatnya jarak spasial-temporal antar observasi yang berbeda dapat dinyatakan sebagai kombinasi bobot linear antara d_{ij}^S dan d_{ij}^T seperti dibawah ini.

$$(d_{ij}^{ST})^2 = \lambda [(u_i - u_j)^2 + (v_i - v_j)^2] + \mu (t_i - t_j)^2 \quad (2.29)$$

dimana t_i dan t_j masing-masing adalah waktu yang diamati dari observasi i dan j . λ dan μ adalah bobot untuk menyeimbangkan efek yang berbeda dikarenakan jarak ruang dan waktu diukur menggunakan satuan yang berbeda sehingga d_{ij}^{ST} dapat

digunakan dalam mengukur jarak spasial-temporal (Sifriyani et al., 2022).

Selanjutnya bobot spasial-temporal dapat dihitung setelah menentukan jarak ruang-waktu. Setelah *bandwidth* spasial-temporal ditentukan, matriks $\mathbf{W}(u_i, v_i, t_i)$ dan Elemen diagonal w_{ij} dapat dihitung. Sebagai contoh diambil fungsi pembobot dari jarak Gaussian yang dijelaskan sebagai berikut (Wang, 2022).

$$w_{ij} = \exp\left(-\frac{(d_{ij}^{ST})^2}{(b_{ST})^2}\right) \quad (2.30)$$

Dimana (b_{ST}) adalah *bandwidth* spasial-temporal, sehingga dapat diekspresikan dengan menggabungkan jarak spasial-temporal Persamaan (2.29) ke fungsi jarak Gaussian Persamaan (2.30) sebagai berikut.

$$w_{ij} = \exp\left\{-\left(\frac{\lambda [(u_i - u_j)^2 + (v_i - v_j)^2] + \mu (t_i - t_j)^2}{(b_{ST})^2}\right)\right\} \quad (2.31)$$

Jika didefinisikan $(b_S) = \frac{(b_{ST})^2}{\lambda}$ dan $(b_T) = \frac{(b_{ST})^2}{\mu}$, maka

$$\begin{aligned} w_{ij} &= \exp\left\{-\left(\frac{\lambda [(u_i - u_j)^2 + (v_i - v_j)^2] + \mu (t_i - t_j)^2}{(b_S)^2} + \frac{\mu (t_i - t_j)^2}{(b_T)^2}\right)\right\} \\ &= \exp\left\{-\left(\frac{(d_{ij}^S)^2}{(b_S)^2} + \frac{(d_{ij}^T)^2}{(b_T)^2}\right)\right\} \\ &= \left\{\exp\left(-\frac{(d_{ij}^S)^2}{(b_S)^2}\right)\right\} \times \left\{\exp\left(-\frac{(d_{ij}^T)^2}{(b_T)^2}\right)\right\} \\ &= w_{ij}^S \times w_{ij}^T \end{aligned} \quad (2.32)$$

dengan

(b_{ST}) : *bandwidth* spasial-temporal

(b_S) : *bandwidth* spasial

(b_T) : *bandwidth* temporal

Dari Persamaan (2.29), jika variasi temporal tidak terjadi pada observasi, maka parameter μ dapat diatur ke 0 sehingga perhitungan jarak spasial-temporal sama dengan jarak euclidean. Namun jika variasi spasial tidak terjadi pada observasi, maka parameter λ yang diatur ke 0. Tetapi, baik μ maupun λ dalam praktiknya tidak sama dengan nol, dan heterogenitas spasial-temporal akan dipertimbangkan dalam jarak spasial-temporal di tiap titik observasi (Xie et al., 2022).

Kemudian akan dilakukan penyederhanaan pada Persamaan (2.29), misalkan $\tau = \frac{\mu}{\lambda}$; ($\lambda \neq 0$), sehingga persamaan menjadi:

$$\frac{(d_{ij}^{ST})^2}{\lambda} = [(u_i - u_j)^2 + (v_i - v_j)^2] + \tau (t_i - t_j)^2 \quad (2.33)$$

Misalkan $\lambda = 1$, tujuannya untuk mereduksi parameter yang tidak diketahui sehingga hanya terdapat satu parameter yang tidak diketahui, yaitu τ . Parameter τ berfungsi untuk memperbesar atau memperkecil efek jarak temporal terhadap jarak spasial. Parameter (b_{ST}) , (b_S) , τ , μ dan λ didapatkan dari kriteria *CV minimum* seperti pada Persamaan (2.19).

2.11. Pengujian Dugaan Model *Geographically and Temporally Weighted Regression* (GTWR)

Model GWR yang didapat selanjutnya dilakukan pengujian hipotesis. Ada dua uji dugaan yang dilakukan pada model GTWR yaitu uji kesesuaian model GTWR *Goodness of Fit* dan Uji Parsial model GTWR (Sartika, 2020).

2.11.1. Uji Kesesuaian Model GTWR *Goodness of Fit*

Uji Kesesuaian Model GTWR *Goodness of Fit* memiliki hipotesis sebagai berikut :

$H_0 : \beta_z(u_i, v_i, t_i) = \beta_z$ (tidak ada perbedaan signifikan pada regresi OLS dan GTWR)

$H_1 : \exists_z, \beta_z(u_i, v_i, t_i) \neq \beta_z$ (ada perbedaan signifikan antara regresi OLS dan GTWR)

dengan rumus statistik uji dilihat pada persamaan berikut :

$$F^* = \frac{\frac{SSE(\mathbf{H}_0)}{df_1}}{\frac{SSE(\mathbf{H}_1)}{df_2}} \quad (2.34)$$

dengan :

$$df_1 = \frac{\zeta_1^2}{\zeta_2} \text{ dengan } \zeta_i = \left(\text{tr} \left[(\mathbf{I} - \mathbf{S})^T (\mathbf{I} - \mathbf{S}) \right]^i \right); i = 1, 2$$

$$df_2 = m - t - 1$$

$$SSE(\mathbf{H}_0) = \mathbf{Y}^T (\mathbf{I} - \mathbf{H}) \mathbf{Y}$$

$$SSE(\mathbf{H}_1) = \mathbf{Y}^T (\mathbf{I} - \mathbf{S})^T (\mathbf{I} - \mathbf{S}) \mathbf{Y}$$

$$\mathbf{I} = \text{Matriks Identitas}$$

Dimana S merupakan suatu matriks berukuran $n \times n$ yang memproyeksikan y menjadi \hat{y} di lokasi (u_i, v_i, t_i) pada model GWR.

$$S = \begin{bmatrix} \mathbf{x}_1^T [\mathbf{X}^T \mathbf{W}(u_1, v_1, t_1) \mathbf{X}]^{-1} \mathbf{X}^T \mathbf{W}(u_1, v_1, t_1) \\ \mathbf{x}_2^T [\mathbf{X}^T \mathbf{W}(u_2, v_2, t_2) \mathbf{X}]^{-1} \mathbf{X}^T \mathbf{W}(u_2, v_2, t_2) \\ \vdots \\ \mathbf{x}_n^T [\mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{X}]^{-1} \mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \end{bmatrix}$$

kemudian untuk $SSE(\mathbf{H}_0)$ dijabarkan sebagai berikut.

$$SSE(\mathbf{H}_0) = \hat{\boldsymbol{\theta}}^T \hat{\boldsymbol{\theta}} = (\mathbf{Y} - \hat{\mathbf{Y}})^T (\mathbf{Y} - \hat{\mathbf{Y}})$$

karena $\hat{\mathbf{Y}} = \mathbf{X}\hat{\boldsymbol{\beta}} = \mathbf{X}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y} = \mathbf{H}\mathbf{Y}$

sehingga didapat :

$$\begin{aligned} SSE(\mathbf{H}_0) &= \hat{\boldsymbol{\theta}}^T \hat{\boldsymbol{\theta}} \\ &= (\mathbf{Y} - \mathbf{H}\mathbf{Y})^T (\mathbf{Y} - \mathbf{H}\mathbf{Y}) \\ &= \mathbf{Y}^T \mathbf{Y} - \mathbf{Y}^T \mathbf{H}\mathbf{Y} - \mathbf{Y}^T \mathbf{H}^T \mathbf{Y} + \mathbf{Y}^T \mathbf{H}^T \mathbf{H}\mathbf{Y} \\ &= \mathbf{Y}^T \mathbf{Y} - \mathbf{Y}^T \mathbf{H}\mathbf{Y} - \mathbf{Y}^T \mathbf{H}^T \mathbf{Y} + \mathbf{Y}^T \mathbf{H}^T \mathbf{H}\mathbf{Y} \\ &= \mathbf{Y}^T \mathbf{Y} - \mathbf{Y}^T \mathbf{H}\mathbf{Y} \\ &= \mathbf{Y}^T (1 - \mathbf{H}) \mathbf{Y} \end{aligned}$$

dan untuk $SSE(\mathbf{H}_1)$ dijabarkan sebagai berikut.

$$\begin{aligned} SSE(\mathbf{H}_1) &= \hat{\boldsymbol{\theta}}^T \hat{\boldsymbol{\theta}} \\ &= (\mathbf{Y} - \mathbf{SY})^T (\mathbf{Y} - \mathbf{SY}) \\ &= ((1 - \mathbf{S})\mathbf{Y})^T (1 - \mathbf{S})\mathbf{Y} \\ &= \mathbf{Y}^T (1 - \mathbf{S})^T (1 - \mathbf{S})\mathbf{Y} \end{aligned}$$

dengan $\mathbf{H} = \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T$ bersifat idempoten.

Jika tingkat signifikansi adalah α , maka dikatakan terdapat perbedaan antara model GTWR dan regresi global adalah saat $F^* > F_{\alpha; df_1, df_2}$ dengan keputusan tolak H_0 (Lutfiani et al., 2019).

2.11.2. Uji Parsial Model GTWR

Pengujian ini dilakukan secara parsial pada model GTWR untuk melihat parameter mana saja yang secara signifikan mempengaruhi variabel terikat (Ramadhan et al., 2022). Uji parsial pada model GWR memiliki hipotesis sebagai berikut:

$H_0 : \beta_z(u_i, v_i, t_i) = 0$ (tidak ada pengaruh variabel bebas terhadap Y)

$H_1 : \exists_z, \beta_z(u_i, v_i, t_i) \neq 0$ (ada pengaruh variabel bebas terhadap Y)

dengan rumus statistik uji di bawah ini :

$$t^* = \frac{\hat{\beta}_z(u_i, v_i, t_i)}{\hat{\sigma} \sqrt{c_{zz}}} \quad (2.35)$$

dimana :

$$\begin{aligned}
 c_{zz} &= \text{elemen diagonal matriks } CC^T \sigma^2; C = (\mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W}(u_i, v_i, t_i) \\
 df &= \frac{\zeta_1^2}{\zeta_2} \\
 \hat{\sigma} &= \frac{SSE(\mathbf{H}_1)}{\zeta_1^2} = \frac{\mathbf{Y}^T (\mathbf{I} - \mathbf{S}^*)^T (\mathbf{I} - \mathbf{S}^*) \mathbf{Y}}{(\text{tr}[(\mathbf{I} - \mathbf{S}^*)^T (\mathbf{I} - \mathbf{S}^*)])}
 \end{aligned}$$

Distribusi t^* mengikuti distribusi t berderajat df , daerah keputusan adalah tolak H_0 jika nilai dari $|t^*| > t_{\frac{\alpha}{2}, df}$ atau saat $p\text{-value} < \alpha$ (Yasin et al., 2022).

2.12. Kriteria Pemilihan Model Terbaik

Model dikatakan baik saat memiliki galat perhitungan atau error yang seminimum mungkin sehingga dapat menggambarkan keadaan yang sebenarnya. Beberapa metode yang dapat digunakan untuk menghitung dan mengetahui error dari proses analisis, diantaranya sebagai berikut:

2.12.1. Akaike Information Criterion (AIC)

Dikemukakan oleh Akaike tahun 1973, metode AIC menjadi salah satu metode terbaik yang digunakan dalam memilih model regresi. Metode ini didasarkan pada MLE (*Maximum Likelihood Estimation*), perhitungan dilakukan dengan rumus berikut (Hong et al., 2021).

$$AIC = 2n \ln(\hat{\sigma}) + n \ln(2\pi) + n \frac{n + \text{tr}(\mathbf{S})}{n - 2 - \text{tr}(\mathbf{S})} \quad (2.36)$$

Keterangan :

$$S = \mathbf{X} (\mathbf{X}^T \mathbf{W} (u_i, v_i) \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W} (u_i, v_i)$$

n = Jumlah sampel

$\hat{\sigma}$ = nilai estimasi standar deviasi dari residual

2.12.2. Koefisien Determinasi R^2

Pemilihan model terbaik dapat dilihat dari nilai R^2 yang didapat. Pada Model GTWR persamaan R^2 sebagai berikut :

$$R^2 = 1 - \frac{SSE}{SST} \quad (2.37)$$

Keterangan :

SSE = *Sum of Square Error* Dalam perbandingan model, semakin kecil

SST = *Sum of Square Total*

nilai AIC, semakin baik model tersebut. Model dengan nilai AIC terendah dianggap sebagai model yang paling cocok untuk data.

Nilai dari koefisien determinasi dapat menggambarkan tingkat variasi yang dari data amatan pada model yang diperoleh. Nilai R^2 yang rendah menandakan variabel bebas yang digunakan tidak cukup baik dalam memberikan informasi dari variabel terikat, sebaliknya jika nilai dari R^2 mendekati 1 berarti variabel bebas secara bersama-sama memiliki kemampuan dalam menjelaskan variabel terikat (Zhang et al., 2021; Lutfiani et al., 2019).

2.13. Menjaga Lingkungan dilihat dari sisi Keislaman

Indonesia sebagai salah satu negara dengan penduduk yang menganut agama Islam terbesar di dunia sangat menjunjung tinggi keselarasan antara manusia dengan lingkungan. Fungsi hutan sangat penting adalah menjadi tempat bernaung hidup berbagai biota serta sebagai stabilisator global khususnya dalam kestabilan emisi gas di udara yang bilamana tidak seimbang dapat menyebabkan global warming, bencana alam seperti longsor, menurunnya kualitas air, perubahan iklim yang tidak menentu (Ridho et al., 2022). Al-Qur'an sebagai hukum utama menjelaskan dalam QS. Hud ayat 61 bahwa Allah menjadikan manusia sebagai makhluk yang memakmurkan bumi.

﴿ وَالِى ثَمُودَ أَخَاهُمْ صَالِحًا قَالَ يَاقَوْمِ اعْبُدُوا اللَّهَ مَا لَكُم مِّنْ إِلَهِ غَيْرُهُ هُوَ أَنشَأَكُم مِّنَ الْأَرْضِ وَاسْتَعْمَرَكُمْ فِيهَا فَاسْتَغْفِرُوا لَهُ ثُمَّ تَوْبُوا إِلَيْهِ إِنَّ رَبِّي قَرِيبٌ مُّجِيبٌ ﴿٦١﴾

Artinya : *Kepada (kaum) Samud (Kami utus) saudara mereka, Saleh. Dia berkata, “Wahai kaumku, sembahlah Allah! Sekali-kali tidak ada tuhan bagimu selain Dia. Dia telah menciptakanmu dari bumi (tanah) dan menjadikanmu pemakmurnya.357) Oleh karena itu, mohonlah ampunan kepada-Nya, kemudian bertobatlah kepada-Nya. Sesungguhnya Tuhanku sangat dekat lagi Maha Memperkenankan (doa hamba-Nya).” (Q.S Hud (11) : 61)*

Makna yang dapat diingat bahwa keberlangsungan ekologi di bumi adalah tanggung jawab manusia. Sebagai seorang yang diamanahkan suatu tanggung jawab sebagai pemakmur dari bumi senantiasa seharusnya menjaga lingkungan dengan sebenar-benarnya, namun kenyataannya walau sudah diberitahukan

kewajiban dan dampak dari lalainya tidak melaksanakan kewajiban tersebut manusia tetap tidak bertindak dengan semestinya (Shihab, 2007).

Salah satunya adalah pengolahan hingga eksploitasi yang berlebihan sebagai dalih pemenuhan ekonomi dengan melakukan pemindahan fungsi utama hutan tanpa melakukan restorasi kembali sehingga dampaknya terjadilah deforestasi. Masalah deforestasi merupakan *feedback* dalam kategori tidak baik yang diberikan lingkungan terhadap tindakan dari manusia yang mana hal ini benar-benar sesuai dengan apa yang telah Allah cantumkan dalam Al-Qur'an surah Ar-Rum ayat 41 bahwa kerusakan yang ada di darat dan laut merupakan akibat ulah tangan manusia (Bilhaq, 2022).

Kerusakan lingkungan hingga menyebabkan deforestasi hendaknya segera dilakukan penanganan dimana salah satunya adalah dengan menanam pohon, hal ini sesuai dengan hadis yang dikutip dari hadits Hisyam bin Yazid dari Anas ra. (Mangka et al., 2022).

عَنْ أَنَسٍ أَنَّ رَسُولَ اللَّهِ صَلَّى اللَّهُ عَلَيْهِ وَسَلَّمَ يَقُولُ مَا مِنْ مُسْلِمٍ يَغْرِسُ غَرْسًا أَوْ
يَزْرَعُ زَرْعًا فَيَأْكُلُ مِنْهُ طَيْرٌ أَوْ إِنْسَانٌ إِلَّا كَانَ لَهُ صَدَقَةٌ

(رواه البخاري رقم 2320, ومسلم رقم 1553)

Artinya : “*Dari sahabat Anas ra, Rasulullah Saw bersabda, ‘Tiada seorang muslim yang menanam pohon atau menebar bibit tanaman, lalu (hasilnya) dimakan oleh burung atau manusia, melainkan ia akan bernilai sedekah bagi penanamnya.’*” (HR Bukhari No. 2320, Muslim No. 1553)

Berdasarkan hadis di atas bahwa Nabi mengarahkan meskipun terjadi kiamat, tetaplah melakukan kebaikan yaitu menanam pohon. Hal ini menunjukkan

bahwa meskipun kasus kerusakan lingkungan begitu besar dan sulit diatasi namun dapat dilakukan langkah kecil dengan melakukan tindakan yang membawa dampak besar seperti menanam pohon, maka dari itu perlunya upaya holistik dari berbagai pihak agar kerusakan lingkungan akibat tangan tidak bertanggung jawab dapat batasi hingga dicegah (An-Nabhani, Syaikh; Abdul Rouf, 2014). Pun terlihat pada kaidah fiqh berikut :

دَرَّةُ الْمَفَاسِدِ مُقَدَّمَةٌ عَلَى جَلْبِ الْمَصَالِحِ

Artinya : *"Menolak Kerusakan harus didahulukan daripada mendatangkan kemashlahatan"*

Dari kaidah di atas dapat diambil pemahaman bahwa diperlukan pertimbangan yang matang dalam bertindak sehingga hasil yang diberikan tidak memberikan dampak yang buruk kedepannya. Firman Allah dalam surah al-maidah ayat 33 tentang orang yang dengan sengaja melakukan suatu tindakan merusak lingkungan dimana dalam tindakan tersebut yang terdapat hanyalah *kemudahratan* maka berat hukumannya.

إِنَّمَا جَزَاءُ الَّذِينَ يُحَارِبُونَ اللَّهَ وَرَسُولَهُ وَيَسْعَوْنَ فِي الْأَرْضِ فَسَادًا أَنْ يُقَتَّلُوا أَوْ يُصَلَّبُوا
أَوْ تُقَطَّعَ أَيْدِيهِمْ وَأَرْجُلُهُمْ مِنْ خِلَافٍ أَوْ يُنْفَخُوا مِنَ الْأَرْضِ ذَلِكَ لَهُمْ خِزْيٌ فِي الدُّنْيَا
وَلَهُمْ فِي الْآخِرَةِ عَذَابٌ عَظِيمٌ ﴿٣٣﴾

Artinya : *"Balasan bagi orang-orang yang memerangi Allah dan rasul-Nya serta membuat kerusakan di bumi hanyalah dibunuh, disalib, dipotong tangan dan kaki mereka secara silang, atau diasingkan dari tempat kediamannya. Yang demikian itu merupakan kehinaan bagi mereka di dunia dan di akhirat (kelak) mereka mendapat azab yang sangat berat"* (Q.S Al-Ma'idah (5) : 33)

Ayat di atas dengan jelas bukan hanya perumpamaan tetapi penegasan sebagai sebuah ancaman yang akan diterima oleh manusia yang melakukan suatu perbuatan pengrusakan sesuatu di muka bumi, salah satunya adalah pengrusakan terhadap kelestarian lingkungan yang mempunyai nilai kemaslahatan yang tinggi bagi bumi dan isinya. Dengan demikian menjaga lingkungan salah satunya hutan dengan tidak melakukan tindakan eksploitasi yang berlebihan terlebih sebagai pemuas kepentingan pribadi yang berdampak buruk merupakan hal yang bertentangan dengan hukum islam, yaitu Al-Qur'an dan sunnah (Rahmi et al., 2022).

Pentingnya bagi manusia memiliki kesadaran eksistensial bahwa manusia dan semua makhluk di bumi adalah sesama makhluk yang Allah ciptakan yang saling bergantung satu sama lainnya. Bilamana keegoisan manusia dengan menganggap dirinya paling istimewa maka akan berdampak runtuhnya sistem. Sebagai contoh sistem yang tidak baik adalah kasus deforestasi akibat kerusakan hutan. Dengan ini sepatunya manusia berhenti melakukan tindakan berlebihan tanpa solusi terhadap hutan sehingga menyebabkan deforestasi. Islam merupakan *rahmatan lil 'alamin* yaitu rahmat bagi alam semesta termasuk kepada hutan.

UIN SUNAN AMPEL
S U R A B A Y A

BAB III

METODE PENELITIAN

3.1. Jenis Penelitian

Penelitian berfokus pada pengolahan data yang mempertimbangkan adanya efek geografis (spasial) serta efek waktu (temporal) sehingga masuk dalam jenis penelitian kuantitatif. Penelitian kuantitatif diterapkan dalam penelitian untuk meninjau, menganalisis, dan menginterpretasikan suatu sampel dengan tujuan menguji hipotesis yang telah ditetapkan (Kamaliah, 2022). Metode yang diterapkan pada penelitian ini sebagai metode analisis dalam memodelkan kasus deforestasi di Indonesia adalah *Geographically-Temporally Weighted Regression* (GTWR).

3.2. Sumber Data dan Variabel Penelitian

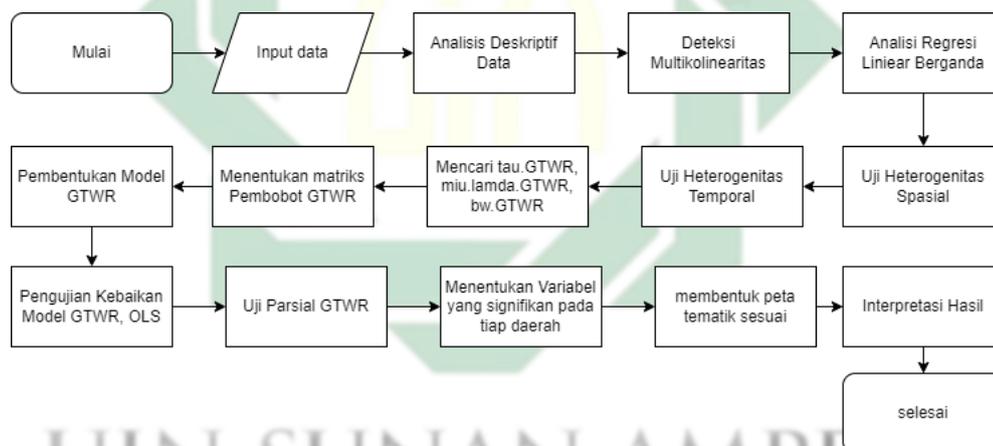
Analisis GTWR dalam penelitian menggunakan data sekunder dari kasus deforestasi Indonesia tahun 2017 hingga 2020, yang mana data diperoleh dari laman resmi BPS Indonesia www.bps.go.id/. Variabel yang dijadikan sebagai dugaan dari faktor penyebab kasus deforestasi di Indonesia sekaligus sebagai variabel dalam penelitian sebagai berikut:

Tabel 3.1 Variabel-variabel penelitian

No.	Nama Variabel	Sumber Data	Skala Pengukuran
Y	Deforestasi (ha)	BPS	Rasio
X_1	Luas Perkebunan Kelapa Sawit (Ha)	BPS	Rasio
X_2	PDRB Pertambangan (Miliar Rupiah)	Publikasi BPS "Produk Domestik Regional Bruto Provinsi-Provinsi Di Indonesia"	Rasio
X_3	Luas Hutan (Ha)	BPS	Rasio
X_4	Jumlah Produksi Kayu Bulat (m^3)	BPS	Rasio
X_5	Jumlah Populasi/Penduduk (jiwa)	BPS	Rasio
X_6	Luas Perkebunan Kopi (Ha)	BPS	Rasio
X_7	Persentase Penduduk Miskin (%)	BPS	Rasio
u	Latitude	BPS	Koordinat
v	Longitude	BPS	Koordinat

3.3. Tahapan Penelitian

Alur penelitian secara umum ditampilkan dalam diagram **Gambar (3.1)** berikut ini.

**Gambar 3.1 Alur Penelitian GTWR**

Langkah-langkah analisis GTWR yang dapat dilakukan sebagai berikut :

1. Eksplorasi sebaran variabel Y dan variabel X menggunakan analisis deskriptif tahun 2017-2020.
2. Melakukan pengujian asumsi multikolinieritas dengan mempertimbangkan nilai VIF (*Variance Inflation Factor*) menggunakan Persamaan (2.9).
3. Melakukan analisis Regresi Linear Berganda kemudian dilakukan uji

simultan dan uji parsial model Regresi Linear menggunakan Persamaan (2.7) dan Persamaan (2.8), dilanjutkan dengan pengujian asumsi klasik residual yaitu uji identik (Heteroskedestisitas), uji independen (Autokorelasi) dan uji normalitas residual menggunakan Persamaan (2.11), Persamaan (2.12) Persamaan (2.13).

4. Menguji keragaman spasial dengan uji *Breusch-Pagan* menggunakan Persamaan (2.14).
5. Menguji keragaman temporal dengan melihat *Box-Plot*.
6. Membangun matriks pembobot (W) metode GTWR sebagai berikut:
 - (a) Menghitung lebar jendela optimum spasial-temporal (b_{ST}), (τ), λ dan μ menggunakan CV minimum menggunakan Persamaan (2.19) dengan interval dibatasi oleh *upper* dan *lower*, dimana *upper* dihitung sebagai jarak euclidean antara batas-batas koordinat spasial, Kemudian, *lower* dihitung dengan membagi *upper* dengan 5000.
 - (b) Menentukan jarak spasial-temporal d_{ij}^{ST} menggunakan Persamaan (2.29).
 - (c) Menentukan matriks pembobot (w_{ij}) menggunakan ukuran jarak spasial-temporal dengan interaksi untuk setiap lokasi pengamatan berdasarkan kernel *Fixed Gaussian* dan *Fixed Bisquare* menggunakan Persamaan (2.20), Persamaan (2.21).
7. Melakukan estimasi model GWTR menggunakan Persamaan (2.26).
8. Melakukan uji *Goodness Of Fit* pada model menggunakan Persamaan (2.34).
9. Melakukan uji parsial pada model menggunakan Persamaan (2.35).

10. Membandingkan kebaikan dari beberapa model yaitu Regresi linear berganda, GTWR berdasarkan nilai AIC, R^2 berdasarkan Persamaan (2.36) dan Persamaan (2.37).
11. Pembuatan peta tematik berdasarkan variabel berpengaruh signifikan terhadap model.



UIN SUNAN AMPEL
S U R A B A Y A

BAB IV

HASIL DAN PEMBAHASAN

Pada bagian ini, terdapat penjelasan dan pengkajian mengenai karakteristik dan analisis deforestasi Indonesia sebagai variabel terikat, yang dipengaruhi oleh faktor-faktor seperti luas hutan, luas perkebunan kelapa sawit, jumlah produksi kayu bulat, jumlah penduduk miskin, PDRB Pertambangan, jumlah perkebunan kopi, jumlah populasi/penduduk. Dalam penelitian ini, terdapat dua tahap pemodelan yang digunakan, yaitu metode regresi linier berganda dan metode *Geographically and Temporally Weighted Regression* (GTWR). Pengumpulan data untuk analisis regresi linier berganda dan GTWR menggunakan data tahunan dari 2017-2020 mengenai deforestasi di Indonesia.

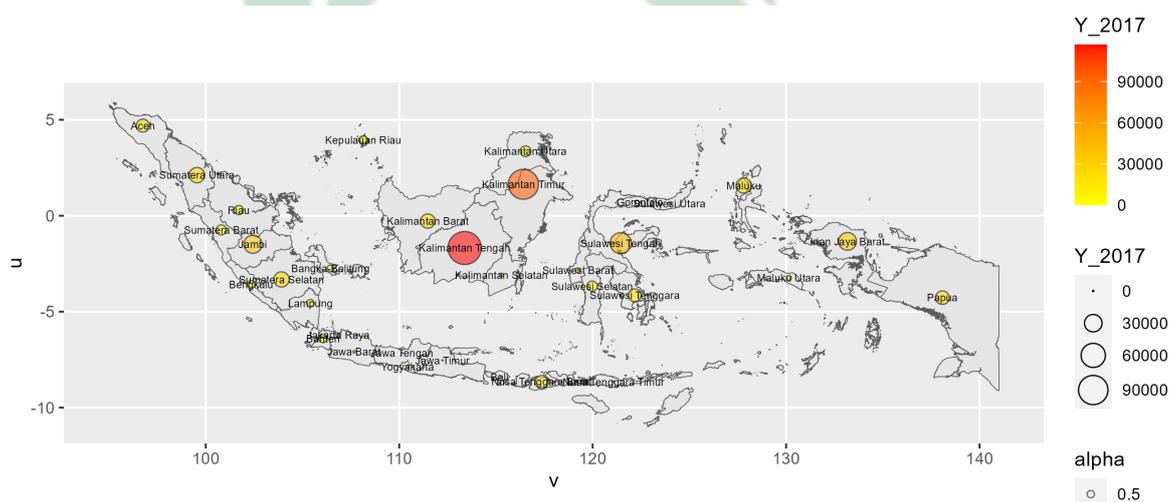
4.1. Analisis Deskriptif Variabel Penelitian

Sebelum melakukan tahap pemodelan, akan dilakukan analisis deskriptif terhadap variabel-variabel penelitian untuk mengetahui gambaran umum dari variabel-variabel penelitian yang digunakan dalam analisis.

Tabel 4.1 Nilai Rataan, Standar Deviasi, Min dan Max Data Deforestasi Indonesia tahun 2017-2020

Variabel	Rata-rata	Standar Deviasi	Min	Max
Deforestasi 2017	15658.2	25604.6	0	116782.8
Deforestasi 2018	14959.1	20734.7	0	78787.4
Deforestasi 2019	15615.7	29152.8	0	142011.1
Deforestasi 2020	3825.7	4443.7	0	16334.5

Berasarkan **Tabel (4.1)** kasus deforestasi tahun 2017 dapat dilihat pada gambar dibawah ini.

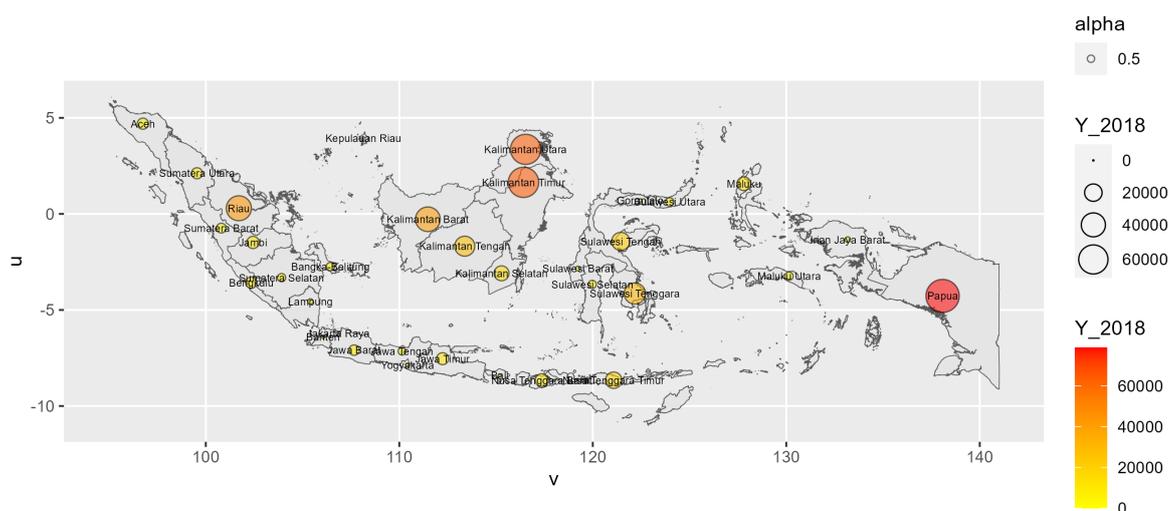


Gambar 4.1 Deforestasi Indonesia 2017

Pada tahun 2017, rata-rata deforestasi mencapai 15658.22 Ha dengan standar deviasi 25604.6 dan nilai tertinggi deforestasi 116782.8. Pada **Gambar (4.1)** diatas terlihat terdapatnya variasi yang signifikan dalam tingkat deforestasi di berbagai daerah di Indonesia pada tahun 2017. Daerah dengan tingkat deforestasi tertinggi adalah Kalimantan Tengah dengan nilai sebesar 116782.8 hektar, diikuti oleh Kalimantan Timur dengan nilai deforestasi sebesar 94981.8 hektar. Kalimantan Utara juga memiliki tingkat deforestasi yang cukup tinggi, mencapai 9908.49 hektar.

Beberapa daerah di Jawa juga mengalami deforestasi, meskipun dengan nilai yang lebih rendah. Jawa Barat memiliki tingkat deforestasi sebesar 188 hektar, sementara Jawa Tengah dan Jawa Timur tidak memiliki laporan deforestasi pada tahun tersebut. Sementara itu, di luar pulau Jawa dan Kalimantan, daerah-daerah seperti Papua, Sulawesi Tengah, dan Sumatera Utara juga mengalami tingkat deforestasi yang signifikan. Papua memiliki deforestasi sebesar 17259.1 hektar, Sulawesi Tengah mencapai 44523.9 hektar, dan Sumatera Utara mencapai 22549.6 hektar.

Selanjutnya untuk kasus deforestasi tahun 2018 dapat dilihat pula pada **Gambar (4.2)**.



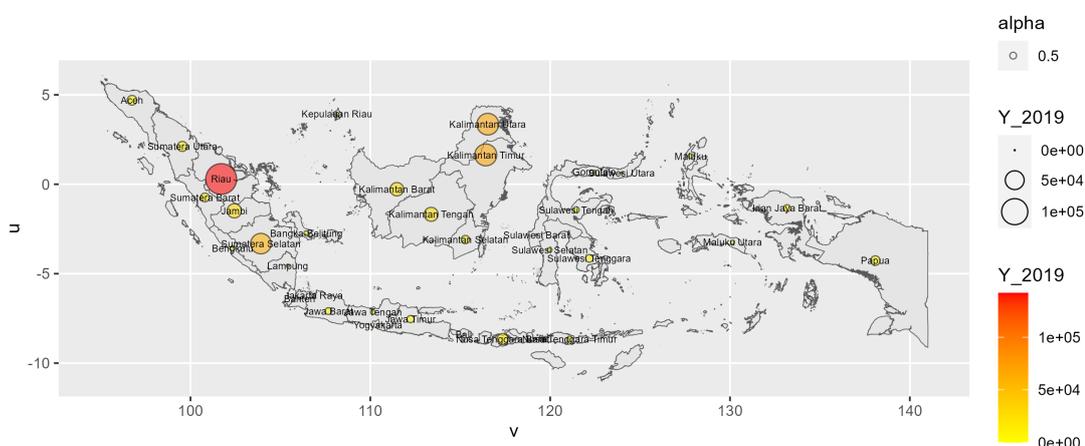
Gambar 4.2 Deforestasi Indonesia 2018

Di tahun 2018, rata-rata deforestasi mencapai 14959.1 Ha dengan standar deviasi 20734.7 dan nilai tertinggi deforestasi 78787.4. Berdasarkan **Gambar (4.2)**, terdapat perbedaan signifikan dalam tingkat deforestasi antara daerah-daerah yang diamati.

Pada tahun 2018, Papua melaporkan tingkat deforestasi tertinggi sebesar 78787.40 hektar, Kalimantan Timur sebesar 65194.20 hektar, diikuti oleh

Kalimantan Utara dengan 64900.00 hektar. Sementara itu, beberapa wilayah di Sumatera juga mengalami tingkat deforestasi yang signifikan meliputi Riau dengan 43714.80 hektar, kemudian ada Sulawesi Tenggara dengan 30834.00 hektar, dan Kalimantan Barat dengan 42291.40 hektar.

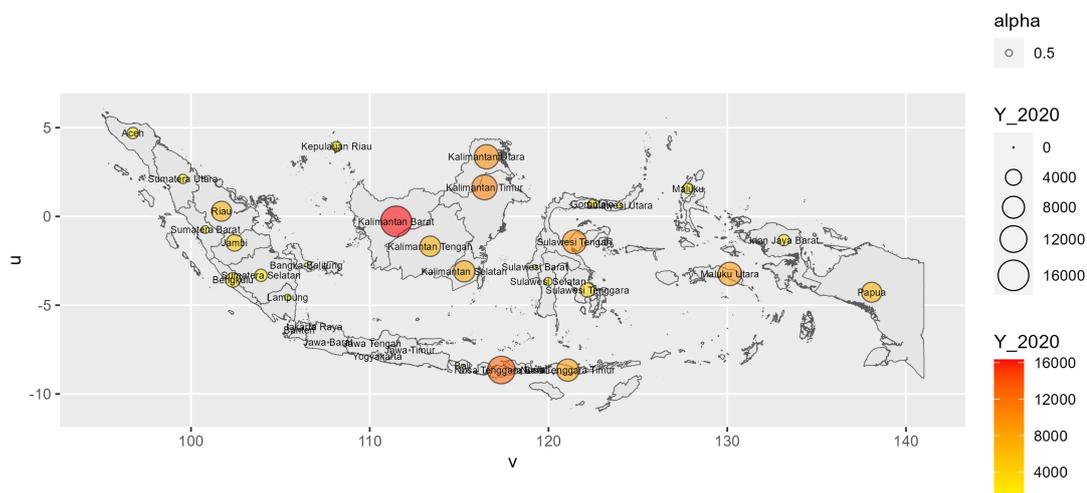
Kemudian pada tahun 2019, kasus deforestasi Indonesia ditampilkan pada gambar di bawah ini.



Gambar 4.3 Deforestasi Indonesia 2019

Pada tahun 2019, rata-rata deforestasi mencapai 15615.7 Ha dengan standar deviasi 29152.8 dan nilai tertinggi deforestasi 142011.1. Pada **Gambar (4.3)** menggambarkan bahwa tingkat deforestasi yang signifikan terjadi di beberapa wilayah, seperti Riau dengan deforestasi sebesar 142011.1 hektar, Kalimantan Timur dengan deforestasi sebesar 69584.6 hektar, dan Kalimantan Utara dengan deforestasi sebesar 68021 hektar.

Selanjutnya pada tahun 2020, kasus deforestasi Indonesia dapat dilihat dari peta sebaran berikut ini.



Gambar 4.4 Deforestasi Indonesia 2020

Kemudian tahun 2020, rata-rata deforestasi mengalami penurunan menjadi 3825.7 Ha dengan standar deviasi 4443.7 dan nilai tertinggi deforestasi 16334.5. Melihat **Gambar (4.4)** pada pulau kalimantan, provinsi tertinggi dengan kasus deforestasi adalah Kalimantan Barat, diikuti oleh Kalimantan Utara dan Kalimantan Timur. kemudian diluar pulau kalimantan, ada provinsi Nusa Tenggara Barat dan Sulawesi tengah juga mengalami kasus deforestasi yang tinggi.

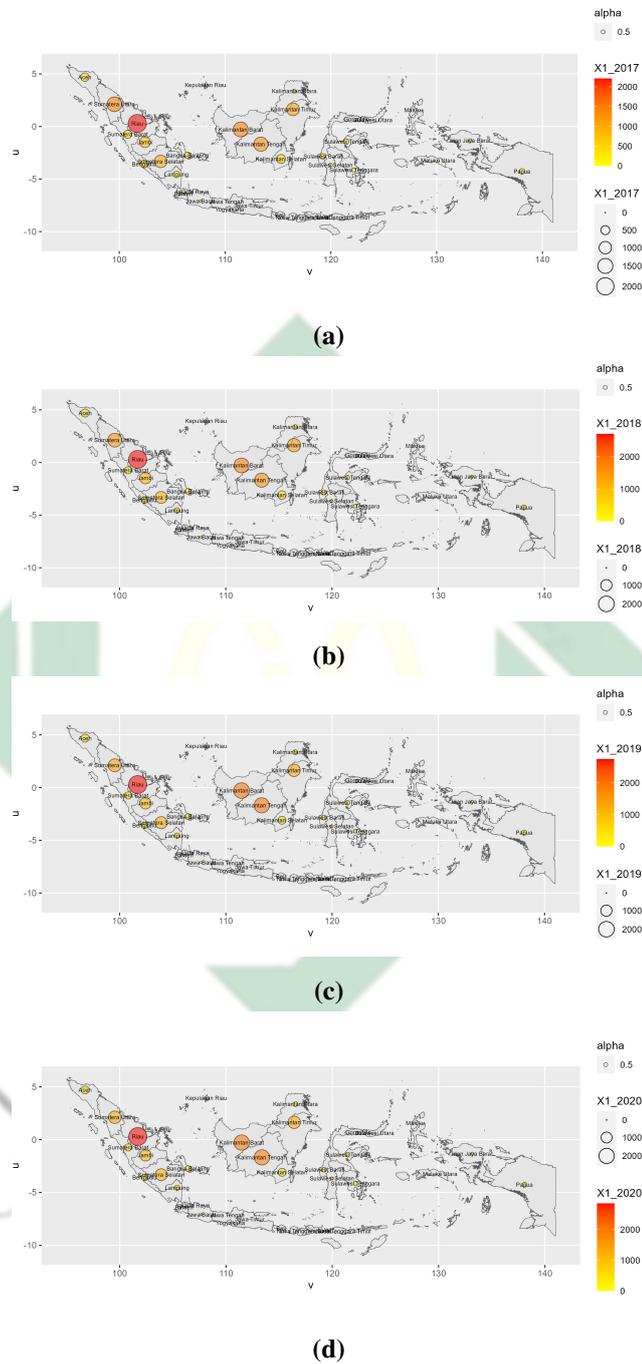
Tabel 4.2 Analisis Deskriptif Variabel Bebas Penelitian tahun 2017-2020

Variabel	X_1	X_2	X_3	X_4	X_5	X_6	X_7
Mean	411.94	29163.72	3752601.39	1717653.27	7809.06	36.61	10.84
SD	657.30	50311.13	5614791.50	3958083.34	10996.86	55.13	5.669
Min	0	400	475.45	0	670	0	3.47
Max	2853.8	297029	29368482	23286290.64	49565.2	251	27.74

Keterangan

X_1 : Luas Perkebunan Kelapa Sawit X_2 : PDRB Pertambangan X_3 : Luas Hutan
 X_4 : Jumlah Produksi Kayu Bulat X_5 : Jumlah Penduduk X_6 : Luas Perkebunan Kopi
 X_7 : Persentase Penduduk Miskin

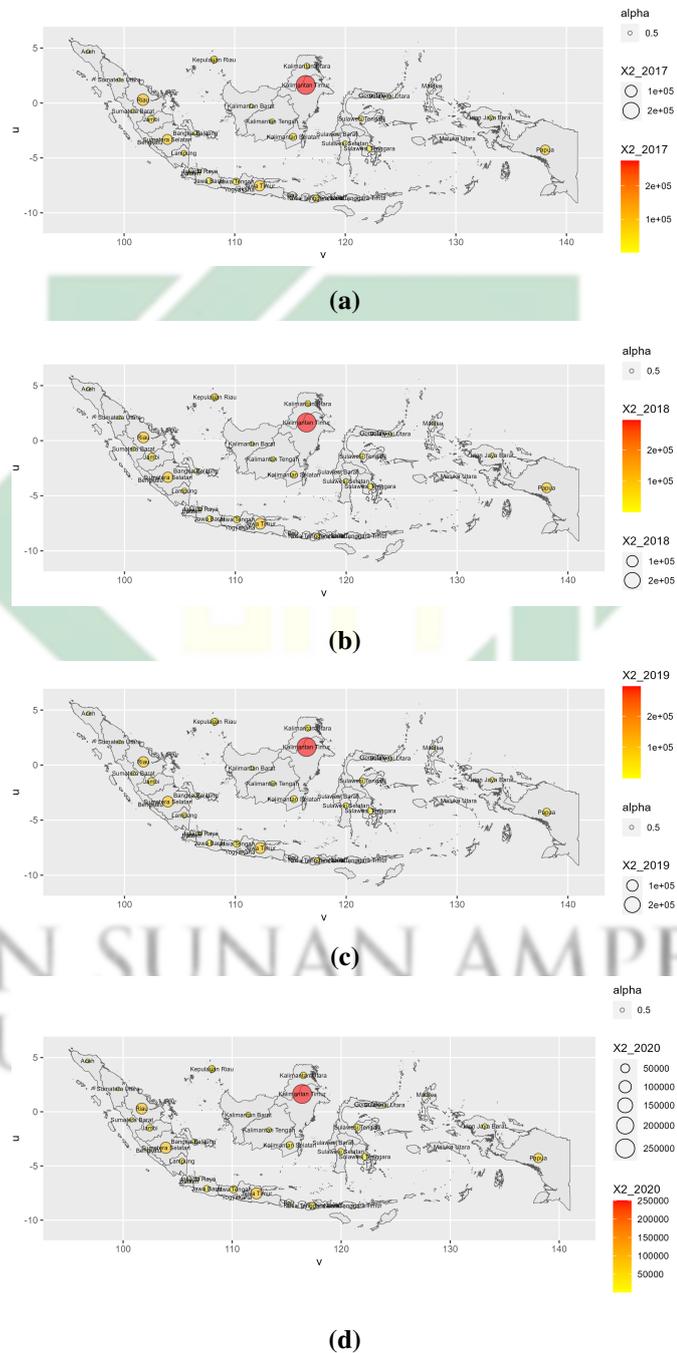
Berdasarkan **Tabel (4.2)** analisis sejalan dengan gambar dibawah ini.



Gambar 4.5 Sebaran Luas Persebunan Kelapa Sawit 2017-2020

Pada **Tabel (4.2)** dan **Gambar (4.5)**, dapat diketahui tahun 2017-2020 rata-rata luas perkebunan kelapa sawit dengan di Indonesia sebesar 411.94 Ha dengan nilai maksimum 2853.8 Ha dan standar deviasi 657.30. Selama empat

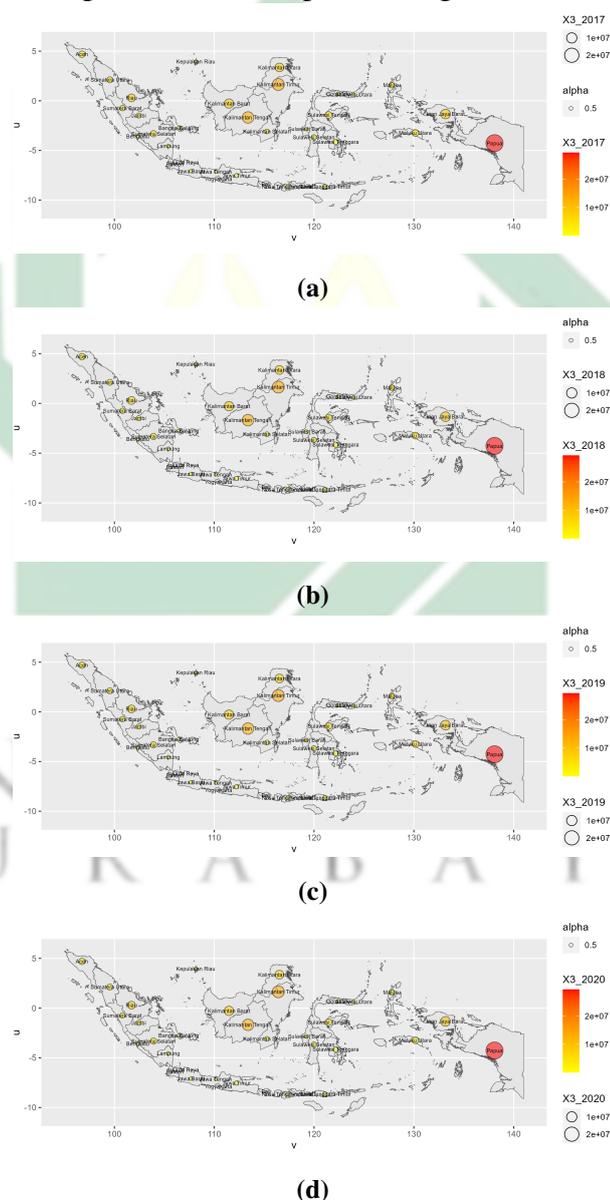
tahun berturut-turut mulai dari 2017 hingga 2020, provinsi Riau menduduki peringkat pertama dalam hal luas perkebunan kelapa sawit, diikuti oleh Kalimantan Barat, Kalimantan Tengah, Kalimantan Timur, dan Sumatra Utara.



Gambar 4.6 Sebaran PDRB Pertambahan 2017-2020

Selanjutnya dari **Gambar (4.6)**, pada tahun 2017-2020 PDRB sektor

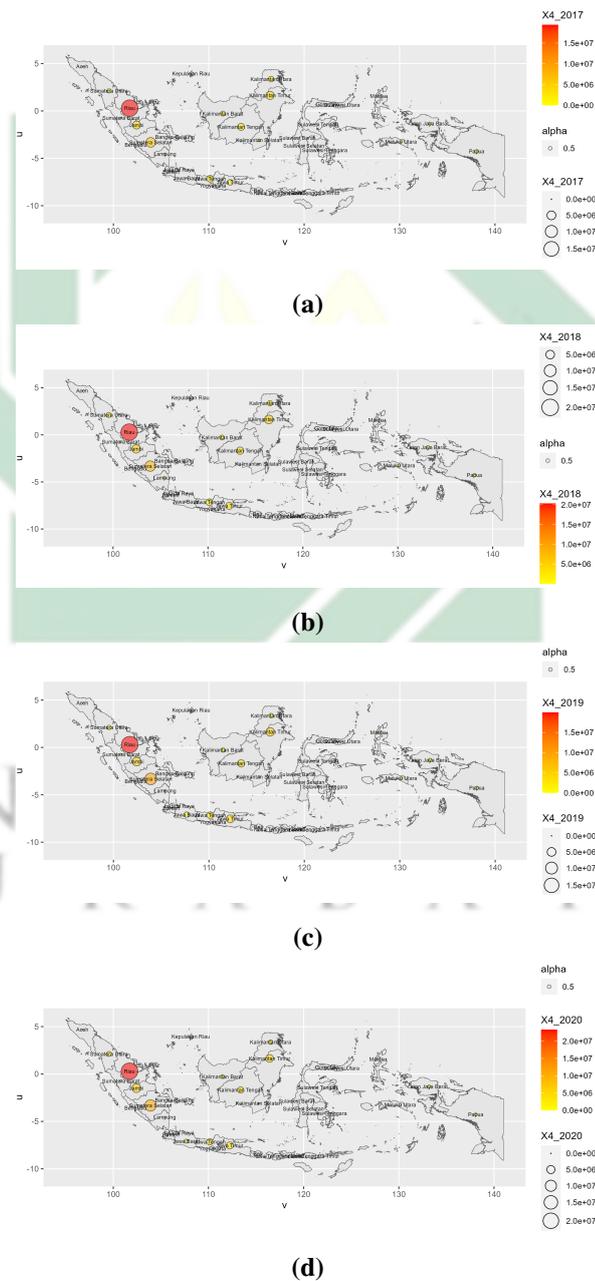
pertambangan memiliki rata-rata 29163.72 miliar dengan nilai minimum 400 miliar dan maksimum 297029 miliar, kemudian standar deviasi sebesar 50311.13. Selama kurun waktu 2017-2020 provinsi Gorontalo menempati posisi terendah pada PDRB sektor pertambangan dan provinsi Kalimantan Timur tahun 2017-2020 menunjukkan kontribusi yang signifikan dari sektor pertambangan. Tahun 2019 Kalimantan Timur menghasilkan PDRB pertambangan sebesar 297029 miliar.



Gambar 4.7 Sebaran Luas Hutan 2017-2020

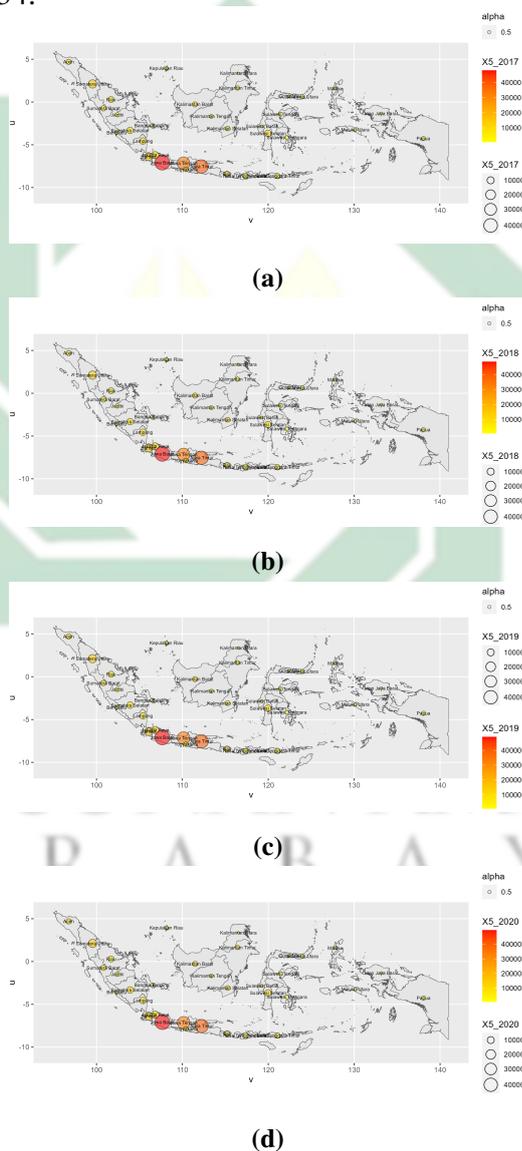
Dapat terlihat pada **Gambar (4.7)** luas hutan minimum tercatat sebesar

475,45 hektar yaitu provinsi Jakarta, kemudian nilai maksimum tercatat sebesar 29368482 hektar yaitu provinsi Papua, dengan rata-rata luas hutan Indonesia 3752601.39. Di sisi lain, provinsi-provinsi seperti Kalimantan Timur, Kalimantan Tengah, dan Sumatera Selatan juga memiliki luas hutan yang signifikan, dengan masing-masing mencapai 13831912.65 hektar, 12697165 hektar, dan 3407693 hektar.



Gambar 4.8 Sebaran *Produksi Kayu Bulat 2017-2020*

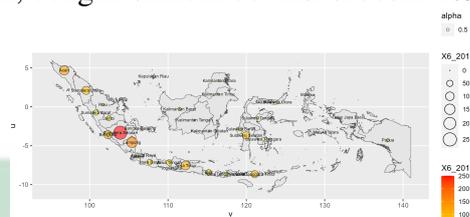
Dalam rentang tahun 2017 hingga 2020, **Gambar (4.8)** menampilkan sebaran produksi kayu bulat di Indonesia mengalami variasi yang signifikan. Provinsi dengan produksi tertinggi selama 2017-2020 adalah Riau dengan jumlah produksi kayu bulat tahun 2020 mencapai 23286290.64 meter kubik. Rata-rata produksi sebesar 1644123.865 ribuan meter kubik dengan standar deviasi yang dihasilkan 3958083.34.



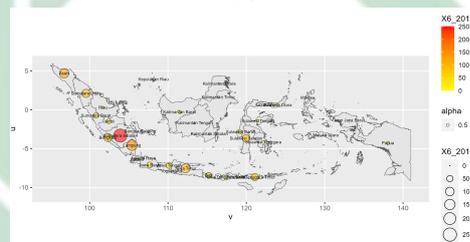
Gambar 4.9 Sebaran Jumlah Penduduk 2017-2020

Dalam **Gambar (4.9)**, rentang jumlah penduduk provinsi di Indonesia berkisar antara 670 hingga 49565.2 ribu jiwa. Provinsi Kalimantan Utara terendah

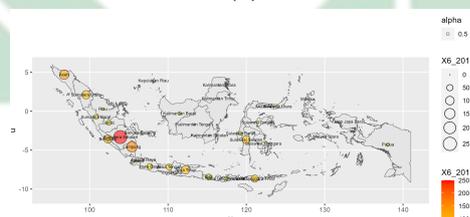
dari tahun 2017 hingga 2020 dengan jumlah penduduk sekitar 670 hingga 708.4 ribu jiwa dan provinsi dengan jumlah populasi tertinggi adalah Jawa Barat, dimulai dari tahun 2017 dengan jumlah sekitar 47922.8 ribu jiwa dan terus meningkat setiap tahunnya. Rata-rata jumlah penduduk dari tahun 2017 hingga 2020 adalah sekitar 7809.1 ribu jiwa, dengan standar deviasi sebesar 10996.86.



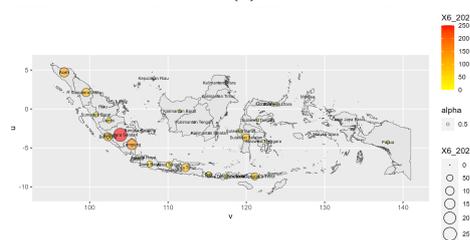
(a)



(b)



(c)

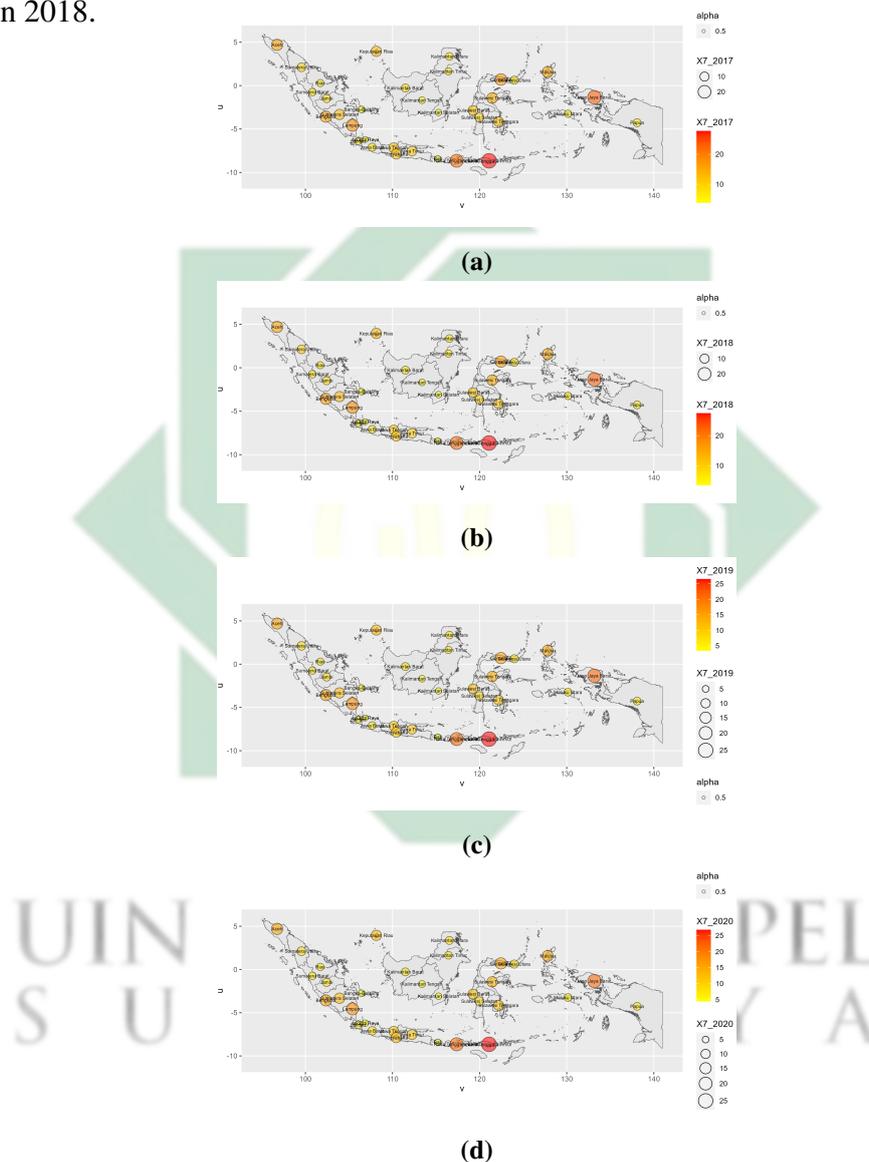


(d)

Gambar 4.10 Sebaran Luas Perkebunan Kopi 2017-2020

Rata-rata luas perkebunan kopi provinsi di Indonesia tahun 2017-2020 sebesar 36.61 ribu Ha dengan standar deviasi 55.13 dan luas tertinggi sebesar 251

ribu ha. Melihat **Gambar (4.10)** tahun 2017 hingga 2020, perkebunan kopi didominasi oleh pulau Sumatera, dimana Sumatera Selatan mencatatkan diri sebagai daerah dengan perkebunan kopi tertinggi, mencapai 251 ribu ha pada tahun 2018.



Gambar 4.11 Sebaran Presentase Penduduk Miskin 2017-2020

Diamati **Gambar (4.11)** bahwa persentase penduduk miskin berkisar antara 3.42% hingga 27.74%, dengan median sebesar 8.965% dan rata-rata sebesar 5.669%. Data ini mencerminkan tingkat kemiskinan yang berbeda-beda di berbagai wilayah tersebut Tahun 2017 hingga 2020, provinsi dengan persentase

penduduk miskin terendah adalah Jakarta hanya 3.77%, 3.57%, 3.47%, 4.69%, sedangkan provinsi dengan persentase penduduk miskin tertinggi dari tahun 2017 sampai 2020 adalah Papua yang mencapai angka persentase 27.62%, 27.74%, 27.53%, 26.8%.

4.2. Standarisasi Data (Z-Score)

Data penelitian dilakukan standarisasi sebelum masuk pada tahap analisis guna menyamakan skala pada data. Berikut data yang telah di standarisasi *Z-score*.

Tabel 4.3 Data Standarisasi Z-Score

No	Y	X ₁	X ₂	X ₃	X ₄	X ₅	X ₆	X ₇
1	0.133761432	0.043140847	-0.445104769	-0.033623403	-0.431127824	-0.240037493	1.579582203	1.066143175
2	-0.547364109	-0.626717421	-0.537748269	-0.645674979	-0.428618826	-0.323097493	-0.025673962	-1.163443768
3	-0.415988424	-0.259154947	-0.417039414	-0.553713596	-0.429716651	-0.58165289	-0.662334882	-0.995871965
4	-0.323261036	-0.596594337	-0.497260218	-0.632403606	-0.375459693	0.412475468	-0.553503956	-0.951774122
5	-0.330865003	-0.109756623	-0.536794206	-0.503664365	-0.432831173	-0.535075999	0.930224342	0.988530971
6	-0.55670638	-0.61637212	-0.57171689	-0.521467875	-0.430428129	-0.60503227	-0.635127151	1.200200618
7	0.83411975	-0.534978939	-0.323262964	0.896237304	-0.315481236	-0.62651111	-0.664148731	2.51431634
8	-0.557767191	-0.626717421	-0.465458115	-0.668257395	-0.433960866	0.230905616	-0.664148731	-1.248111627
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
125	-0.188324056	-0.626717421	-0.556710273	-0.403698765	-0.433960866	-0.208755864	0.625497748	1.828153902
126	-0.262277758	-0.383754974	0.538275869	4.562214034	-0.301339531	-0.401565278	-0.437417634	2.814181672
127	-0.265134817	3.714962171	1.010537091	0.294648626	5.449263064	-0.078009566	-0.587967083	-0.67131184
128	-0.548188689	-0.389079762	-0.559651967	-0.473788812	-0.433840005	-0.584799239	-0.375746776	0.115393679
129	-0.516836812	-0.558712278	-0.141593454	-0.306887334	-0.411654616	0.098186029	0.759722557	-0.327348665
130	-0.134231594	-0.404749851	-0.053819651	0.032408435	-0.417038214	-0.429882427	-0.484577702	0.39056422
131	-0.41586808	-0.458910546	-0.055906664	-0.254004516	-0.423807584	-0.464274032	-0.509971585	0.14890804
132	-0.54000083	-0.626717421	-0.436975357	-0.54457274	-0.433943699	-0.481606237	-0.520854678	-0.540782225
133	-0.523277452	-0.028363443	-0.374146328	-0.251070302	-0.393383709	-0.205818664	-0.20705884	-0.755979699
134	-0.454752608	1.195881272	1.085888197	-0.061428531	2.212799493	0.071996758	3.874100903	0.37645291
135	-0.502818949	1.389247127	-0.441805301	-0.124101918	-0.017647043	0.63557532	1.068076849	-0.300889959
136	-0.557802849	-0.626717421	-0.56627078	-0.6653465	-0.42499869	-0.353724391	-0.633313302	0.344702463

4.3. Deteksi Multikolinearitas

Deteksi multikolinearitas perlu dilakukan untuk mengidentifikasi adanya korelasi yang tinggi antara variabel-variabel independen dalam model regresi yang dapat mempengaruhi keakuratan dan interpretasi hasil model regresi, serta dapat menyebabkan masalah dalam estimasi parameter. Berikut nilai dari deteksi multikolinearitas dengan menggunakan metode varians-inflasi faktor (VIF).

Melihat hasil VIF dari variabel pada **Tabel (4.4)** di atas disimpulkan bahwa nilai $VIF < 10$, dengan demikian semua variabel akan diikuti sertakan dalam

Tabel 4.4 Variabel VIF

Variabel	VIF
X_1	2.16
X_2	1.87
X_3	2.58
X_4	2.51
X_5	2.78
X_6	2.58
X_7	1.82

pemodelan.

4.4. Pemodelan Menggunakan Regresi Linier Berganda

Setelah melakukan deteksi multikolinieritas pada variabel, selanjutnya akan dibentuk model regresi linier. Estimasi model regresi linear menggunakan metode *Ordinary Least Square* (OLS) seperti pada Persamaan (2.6). Diberikan matriks \mathbf{X} dan \mathbf{Y} sebagai berikut :

$$\mathbf{X} = \begin{bmatrix} 1 & x_{11} & x_{21} & x_{31} & \dots & x_{71} \\ 1 & x_{12} & x_{22} & x_{32} & \dots & x_{72} \\ 1 & x_{13} & x_{23} & x_{33} & \dots & x_{73} \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{1361} & x_{1362} & x_{1363} & \dots & x_{1367} \end{bmatrix}_{136 \times 8}$$

dimana angka 1 sebagai konstanta untuk mengestimasi intercept, sedangkan kolom-kolom berikutnya berisi nilai-nilai dari variabel bebas X_1 hingga X_7 .

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ y_3 \\ \vdots \\ y_{136} \end{bmatrix}_{136 \times 1}$$

Matriks Y berisi nilai-nilai variabel Y yang merupakan terikat atau target dalam analisis statistik atau regresi. Kemudian dilakukan estimasi OLS sebagai berikut:

$$\mathbf{X}_{8 \times 136}^T \times \mathbf{X}_{136 \times 8} = \begin{bmatrix} 136 & 605.13 & 1266.19 & 1919.83 & 1582.49 & 1139.00 & 360.55 & 304.54 \\ 605.13 & 3229.63 & 5806.08 & 8828.11 & 7440.20 & 5049.05 & 1651.98 & 1323.28 \\ 1266.19 & 5806.08 & 12100.17 & 18040.84 & 15103.82 & 10673.67 & 3407.85 & 2817.63 \\ 1919.83 & 8828.11 & 18040.84 & 27633.74 & 22837.57 & 16015.14 & 5084.87 & 4322.92 \\ 1582.49 & 7440.20 & 15103.82 & 22837.57 & 19746.56 & 13330.43 & 4167.01 & 3527.15 \\ 1139.00 & 5049.05 & 10673.67 & 16015.14 & 13330.43 & 9678.19 & 3133.41 & 2543.25 \\ 360.55 & 1651.98 & 3407.85 & 5084.87 & 4167.01 & 3133.41 & 1256.09 & 840.27 \\ 304.54 & 1323.28 & 2817.63 & 4322.92 & 3527.15 & 2543.25 & 840.27 & 716.20 \end{bmatrix}_{8 \times 8}$$

$$\left((\mathbf{X}^T \mathbf{X})_{8 \times 8} \right)^{-1} = \begin{bmatrix} 2.1739 & -0.0219 & -0.0078 & -0.0535 & 0.0299 & -0.1744 & 0.0808 & -0.1528 \\ -0.0219 & 0.0040 & -0.0005 & -0.0013 & -0.0007 & 0.0032 & -0.0026 & 0.0072 \\ -0.0078 & -0.0005 & 0.0060 & -0.0013 & -0.0008 & -0.0028 & -0.0003 & 0.0027 \\ -0.0535 & -0.0013 & -0.0013 & 0.0049 & -0.0014 & 0.0036 & -0.0005 & -0.0047 \\ 0.0299 & -0.0007 & -0.0008 & -0.0014 & 0.0019 & -0.0027 & 0.0016 & -0.0014 \\ -0.1744 & 0.0032 & -0.0028 & 0.0036 & -0.0027 & 0.0201 & -0.0090 & 0.0106 \\ 0.0808 & -0.0026 & -0.0003 & -0.0005 & 0.0016 & -0.0090 & 0.0086 & -0.0117 \\ -0.1528 & 0.0072 & 0.0027 & -0.0047 & -0.0014 & 0.0106 & -0.0117 & 0.0534 \end{bmatrix}_{8 \times 8}$$

$$\mathbf{X}_{8 \times 136}^T \times \mathbf{Y}_{136 \times 1} = \begin{bmatrix} 1058.17 \\ 5084.41 \\ 10045.93 \\ 15402.60 \\ 12790.51 \\ 8773.19 \\ 2766.00 \\ 2380.73 \end{bmatrix}_{8 \times 1}$$

$$\left((\mathbf{X}^T \mathbf{X})^{-1} \right)_{8 \times 8} \times (\mathbf{X}^T \mathbf{Y})_{8 \times 1} = \begin{bmatrix} -1.934034 \\ 0.369078 \\ 0.265029 \\ 0.534002 \\ -0.004377 \\ -0.312639 \\ -0.165453 \\ 0.524587 \end{bmatrix}_{8 \times 1}$$

Maka didapat nilai estimasi paramater model regresi linear berganda sebagai berikut :

$$\hat{Y} = -1.934034 + 0.369078x_1 + 0.265029x_2 + 0.534002x_3 - 0.004377x_4 \\ - 0.312639x_5 - 0.165453x_6 + 0.524587x_7$$

Dalam model regresi linier di atas, dapat dijelaskan bahwa koefisien β_0 memiliki nilai -1.93, yang menunjukkan bahwa saat semua variabel independen x bernilai 0, maka nilai \hat{Y} adalah -1.93. kemudian koefisien β_1 memiliki nilai 0.37, yang

menunjukkan bahwa setiap peningkatan 1 unit dalam variabel x_1 berkontribusi positif sebesar 0.37 dalam nilai \hat{Y} . Selanjutnya koefisien β_2 memiliki nilai 0.27, yang menunjukkan bahwa setiap peningkatan 1 unit dalam variabel x_2 berkontribusi positif sebesar 0.27 dalam nilai \hat{Y} . Kemudian koefisien β_3 memiliki nilai 0.53, yang menunjukkan bahwa setiap peningkatan 1 unit dalam variabel x_3 berkontribusi positif sebesar 0.53 dalam nilai \hat{Y} begitu seterusnya untuk variabel lain.

4.5. Uji Simultan Model Regresi Linear

Model regresi linier yang didapat selanjutnya dilakukan uji simultan atau uji-F yang berguna untuk melihat efek keseluruhan dari variabel independen terhadap variabel dependen dalam model regresi linier. Hasil uji simultan ditampilkan pada tabel di bawah ini.

Tabel 4.5 Uji Simultan

Source	DF	SS	MS	F-Value
Regression	7	476.70	68.10	25.78
Error	128	338.107	2.641	
Total	135	814.809		

Daerah kritis yang diberikan pada uji simultan tolak H_0 jika nilai $p\text{-value} < \alpha$ atau $F_{hitung} > F_{(\alpha,t,m-t-1)}$. Hasil pada **Tabel (4.5)** menunjukkan bahwa pada taraf $\alpha = 5\%$, $t = 7$ dan $m = 136$ didapat keputusan :

$$F_{hitung} > F_{(\alpha,t,m-t-1)}$$

$$25.78 > F_{0.05,7,128}$$

$$25.78 > 2.081871890$$

Diperoleh nilai dari F_{hitung} lebih besar dari $F_{(\alpha,t,m-t-1)}$, sehingga keputusan hipotesis yang diberikan adalah terima H_1 dimana terdapat pengaruh secara

bersamaan variabel X terhadap terhadap variabel Y .

4.6. Uji Parsial Model Regresi Linear

Uji parsial dilakukan guna melihat efek signifikan dari setiap variabel independen terhadap variabel dependen dalam model regresi. Berikut tabel hasil uji parsial model regresi linear.

Tabel 4.6 Uji Parsial

Variabel	t-value	P-value
<i>Intercept</i>	-0.8071	0.4211091
X_1	3.5795	0.0004871
X_2	2.1023	0.0374829
X_3	4.7117	6.31E-06
X_4	-0.062	0.9506372
X_5	-1.3583	0.1767432
X_6	-1.0965	0.2748975
X_7	1.3973	0.164751

Daerah kritis tolak H_0 jika nilai $p\text{-value} < \alpha$ atau $|t_{hitung}| > t_{(\frac{\alpha}{2}, m-t-1)}$.

Keputusan yang diambil sebagai berikut:

$$|t_{hitung}| > t_{(\frac{\alpha}{2}, m-t-1)}$$

$$> t_{\frac{0.05}{2}, 128}$$

$$> t_{0.025, 128}$$

$$> 1.657$$

Didapat hasil dari $t_{(\frac{\alpha}{2}, m-t-1)} = 1.657$, sehingga berdasarkan **Tabel (4.6)** keputusan yang diperoleh hanya variabel X_1, X_2 dan X_3 yang memberikan efek signifikan terhadap variabel dependen dalam model regresi, sedangkan untuk X_4, X_5, X_6, X_7 yang memiliki nilai t_{hitung} kurang dari nilai $t_{(\frac{\alpha}{2}, m-t-1)}$ diambil keputusan adalah gagal tolak H_0 yang berarti bahwa tidak ada cukup bukti yang kuat untuk mendukung H_1 .

4.7. Uji Asumsi Klasik

4.7.1. Uji Homoskedestisitas Residual Regresi Linear

Uji Homoskedastisitas adalah langkah penting dalam analisis regresi. Uji ini dilakukan untuk memeriksa apakah terdapat perbedaan dalam varian residual atau kesalahan prediksi di sepanjang rentang nilai variabel independen. Pengujian menggunakan metode Glejser dengan hasil seperti pada tabel di bawah ini.

Tabel 4.7 Uji Homoskedastisitas

Uji Homoskedastisitas	p-value	Parameter
Glejser	1.73×10^{-19}	7

Keputusan tolak H_0 jika nilai $p\text{-value} < \alpha$ artinya residual tidak identik atau adanya kasus heteroskedastisitas. Pada **Tabel (4.6)** tertera $p\text{-value}$ yang dihasilkan (1.73×10^{-19}) lebih kecil dari tingkat signifikansi (α) yang ditetapkan (0.05). Hal ini menunjukkan bahwa terdapat bukti yang sangat kuat untuk menolak hipotesis nol dan menyimpulkan adanya heteroskedastisitas dalam model regresi.

4.7.2. Uji Autokorelasi Residual Regresi Linear

Uji autokorelasi dilakukan untuk memeriksa keberadaan autokorelasi atau ketergantungan antara residual dalam model regresi. Autokorelasi terjadi ketika ada pola atau hubungan teratur antara residual dalam model, yang berarti bahwa residual pada satu observasi terkait dengan residual pada observasi sebelumnya. Pengujian menggunakan metode Durbin-Watson dengan perhitungan sesuai dengan Persamaan (2.12) sebagai berikut.

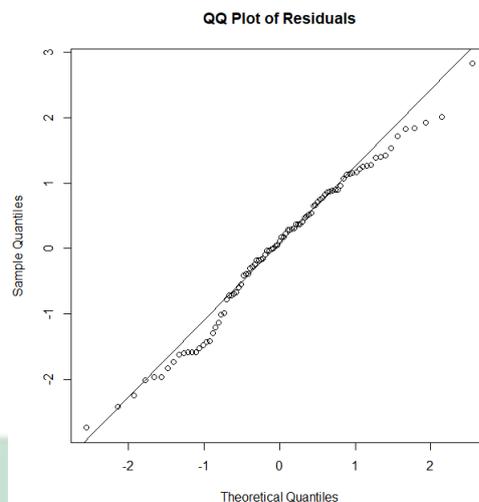
$$\begin{aligned}
 d &= \frac{\sum_{i=2}^m (\theta_i - \theta_{i-1})^2}{\sum_{i=1}^m \theta_i^2} \\
 &= \frac{((-3770.42 - 9068.54)^2 + (-5058.79 - (-3770.42))^2 + \dots + (-2817.41 - (-12492.84)))^2}{(9068.54)^2 + (-3770.42)^2 + \dots + (-2817.41)^2} \\
 &= \frac{66128741680}{37478222314} \\
 &= 1.76459
 \end{aligned}$$

Dari perhitungan di atas diperoleh nilai dari *Durbin-Watson* (d) = 1.76459, kemudian berdasarkan tabel *Durbin-Watson* **Tabel (2.2)** didapatkan keputusan bahwa nilai $d = 1.76459$ berada pada rentang 1.55 sampai 2.46 yang menandakan tidak dapat disimpulkan adanya autokorelasi sehingga asumsi ketiadaan autokorelasi terpenuhi .

4.7.3. Uji Normalitas Residual Regresi Linear

Pengujian normalitas pada residual dapat memberikan kesimpulan yang lebih jelas dengan melihat plot dari residual, seperti *QQ-Plot* (*Quantile-Quantile plot*). *QQ-Plot* membandingkan kuantil residual yang diamati dengan kuantil yang diharapkan dari distribusi normal. Jika sebaran residual pada *QQ-plot* cenderung mengikuti garis diagonal, ini menunjukkan bahwa residual secara kasar mengikuti distribusi normal. Artinya, data residual mendekati distribusi normal yang diharapkan.

Namun, jika sebaran residual tidak mengikuti garis diagonal dan memiliki pola yang melengkung atau tidak teratur, ini menunjukkan bahwa residual tidak mengikuti distribusi normal secara baik. Hal ini menunjukkan adanya ketidakteraturan dalam sebaran residual yang dapat mempengaruhi asumsi model regresi. *QQ-Plot* dapat berguna sebagai visualisasi yang jelas, pengidentifikasi pola juga sebagai validasi asumsi. Berikut *QQ-Plot* dari residual model regresi.



Gambar 4.12 *QQ-Plot Residual*

Melihat **Gambar (4.12)** disimpulkan data telah berdistribusi normal, diperkuat dengan melihat hasil pengujian Kolmogorov-Smirnov berikut ini.

Tabel 4.8 Uji Normalitas

Uji Normalitas	p-value	D
Kolmogorov-Smirnov	0.5659	0.067459

Dimana keputusan residual telah berdistribusi normal jika nilai dari $D < D_{\alpha}(m)$ atau $p\text{-value} > \alpha$. Pada **Tabel (4.8)** di atas didapat $D = 0.067459$ (nilai statistik uji Kolmogorov-Smirnov) kurang dari $D_{\alpha}(m) = 0.1157615$ (nilai kritis yang diketahui dari tabel), dan $p\text{-value} = 0.5659$ lebih besar dari $\alpha = 0.05$. Oleh karena itu, berdasarkan hasil tersebut, dapat disimpulkan bahwa terdapat bukti kuat yang mendukung hipotesis H_0 , yaitu residual data telah berdistribusi normal.

4.8. Uji Heterogenitas Spasial dan Temporal

Uji heterogenitas spasial dan temporal dilakukan guna menganalisis dan mengidentifikasi adanya variasi atau perbedaan yang signifikan dalam pola spasial dan temporal data yang diamati. Uji heterogenitas spasial dilakukan dengan

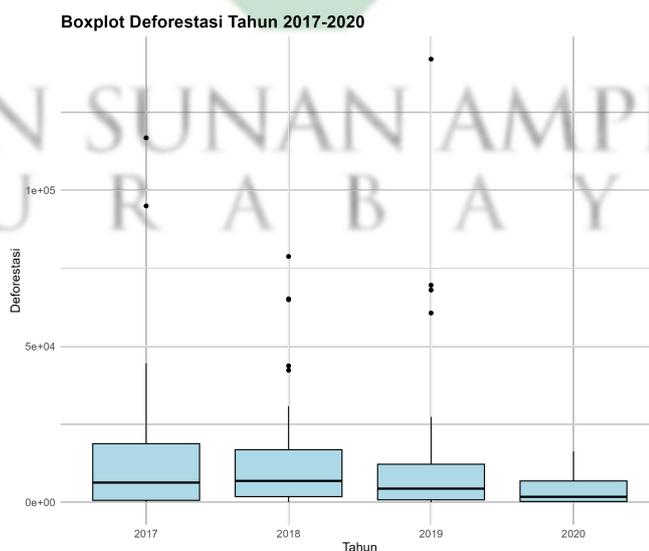
menggunakan *Breusch-Pagan test*, hasil ditampilkan pada tabel di bawah ini:

Tabel 4.9 Uji Heterogenitas spasial

Uji heterogenitas spasial	p-value	BP
<i>Breusch-Pagan test</i>	3.713×10^{-16}	37.535

Daerah kritis tolak H_0 jika nilai dari $BP > \chi_{\alpha,t}^2$ atau saat nilai $p\text{-value} < \alpha$. Berdasarkan nilai yang tertera pada **Tabel (4.9)** dapat diambil kesimpulan bahwa $BP = 37.535 > \chi_{0.05,7}^2 = 14.0671$ dan $p\text{-value} = 3.713 \times 10^{-16} < 0.05$ maka keputusan yang tepat adalah terdapat perbedaan yang signifikan dalam pola spasial data yang diamati. Dengan kata lain, distribusi nilai variabel yang diuji tidak homogen secara spasial atau menunjukkan adanya variasi yang signifikan antara lokasi-lokasi di dalam data tersebut.

Selanjutnya dilakukan pengujian heterogenitas temporal bertujuan untuk mengidentifikasi apakah terdapat variasi atau perbedaan yang signifikan dalam pola data seiring berjalannya waktu yang dapat menyebabkan heterogenitas temporal, pengujian dilakukan dengan melihat *Box-Plot* berikut ini.



Gambar 4.13 Box-Plot Deforestasi

Pada **Gambar (4.13)** kotak pada *Box-Plot* pada periode waktu 2017 lebih

lebar atau terletak pada posisi yang berbeda dibandingkan dengan periode waktu 2018, 2019, 2020, maka ini menunjukkan adanya variasi atau fluktuasi yang signifikan dalam distribusi data di antara periode waktu tersebut. Hal ini dapat mengindikasikan adanya heterogenitas temporal dalam data.

4.9. Pemodelan Model *Geographically and Temporally Weighted Regression* (GTWR)

Analisis metode GTWR memerlukan matriks pembobot (W_{ij}) yang dibangun dari matriks jarak *euclidean*. Matriks jarak ini menggunakan jarak spasial dan jarak temporal. Oleh karena itu dalam membangun matriks jarak *euclidean* dengan memerlukan parameter penyeimbang. Penggunaan parameter penyeimbang tersebut dimaksudkan karena adanya perbedaan satuan antara jarak spasial dan jarak temporal. Parameter penyeimbang yang digunakan dalam penelitian ini adalah parameter jarak spasial (λ), parameter jarak temporal (μ) dan parameter rasio yang optimum (τ). Untuk menghitung parameter tersebut dilakukan dengan menggunakan pendekatan CV minimum, dimana iterasi dilakukan dengan menguji nilai *lower* = 0.008959388 hingga *upper* = 44.79694 dengan panjang sebanyak 100. Nilai-nilai parameter untuk masing-masing model dapat dilihat pada **Tabel (4.10)**

Tabel 4.10 Nilai parameter pada masing-masing model

Model GTWR	b_S	b_{ST}	λ	μ	τ
Fixed Gaussian	43.42964	34.22245	43.43387	1885.136	43.4024
Fixed Bisquare	17.90507	43.43423	21.43584	931.0472	43.4341

Nilai yang didapat selanjutnya digunakan untuk membentuk jarak spasial-temporal (d_{ij}^{ST}) sesuai dengan Persamaan (2.29). Berikut nilai jarak spasial-temporal untuk 34 provinsi yang didapat dengan ukuran matriks 136×136 ,

contoh provinsi Aceh tahun 2017.

$$d_{ij}^{ST} = \begin{bmatrix} d_{11} & d_{12} & \dots & d_{1n} \\ d_{21} & d_{22} & \dots & d_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ d_{n1} & d_{n2} & \dots & d_{nn} \end{bmatrix} = \begin{bmatrix} 0 & 122.23 & \dots & 158.90 \\ 122.23 & 0 & \dots & 133.98 \\ \vdots & \vdots & \ddots & \vdots \\ 158.90 & 133.98 & \dots & 0 \end{bmatrix}_{136 \times 136}$$

Kemudian nilai dari b_{ST} dan (d_{ij}^{ST}) digunakan sebagai pembentuk matriks pembobot W_{ij} dengan menggunakan fungsi pembobot *fixed kernel gaussian*, *fixed kernel bisquare*. Berdasarkan Persamaan (2.20), (2.21), berikut matriks pembobot provinsi Aceh dengan kernel *Fixed Gaussian* menggunakan Persamaan (2.20) .

Tabel 4.11 Matriks Pembobot W_{ij} Kernel Fixed Gaussian Provinsi Aceh

No	Provinsi	Tahun	d_{ij}^{ST}	W_{ij}
1	Aceh	2017	0.00	1
2	Bali	2017	122.23	0.0017107
3	Bangka-Belitung	2017	64.30	0.1715111
4	Banten	2017	62.38	0.1902306
5	Bengkulu	2017	37.80	0.5436786
6	Gorontalo	2017	169.40	4.85E-06
7	Irian Jaya	2017	240.13	2.09E-11
8	Jakarta	2017	67.42	0.143915
9	Jambi	2017	38.00	0.540283
10	Jawa Barat	2017	72.92	0.1035546
11	Jawa Tengah	2017	89.04	0.0340122
12	Jawa Timur	2017	102.81	0.0110283
13	Kalimantan Barat	2017	97.18	0.0178281
⋮	⋮	⋮	⋮	⋮
128	Sulawesi Barat	2020	197.43	6.05E-08
129	Sulawesi Selatan	2020	201.16	3.21E-08
130	Sulawesi Tengah	2020	208.55	8.81E-09
131	Sulawesi Tenggara	2020	212.42	4.40E-09
132	Sulawesi Utara	2020	221.76	7.81E-10
133	Sumatera Barat	2020	133.07	0.0005253
134	Sumatera Selatan	2020	138.78	0.0002710
135	Sumatera Utara	2020	131.58	0.0006220
136	Yogyakarta	2020	158.90	2.11E-05

Sehingga bentuk matriks pembobot untuk provinsi Aceh dengan kernel *Fixed Gaussian* sebagai berikut.

$$w_{ij} = \begin{bmatrix} 1 & 0 & \dots & 0 \\ 0 & 0.0017107 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 2.11E - 05 \end{bmatrix}$$

Kemudian matriks pembobot dengan kernel *Fixed Bisquare* menggunakan Persamaan (2.21) untuk provinsi Aceh sebagai berikut.

Tabel 4.12 Matriks Pembobot W_{ij} Kernel *Fixed Bisquare* Provinsi Aceh

No	Provinsi	Tahun	d_{ij}^{ST}	W_{ij}
1	Aceh	2017	0	1
2	Bali	2017	86.3727	0
3	Bangka-Belitung	2017	45.4811	0
4	Banten	2017	44.5314	0
5	Bengkulu	2017	27.20197725	0.36938
6	Gorontalo	2017	119.042	0
7	Irian Jaya Barat	2017	168.7528	0
8	Jakarta	2017	47.99787	0
9	Jambi	2017	27.05324808	0.37460
10	Jawa Barat	2017	51.91163	0
11	Jawa Tengah	2017	63.11973	0
12	Jawa Timur	2017	72.74790	0
13	Kalimantan Barat	2017	68.36036	0
	\vdots	\vdots	\vdots	\vdots
128	Sulawesi Barat	2020	138.8216	0
129	Sulawesi Selatan	2020	141.4621	0
130	Sulawesi Tengah	2020	146.5971	0
131	Sulawesi Tenggara	2020	149.38065	0
132	Sulawesi Utara	2020	155.8363	0
133	Sumatera Barat	2020	93.59845	0
134	Sumatera Selatan	2020	97.69398	0
135	Sumatera Utara	2020	92.48578	0
136	Yogyakarta	2020	112.01395	0

Sehingga bentuk matriks pembobot untuk provinsi Aceh dengan kernel *Fixed Bisquare* sebagai berikut.

$$w_{ij} = \begin{bmatrix} 1 & 0 & \dots & 0 \\ 0 & 0 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 0 \end{bmatrix}$$

4.10. Estimasi Parameter Model *Geographically and Temporally Weighted Regression (GTWR)*

Nilai dari matriks pembobot untuk tiap fungsi pembobot yang telah didapat kemudian digunakan untuk membentuk penduga parameter model GTWR yaitu dengan menggunakan metode WLS seperti pada Persamaan (2.26). Berikut ditampilkan nilai $\hat{\beta}$ untuk kernel *Fixed Gaussian*.

Tabel 4.13 Estimasi Parameter Model GTWR dengan Kernel *Fixed Gaussian*

Provinsi	Tahun	β_0	β_1	β_2	β_3	β_4	β_5	β_6	β_7
Aceh	2017	4.35495	0.07156	-0.43973	0.71015	0.23306	-0.59132	0.15421	-0.10639
Bali	2017	2.25433	0.48392	0.43417	0.32320	0.02047	-0.78563	-0.13229	0.70418
Bangka-Belitung	2017	4.36530	0.31595	-0.28880	0.62689	0.13116	-0.63397	-0.07697	0.14420
Banten	2017	4.57319	0.30394	-0.30885	0.63106	0.14099	-0.64103	-0.05817	0.08985
Bengkulu	2017	5.90175	0.17460	-0.43250	0.65501	0.22243	-0.69724	0.11189	-0.25732
Gorontalo	2017	1.19532	0.21829	1.01737	0.36183	-0.00762	-1.15919	0.20304	0.25571
Irian Jaya Barat	2017	1.94568	-0.06619	1.14340	-0.46914	0.38490	-0.06346	-0.59756	0.41378
Jakarta	2017	4.15106	0.33088	-0.27190	0.62303	0.12130	-0.62257	-0.09836	0.19112
Jambi	2017	5.87986	0.17636	-0.42914	0.65472	0.22066	-0.69767	0.10870	-0.24844
Jawa Barat	2017	3.71220	0.35677	-0.22992	0.61243	0.10199	-0.60445	-0.13838	0.29301
Jawa Tengah	2017	2.60569	0.41090	-0.07184	0.55934	0.06059	-0.58032	-0.22899	0.52877
Jawa Timur	2017	2.06030	0.43561	0.10482	0.48633	0.04290	-0.60944	-0.25299	0.62165
Kalimantan Barat	2017	2.15963	0.43145	0.04025	0.51244	0.04835	-0.59059	-0.24837	0.60288
Kalimantan Selatan	2017	2.20764	0.49125	0.44599	0.31633	0.01945	-0.78941	-0.11956	0.70906
Kalimantan Tengah	2017	1.89566	0.45490	0.22211	0.43166	0.03402	-0.64856	-0.22781	0.65443
Kalimantan Timur	2017	2.62851	0.51851	0.59303	0.23476	0.01250	-0.91147	-0.01308	0.75041
Kalimantan Utara	2017	2.65376	0.52141	0.60697	0.22767	0.01173	-0.92275	-0.00091	0.75367
Kepulauan Riau	2017	3.44030	0.36874	-0.19487	0.60172	0.09129	-0.59993	-0.15649	0.36338
Lampung	2017	4.91122	0.27921	-0.33588	0.63635	0.15769	-0.65761	-0.02330	0.00998
Maluku Utara	2017	2.53738	0.08755	1.01177	-0.35108	0.40708	-0.29494	-0.31541	0.11675
Maluku	2017	-1.38802	0.05446	0.97609	0.25631	0.18403	-0.55209	-0.13255	-0.09036
Nusa Tenggara Barat	2017	3.35736	0.51981	0.72022	0.16305	0.01001	-1.04411	0.06610	0.77863
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
Nusa Tenggara Timur	2020	-11.45197	0.08379	0.36064	0.92076	-0.11429	0.14342	-0.40728	1.35465
Papua	2020	-10.23493	0.13446	-0.29344	0.69857	0.03207	1.10246	-0.35550	0.65453
Riau	2020	-0.42576	0.62160	0.45075	0.32160	-0.04907	-0.55702	-0.11345	0.55911
Sulawesi Barat	2020	-7.92628	0.15135	0.45008	0.78191	-0.13064	-0.17089	-0.35904	1.35807
Sulawesi Selatan	2020	-9.23678	0.12102	0.41827	0.83507	-0.12295	-0.05902	-0.37408	1.35756
Sulawesi Tengah	2020	-12.20798	0.07407	0.33614	0.95158	-0.10756	0.21329	-0.41281	1.32996
Sulawesi Tenggara	2020	-13.82534	0.05987	0.28991	1.00860	-0.10368	0.37707	-0.44476	1.31923
Sulawesi Utara	2020	-17.71068	0.05318	0.16789	1.12456	-0.09468	0.82142	-0.54220	1.26508
Sumatera Barat	2020	-0.26783	0.62941	0.43296	0.31878	-0.04575	-0.55749	-0.09684	0.52467
Sumatera Selatan	2020	-0.71794	0.60093	0.49623	0.33150	-0.05946	-0.56424	-0.15519	0.62071
Sumatera Utara	2020	-0.05821	0.63879	0.41421	0.31703	-0.04313	-0.56232	-0.07643	0.47690
Yogyakarta	2020	-1.60533	0.47548	0.53065	0.47721	-0.14125	-0.57857	-0.26428	0.91440

Selanjutnya ditampilkan nilai estimasi $\hat{\beta}$ model GTWR untuk kernel *Fixed Bisquare* pada **Tabel (4.14)** di bawah ini.

Tabel 4.14 Estimasi Parameter Model GTWR dengan Kernel *Fixed Bisquare*

Provinsi	Tahun	β_0	β_1	β_2	β_3	β_4	β_5	β_6	β_7
Aceh	2017	-8.43550	-0.85441	-1.33293	2.60602	0.81375	-1.80997	0.66359	0.15268
Bali	2017	9.23737	0.71235	0.68717	-0.04461	-0.03697	-1.46842	0.02452	1.03032
Bangka-Belitung	2017	8.85773	0.21749	-0.42703	0.66909	0.17893	-1.00019	0.07554	-0.36215
Banten	2017	9.07931	0.19852	-0.44765	0.66826	0.19789	-1.00268	0.10986	-0.46195
Bengkulu	2017	9.41543	-0.12333	-0.58709	0.59190	0.41703	-0.94747	0.28453	-0.33249
Gorontalo	2017	4.47623	0.30619	1.45031	-0.02928	0.02341	-1.57473	0.37864	0.53814
Irian Jaya Barat	2017	-1.39792	-6.49115	2.54875	15.14522	-7.90651	-14.78540	-2.31132	-5.94449
Jakarta	2017	8.53362	0.25277	-0.42392	0.67585	0.15533	-0.96998	0.03408	-0.29085
Jambi	2017	9.33125	-0.12350	-0.57732	0.59671	0.41143	-0.94965	0.27946	-0.31837
Jawa Barat	2017	7.90943	0.29688	-0.40515	0.68363	0.11238	-0.92977	-0.03328	-0.08727
Jawa Tengah	2017	4.68160	0.36861	-0.40307	0.83058	-0.10774	-0.69573	-0.26938	0.83858
Jawa Timur	2017	2.54894	0.27563	-0.25235	0.92707	-0.20734	-0.57770	-0.52841	1.02458
Kalimantan Barat	2017	2.87501	0.35601	-0.31233	0.89525	-0.19787	-0.59848	-0.43546	1.14434
Kalimantan Selatan	2017	9.51270	0.78226	0.72602	-0.11636	-0.02027	-1.52847	0.11048	1.10355
Kalimantan Tengah	2017	2.81931	0.31387	-0.00718	0.74774	-0.15567	-0.66123	-0.54522	0.86532
Kalimantan Timur	2017	11.72995	0.92504	1.03777	-0.39919	-0.01728	-1.85862	0.38637	1.23540
Kalimantan Utara	2017	11.47509	0.92277	1.04778	-0.38831	-0.01932	-1.85656	0.40241	1.22351
Kepulauan Riau	2017	7.54267	0.31467	-0.36513	0.67928	0.08085	-0.94100	-0.07392	0.15071
Lampung	2017	9.30288	0.14244	-0.45501	0.65659	0.23490	-1.02156	0.17128	-0.53567
Maluku Utara	2017	-1.33899	-0.69948	1.94752	-1.63533	1.49436	0.27268	-0.83546	0.72278
Maluku	2017	-16.50838	-0.33851	1.95864	0.10735	0.64348	0.21239	-0.88832	0.25091
Nusa Tenggara Barat	2017	12.97567	0.88189	1.27390	-0.51859	-0.03993	-2.04933	0.48784	1.26794
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
Nusa Tenggara Timur	2020	-16.55039	-0.03352	0.40606	0.85808	-0.08823	0.69579	-0.53393	2.00571
Papua	2020	-0.51821	-6.10577	8.83319	-3.75515	12.14176	-12.36142	-6.05341	-18.38741
Riau	2020	1.14921	0.85150	0.29252	0.07892	0.00346	-0.62354	-0.33294	1.64593
Sulawesi Barat	2020	-12.27058	-0.04168	0.48126	0.96244	-0.16031	0.10826	-0.50302	1.58086
Sulawesi Selatan	2020	-13.81657	-0.05749	0.45684	0.93129	-0.12378	0.30094	-0.49259	1.71856
Sulawesi Tengah	2020	-17.30607	-0.04514	0.38519	0.91763	-0.07573	0.68838	-0.50105	1.99264
Sulawesi Tenggara	2020	-19.50866	-0.03719	0.31848	1.00049	-0.08180	0.88702	-0.55683	2.04619
Sulawesi Utara	2020	-28.50950	-0.00983	0.06853	1.54988	-0.12328	1.47012	-0.76995	1.79310
Sumatera Barat	2020	1.39005	0.89563	0.21688	0.08568	0.00372	-0.58406	-0.29783	1.49335
Sumatera Selatan	2020	-1.21403	0.73269	0.60485	0.27242	-0.13173	-0.64864	-0.24758	1.13619
Sumatera Utara	2020	2.26352	0.99029	0.15638	0.12208	-0.03702	-0.59711	-0.18801	0.96195
Yogyakarta	2020	-4.11244	0.59940	0.61949	0.52991	-0.28432	-0.41612	-0.51400	1.32005

Berdasarkan **Tabel (4.13)** dan **Tabel (4.14)**, sebagai contoh provinsi Aceh tahun 2017 didapat estimasi model GTWR sebagai berikut.

Model GTWR kernel *Fixed Gaussian*:

$$\hat{Y}_{\text{gaussian}} = 4.35495 + 0.07156x_1 - 0.43973x_2 + 0.71015x_3 + 0.23306x_4 - 0.59132x_5 \\ + 0.15421x_6 - 0.10639x_7$$

Model GTWR kernel *Fixed Bisquare* :

$$\hat{Y}_{\text{bisquare}} = -8.43550 - 0.85441x_1 - 1.33293x_2 + 2.60602x_3 + 0.81375x_4 - 1.80997x_5 \\ + 0.66359x_6 + 0.15268x_7$$

4.11. Uji Kesesuaian *Goodness Of Fit* Model GTWR (*Geographically and Temporally Weighted Regression*)

Uji *goodness of fit* dapat dilakukan untuk membandingkan kinerja antara model OLS (*Ordinary Least Squares*) dan model GTWR (*Geographically and Temporally Weighted Regression*). Tujuannya adalah untuk mengetahui apakah terdapat perbedaan signifikan antara kedua model tersebut dalam menjelaskan data yang ada. Berdasarkan Persamaan (2.34) didapat nilai *Goodness Of Fit* berikut ini.

Tabel 4.15 Hasil Uji Kecocokan Model GTWR dengan OLS

Model GTWR	F-Value	p-value	F-tabel
Fixed Gaussian	1.5953	0.015	1.42518
Fixed Bisquare	1.4964	0.0407	

Berdasarkan hasil yang diberikan pada **Tabel (4.15)**, dengan tingkat signifikansi adalah $\alpha = 0.05$, keputusan tolak H_0 saat $F^* > F_{\alpha;df_1,df_2}$. Model GTWR dengan fungsi pembobot *Fixed Gaussian* menunjukkan nilai $F^* = 1.5953$ dan fungsi pembobot *Fixed Bisquare* memiliki nilai $F^* = 1.4964$ yang lebih kecil dari $F - tabel = 1.42518$ menandakan keputusan terdapat bukti yang kuat untuk menolak hipotesis nol dengan demikian secara signifikan model GTWR lebih baik daripada model regresi linear dalam memodelkan data Deforestasi di Indonesia tahun 2017-2020.

4.12. Uji Parsial Model GTWR (*Geographically and Temporally Weighted Regression*)

Uji parsial dilakukan untuk menentukan variabel independen yang berpengaruh signifikan terhadap kasus deforestasi di Indonesia pada tahun 2017-2020. Pengujian dilakukan menggunakan statistik uji t dengan menggunakan

Persamaan (2.35). Menggunakan tingkat kepercayaan $\alpha = 5\%$, jika nilai $(|t^*| \leq t_{\frac{\alpha}{2}, df} = 1.9844)$ atau jika nilai $p - value < \alpha = 0.05$, maka tolak H_0 . Ini berarti variabel independen tersebut dianggap signifikan terhadap model. Ditampilkan pada **Tabel (4.16)** variabel yang signifikan model GTWR kernel *Fixed Gaussian* dan model GTWR kernel *Fixed Bisquare* tahun 2017 pada **Tabel (4.16)**.

Tabel 4.16 Variabel Signifikan dalam Model GTWR Tahun 2017

Provinsi	Fixed Gaussian	Fixed Bisquare
Aceh	X_3	X_3, X_6
Bali	X_3	X_1, X_3
Bangka-Belitung	X_1, X_2, X_5	X_3, X_6
Banten	X_3	X_3, X_6
Bengkulu	X_3	X_3, X_6
Gorontalo	X_2	X_1, X_3
Irian Jaya Barat	X_2	X_1, X_3
Jakarta Raya	X_3	X_3, X_6
Jambi	X_2, X_5	X_3, X_6
Jawa Barat	X_2	X_3, X_6
Jawa Tengah	X_3	X_1, X_3
Jawa Timur	X_3	X_1, X_3
Kalimantan Barat	X_3	X_1, X_3
Kalimantan Selatan	X_2	X_1, X_3
Kalimantan Tengah	X_1, X_3	X_1, X_3
Kalimantan Timur	X_1, X_2, X_5	X_1, X_3
Kalimantan Utara	X_2, X_5	X_1, X_3
Kepulauan Riau	X_1, X_3	X_1, X_3, X_6
Lampung	X_1, X_3	X_3, X_6
Maluku	X_3	X_1, X_3
Maluku Utara	X_3	X_1, X_3
Nusa Tenggara Barat	X_3	X_1, X_3
Nusa Tenggara Timur	X_3	X_1, X_3
Papua	X_1, X_3	X_1, X_3, X_7
Riau	X_1, X_2, X_5	X_3, X_6
Sulawesi Barat	X_1, X_2, X_5	X_1, X_3
Sulawesi Selatan	X_2, X_5	X_1, X_3
Sulawesi Tengah	X_2, X_5	X_1, X_3
Sulawesi Tenggara	X_2, X_5	X_1, X_3
Sulawesi Utara	X_3	X_1, X_3
Sumatera Barat	X_1, X_3	X_3, X_6
Sumatera Selatan	X_1, X_2, X_5	X_3, X_6
Sumatera Utara	X_1, X_2, X_5	X_3, X_6
Yogyakarta	X_1, X_3	X_1, X_3

Tabel signifikansi untuk model GTWR kernel *Fixed Gaussian* dan model GTWR kernel *Fixed Bisquare* tahun 2018 ditampilkan pada tabel **Tabel (4.17)**.

Tabel 4.17 Variabel Signifikan dalam Model GTWR Tahun 2018

Provinsi	Fixed Gaussian	Fixed Bisquare
Aceh	X_3	X_3, X_6
Bali	X_3	X_1, X_3
Bangka-Belitung	X_3	X_3
Banten	X_3	X_3
Bengkulu	X_3	X_3
Gorontalo	X_2	X_1, X_3
Irian Jaya Barat	X_2	X_1, X_3
Jakarta Raya	X_3	X_3
Jambi	X_3	X_3
Jawa Barat	X_3	X_3
Jawa Tengah	X_3	X_3
Jawa Timur	X_3	X_1, X_3
Kalimantan Barat	X_3	X_1, X_3
Kalimantan Selatan	X_3	X_1, X_3
Kalimantan Tengah	X_3	X_1, X_3
Kalimantan Timur	X_2, X_3	X_1, X_3
Kalimantan Utara	X_2, X_3	X_1, X_3
Kepulauan Riau	X_3	X_3
Lampung	X_3	X_3
Maluku	X_2	X_1, X_3
Maluku Utara	X_2	X_1, X_3
Nusa Tenggara Barat	X_2, X_3	X_1, X_3
Nusa Tenggara Timur	X_2	X_1, X_3
Papua	X_2	X_1, X_3
Riau	X_3	X_3, X_6
Sulawesi Barat	X_2	X_1, X_3
Sulawesi Selatan	X_2	X_1, X_3
Sulawesi Tengah	X_2	X_1, X_3
Sulawesi Tenggara	X_2	X_1, X_3
Sulawesi Utara	X_2	X_1, X_3
Sumatera Barat	X_3	X_3, X_6
Sumatera Selatan	X_3	X_3
Sumatera Utara	X_3	X_3, X_6
Yogyakarta	X_3	X_3

Selanjutnya tabel signifikansi untuk model GTWR kernel *Fixed Gaussian* dan model GTWR kernel *Fixed Bisquare* tahun 2019 ditampilkan pada tabel **Tabel (4.18)**.

Tabel 4.18 Variabel Signifikan dalam Model GTWR Tahun 2019

Provinsi	Fixed Gaussian	Fixed Bisquare
Aceh	X_1, X_3	X_2, X_3
Bali	X_2, X_3	X_1, X_3
Bangka-Belitung	X_1, X_3	X_3
Banten	X_1, X_3	X_2
Bengkulu	X_1, X_3	X_2
Gorontalo	X_2, X_3	X_1, X_3
Irian Jaya Barat	X_2, X_3	X_1, X_3
Jakarta Raya	X_1, X_3	X_2
Jambi	X_1, X_3	X_2
Jawa Barat	X_1, X_3	X_1
Jawa Tengah	X_1, X_3	X_1
Jawa Timur	X_3	X_1
Kalimantan Barat	X_3	X_1
Kalimantan Selatan	X_2, X_3	X_1, X_3
Kalimantan Tengah	X_3	X_1, X_3
Kalimantan Timur	X_2, X_3	X_1, X_3
Kalimantan Utara	X_2, X_3	X_1, X_3
Kepulauan Riau	X_1, X_3	X_1
Lampung	X_1, X_3	X_3
Maluku	X_2, X_3	X_1, X_3
Maluku Utara	X_2, X_3	X_1, X_3
Nusa Tenggara Barat	X_2, X_3	X_1, X_3
Nusa Tenggara Timur	X_2, X_3, X_7	X_1, X_3
Papua	X_2, X_3	X_1, X_3
Riau	X_1, X_3	X_2
Sulawesi Barat	X_2, X_3	X_1, X_3
Sulawesi Selatan	X_2, X_3, X_7	X_1, X_3
Sulawesi Tengah	X_2, X_3	X_1, X_3
Sulawesi Tenggara	X_2, X_3	X_1, X_3
Sulawesi Utara	X_3	X_1, X_3
Sumatera Barat	X_1, X_3	X_2
Sumatera Selatan	X_1, X_3	X_1, X_3
Sumatera Utara	X_1, X_3	X_2
Yogyakarta	X_1, X_3	X_1

Kemudian tabel signifikansi untuk model GTWR kernel *Fixed Gaussian* dan model GTWR kernel *Fixed Bisquare* tahun 2020 ditampilkan pada tabel **Tabel (4.19)**.

Tabel 4.19 Variabel Signifikan dalam Model GTWR Tahun 2020

Provinsi	Fixed Gaussian	Fixed Bisquare
Aceh	X1	X1, X2, X3
Bali	X2, X3, X7	X1, X3
Bangka-Belitung	X1, X2	X1
Banten	X1, X2	X1
Bengkulu	X1	X1, X2
Gorontalo	X3	X1, X3
Irian Jaya Barat	X3	X1, X3
Jakarta Raya	X1, X2	X1
Jambi	X1	X1, X2
Jawa Barat	X1, X2	X1
Jawa Tengah	X1, X2, X3	X1, X3
Jawa Timur	X1, X2, X3	X1, X3
Kalimantan Barat	X1, X2, X3	X1, X3
Kalimantan Selatan	X2, X3, X7	X1, X3
Kalimantan Tengah	X1, X2, X3	X1, X3
Kalimantan Timur	X2, X3, X7	X1, X3
Kalimantan Utara	X2, X3, X7	X1, X3
Kepulauan Riau	X1, X2, X3	X1
Lampung	X1, X2	X1
Maluku	X5	X1, X3
Maluku Utara	X3, X5, X6	X1, X3
Nusa Tenggara Barat	X2, X3, X7	X1, X3
Nusa Tenggara Timur	X3, X7	X1, X3
Papua	X3	X1, X3
Riau	X1	X1, X2
Sulawesi Barat	X3, X7	X1, X3
Sulawesi Selatan	X3, X7	X1, X3
Sulawesi Tengah	X3, X7	X1, X3
Sulawesi Tenggara	X3	X1, X3
Sulawesi Utara	X3	X1, X3
Sumatera Barat	X1	X1, X2
Sumatera Selatan	X1	X1
Sumatera Utara	X1	X1, X2, X3
Yogyakarta	X1, X2, X3	X1, X3

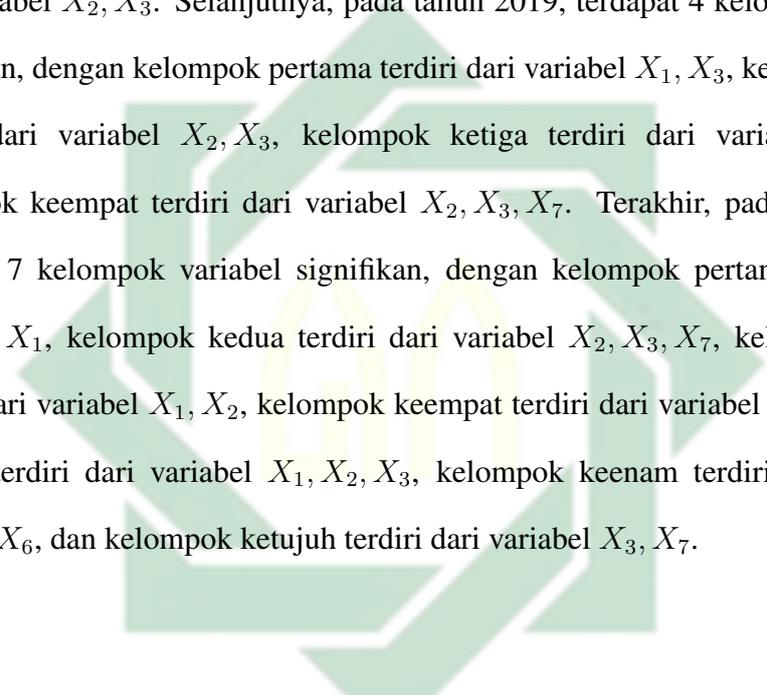
Berdasarkan **Tabel (4.16), (4.17), (4.18), (4.19)** di atas kemudian dilakukan pengelompokan provinsi berdasarkan variabel independen yang signifikan. Berikut tabel pengelompokan berdasarkan variabel signifikan berpengaruh terhadap deforestasi setiap provinsi pertahunnya dengan pembobot kernel *Fixed Gaussian* pada **Tabel (4.20)** dan pembobot kernel *Fixed Bisquare* pada **Tabel (4.21)**. Pada

Tabel 4.20 Pengelompokan Provinsi Model GTWR *Fixed Gaussian* Berdasarkan Signifikansi Variabel

Tahun	Kelompok	Provinsi	Variabel
2017	1	Aceh, Bali, Banten, Bengkulu, Jakarta Raya, Jawa Tengah, Jawa Timur, Kalimantan Barat, Maluku, Maluku Utara, Nusa Tenggara Timur, Nusa Tenggara Timur and Sulawesi Utara	X_3
	2	Bangka-Belitung, Kalimantan Timur, Riau, Sulawesi Barat, Sumatera Selatan, Sumatera Utara	X_1, X_2, X_5
	3	Gorontalo, Irian Jaya Barat, Jawa Barat, dan Kalimantan Selatan	X_2
	4	Jambi, Kalimantan Utara, Sulawesi Selatan, Sulawesi Tengah, dan Sulawesi Tenggara	X_2, X_5
	3	Kalimantan Tengah, Kepulauan Riau, Lampung, Papua, Sumatera Barat, dan Yogyakarta	X_1, X_3
2018	1	Aceh, Bali, Bangka-Belitung, Banten, Bengkulu, Jakarta Raya, Jambi, Jawa Barat, Jawa Tengah, Jawa Timur, Kalimantan Barat, Kalimantan Selatan, Kalimantan Tengah, Kepulauan Riau, Lampung, Riau, Sumatera Barat, Sumatera Selatan, Sumatera Utara, dan Yogyakarta	X_3
	2	Gorontalo, Maluku Utara, Maluku, Nusa Tenggara Timur, Sulawesi Barat, Sulawesi Selatan, Sulawesi Tengah, Sulawesi Tenggara, Sulawesi Utara, Irian Jaya Barat, dan Papua	X_2
	3	Kalimantan Timur, Kalimantan Utara, dan Nusa Tenggara Barat	X_2, X_3
2019	1	Aceh, Bangka-Belitung, Banten, Bengkulu, Jakarta Raya, Jambi, Jawa Barat, Jawa Tengah, Kepulauan Riau, Lampung, Riau, Sumatera Barat, Sumatera Selatan, Sumatera Utara, dan Yogyakarta	X_1, X_3
	2	Bali, Gorontalo, Kalimantan Selatan, Kalimantan Timur, Kalimantan Utara, Nusa Tenggara Barat, Sulawesi Barat, Sulawesi Tengah, Sulawesi Tenggara, Irian Jaya Barat, Maluku Utara, Maluku, dan Papua	X_2, X_3
	3	Jawa Timur, Kalimantan Barat, Kalimantan Tengah, dan Sulawesi Utara	X_3
	4	Nusa Tenggara Timur dan Sulawesi Selatan	X_2, X_3, X_7
2020	1	Aceh, Bengkulu, Jambi, Riau, Sumatera Barat, Sumatera Selatan, dan Sumatera Utara	X_1
	2	Bali, Kalimantan Selatan, Kalimantan Timur, Kalimantan Utara, dan Nusa Tenggara Barat	X_2, X_3, X_7
	3	Bangka-Belitung, Banten, Jakarta Raya, Jawa Barat, dan Lampung	X_1, X_2
	4	Gorontalo, Sulawesi Tenggara, Sulawesi Utara, Irian Jaya Barat, dan Papua	X_3
	5	Jawa Tengah, Jawa Timur, Kalimantan Barat, Kalimantan Tengah, Kepulauan Riau, dan Yogyakarta	X_1, X_2, X_3
	6	Maluku Utara dan Maluku	X_3, X_5, X_6
	7	Nusa Tenggara Timur, Sulawesi Barat, Sulawesi Selatan, dan Sulawesi Tengah	X_3, X_7

Tabel (4.20), yang menggunakan pembobot *Fixed Gaussian* pada tahun 2017, ditemukan 5 kelompok variabel independen yang signifikan. Kelompok pertama

terdiri dari variabel X_3 , kelompok kedua terdiri dari variabel X_1, X_2, X_5 , kelompok ketiga terdiri dari variabel X_2 , kelompok keempat terdiri dari variabel X_2, X_5 , dan kelompok kelima terdiri dari variabel X_1, X_3 . Pada tahun 2018, terdapat 3 kelompok variabel signifikan, dengan kelompok pertama terdiri dari variabel X_3 , kelompok kedua terdiri dari variabel X_2 , dan kelompok ketiga terdiri dari variabel X_2, X_3 . Selanjutnya, pada tahun 2019, terdapat 4 kelompok variabel signifikan, dengan kelompok pertama terdiri dari variabel X_1, X_3 , kelompok kedua terdiri dari variabel X_2, X_3 , kelompok ketiga terdiri dari variabel X_3 , dan kelompok keempat terdiri dari variabel X_2, X_3, X_7 . Terakhir, pada tahun 2020, terdapat 7 kelompok variabel signifikan, dengan kelompok pertama terdiri dari variabel X_1 , kelompok kedua terdiri dari variabel X_2, X_3, X_7 , kelompok ketiga terdiri dari variabel X_1, X_2 , kelompok keempat terdiri dari variabel X_3 , kelompok kelima terdiri dari variabel X_1, X_2, X_3 , kelompok keenam terdiri dari variabel X_3, X_5, X_6 , dan kelompok ketujuh terdiri dari variabel X_3, X_7 .



UIN SUNAN AMPEL
S U R A B A Y A

Tabel 4.21 Pengelompokan Provinsi Model GTWR *Fixed Bisquare* Berdasarkan Signifikansi Variabel

Tahun	Kelompok	Provinsi	Variabel
2017	1	Aceh, Bangka-Belitung, Banten, Bengkulu, Jakarta Raya, Jambi, Jawa Barat, Lampung, Riau, Sumatera Barat, Sumatera Selatan, dan Sumatera Utara	X_3, X_6
	2	Bali, Gorontalo, Irian Jaya Barat, Jawa Tengah, Jawa Timur, Kalimantan Barat, Kalimantan Selatan, Kalimantan Tengah, Kalimantan Timur, Kalimantan Utara, Maluku Utara, Maluku, Nusa Tenggara Barat, Nusa Tenggara Timur, Riau, Papua, Sulawesi Barat, Sulawesi Selatan, Sulawesi Tengah, Sulawesi Tenggara, Sulawesi Utara, dan Yogyakarta	X_1, X_3
	5	Kepulauan Riau	X_1, X_3, X_6
2018	1	Aceh, Riau, Sumatera Barat, dan Sumatera Utara	X_3, X_6
	2	Bali, Gorontalo, Irian Jaya Barat, Jawa Timur, Kalimantan Barat, Kalimantan Selatan, Kalimantan Tengah, Kalimantan Timur, Kalimantan Utara, Maluku Utara, Maluku, Nusa Tenggara Barat, Nusa Tenggara Timur, Papua, Sulawesi Barat, Sulawesi Selatan, Sulawesi Tengah, Sulawesi Tenggara, dan Sulawesi Utara	X_1, X_3
	3	Bangka-Belitung, Banten, Bengkulu, Jakarta Raya, Jambi, Jawa Barat, Jawa Tengah, Kepulauan Riau, Lampung, Sumatera Selatan, dan Yogyakarta	X_3
2019	1	Bali, Gorontalo, Irian Jaya Barat, Kalimantan Selatan, Kalimantan Tengah, Kalimantan Timur, Kalimantan Utara, Maluku Utara, Maluku, Nusa Tenggara Barat, Nusa Tenggara Timur, Papua, Sulawesi Barat, Sulawesi Selatan, Sulawesi Tengah, Sulawesi Tenggara, dan Sulawesi Utara	X_1, X_3
	2	Bangka-Belitung, Banten, Jakarta Raya, Lampung, Sumatera Selatan, Bengkulu, Jambi, Riau, Sumatera Barat, dan Sumatera Utara	X_2
	3	Jawa Barat, Jawa Tengah, Jawa Timur, Kalimantan Barat, Kepulauan Riau, dan Yogyakarta	X_1
	4	Aceh	X_2, X_3
2020	1	Aceh dan Sumatera Utara	X_1, X_2, X_3
	2	Bali, Gorontalo, Irian Jaya Barat, Jawa Tengah, Jawa Timur, Kalimantan Barat, Kalimantan Selatan, Kalimantan Tengah, Kalimantan Timur, Kalimantan Utara, Maluku Utara, Maluku, Nusa Tenggara Barat, Nusa Tenggara Timur, Papua, Sulawesi Barat, Sulawesi Selatan, Sulawesi Tengah, Sulawesi Tenggara, Sulawesi Utara, dan Yogyakarta	X_1, X_3
	3	Bangka-Belitung, Banten, Jakarta Raya, Jawa Barat, Kepulauan Riau, Lampung, dan Sumatera Selatan	X_1
	4	Bengkulu, Jambi, Riau, dan Sumatera Barat	X_1, X_2

Pada **Tabel (4.21)**, yang menggunakan pembobot *Fixed Bisquare* pada tahun 2017, ditemukan 3 kelompok model. Kelompok pertama terdiri dari satu variabel independen yang signifikan yaitu X_3, X_6 , kelompok kedua terdiri dari variabel X_1, X_3 yang signifikan, dan model ketiga terdiri dari satu variabel signifikan yaitu X_1, X_3, X_6 . Pada tahun 2018, terdapat 3 kelompok model, dengan kelompok pertama terdiri dari variabel X_3, X_6 yang signifikan, kelompok kedua

terdiri dari variabel X_1, X_3 yang signifikan, dan kelompok ketiga hanya terdiri dari variabel X_3 yang signifikan. Selanjutnya, pada tahun 2019, terdapat 3 kelompok model. Kelompok pertama terdiri dari variabel X_1, X_3 yang signifikan, kelompok kedua terdiri dari variabel X_2 yang signifikan, dan kelompok ketiga hanya terdiri dari variabel X_1 yang signifikan. Terakhir, pada tahun 2020, terdapat 4 kelompok model. Kelompok pertama terdiri dari tiga variabel yang signifikan yaitu X_1, X_2, X_3 , kelompok kedua terdiri dari variabel X_1, X_3 yang signifikan, kelompok ketiga terdiri dari variabel X_1 yang signifikan, dan kelompok keempat terdiri dari variabel X_1, X_2 yang signifikan.

4.13. Perbandingan Kebaikan Model GTWR (*Geographically and Temporally Weighted Regression*)

Untuk memilih model terbaik yang sesuai dengan data sebenarnya, dilakukan perbandingan antara jenis fungsi pembobot pada model GTWR (*Geographically and Temporally Weighted Regression*). Pemilihan model terbaik didasarkan pada nilai *Akaike Information Criterion* (AIC) dan nilai R^2 . Tujuan dari perbandingan ini adalah untuk menentukan model yang paling baik dan akurat dalam menjelaskan hubungan antara variabel-variabel yang dipelajari di setiap lokasi geografis. **Tabel (4.22)** menunjukkan hasil nilai perbandingan model.

Tabel 4.22 Perbandingan Kebaikan Model

Model	R^2	AIC
OLS	0.58504	653.092
GTWR <i>Fixed Gaussian</i>	0.7974	573.192
GTWR <i>Fixed Bisquare</i>	0.8785	606.8902

Perbandingan kualitas dari beberapa model dapat dilakukan dengan memperhatikan nilai AIC dan R^2 . Dalam penelitian ini, **Tabel (4.22)** menunjukkan bahwa model GTWR *Fixed Gaussian* dan GTWR *Fixed Bisquare* memiliki nilai AIC yang lebih rendah dibandingkan dengan regresi linear. Hal ini menunjukkan bahwa model GTWR memberikan estimasi yang lebih akurat dan mendekati keragaman pada data observasi.

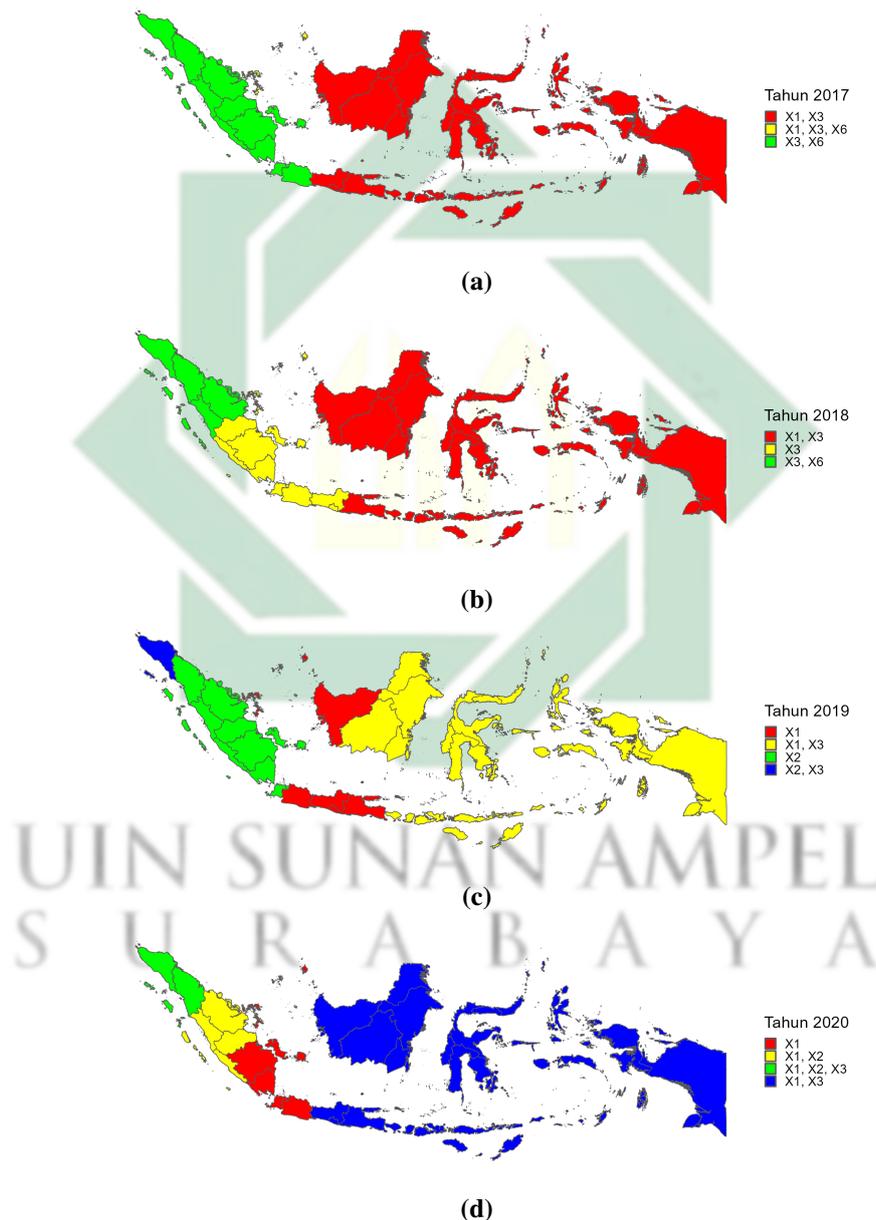
Kemudian nilai R^2 pada model GTWR juga tinggi, yaitu GTWR *Fixed Gaussian* sebesar 0.7974. Nilai R^2 tersebut mengindikasikan bahwa variabel independen dalam model GTWR *Fixed Gaussian* mampu menjelaskan sekitar 79.74% variasi dalam variabel dependen. Dengan kata lain, faktor-faktor seperti luas perkebunan kelapa sawit (X_1), PDRB pertambangan (X_2), luas hutan (X_3), jumlah produksi kayu bulat (X_4), jumlah penduduk (X_5), luas perkebunan kopi (X_6), dan persentase penduduk miskin (X_7) dapat menjelaskan sebagian besar variasi dalam data deforestasi sebesar 79.74%, sementara sisanya dipengaruhi oleh faktor lain yang tidak dimasukkan dalam model.

Selanjutnya, model GTWR *Fixed Bisquare* memiliki nilai R^2 sebesar 0.8785. Hal ini menunjukkan bahwa variabel independen yang dimasukkan ke dalam GTWR *Fixed Bisquare* dapat menjelaskan sebanyak 87.85% variasi dalam variabel dependen tersebut. Sisanya, variasi yang tidak dijelaskan oleh variabel independen dalam model disebabkan oleh faktor-faktor lain yang tidak termasuk dalam model.

4.14. Peta Variabel Signifikan Model GTWR

Variabel-variabel signifikan pada model GTWR dengan pembobot *Fixed Gaussian* dan *Fixed Bisquare* akan divisualisasikan dalam bentuk peta. Jika

kebaikan model dilihat dari R^2 tertinggi maka model GTWR *Fixed Bisquare* menjadi model terbaik, namun jika kebaikan model dilihat dari AIC terendah maka model GTWR *Fixed Gaussian* menjadi model terbaik. Berikut Visualisasi dari R^2 tertinggi yaitu model GTWR *Fixed Bisquare*.



Gambar 4.14 Peta Variabel Signifikan model GTWR *Fixed Bisquare* tahun 2017-2020

Melihat **Gambar (4.14)**, tahun 2017, terdapat 3 kelompok dengan model

yang berbeda. Pada kelompok pertama, model dipengaruhi oleh dua variabel independen yang signifikan, yaitu luas hutan (X_3) dan luas perkebunan kopi (X_6). Pada kelompok kedua, variabel yang signifikan adalah luas perkebunan kelapa sawit (X_1) dan luas hutan (X_3). Pada kelompok ketiga, model hanya memiliki satu variabel yang signifikan, yaitu luas perkebunan kelapa sawit (X_1), luas hutan (X_3), dan luas perkebunan kopi (X_6).

Pada tahun 2018, pada kelompok pertama variabel yang signifikan adalah luas hutan (X_3) dan luas perkebunan kopi (X_6). Pada kelompok kedua, variabel yang signifikan adalah luas perkebunan kelapa sawit (X_1) dan luas hutan (X_3). Pada kelompok ketiga, hanya variabel luas hutan (X_3) yang signifikan.

Selanjutnya, pada tahun 2019, pada kelompok pertama variabel yang signifikan adalah luas perkebunan kelapa sawit (X_1) dan luas hutan (X_3). Pada kelompok kedua, variabel yang signifikan adalah PDRB pertambahan (X_2). Pada kelompok ketiga, variabel yang signifikan adalah luas perkebunan kelapa sawit (X_1).

Terakhir, pada tahun 2020, terdapat 4 kelompok. Pada kelompok pertama, tiga variabel yang signifikan adalah luas perkebunan kelapa sawit (X_1), PDRB pertambahan (X_2), dan luas hutan (X_3). Pada kelompok kedua, variabel yang signifikan adalah luas perkebunan kelapa sawit (X_1) dan luas hutan (X_3). Pada kelompok ketiga, variabel yang signifikan adalah luas perkebunan kelapa sawit (X_1). Pada kelompok keempat, variabel yang signifikan adalah luas perkebunan kelapa sawit (X_1) dan PDRB pertambahan (X_2).

Dalam rentang waktu dari tahun 2017 hingga 2020, terdapat kecenderungan dominasi variabel signifikan yang terdiri dari X_1 , X_2 , X_3 , dan X_6 . Variabel-variabel ini secara konsisten mempengaruhi tingkat deforestasi dalam

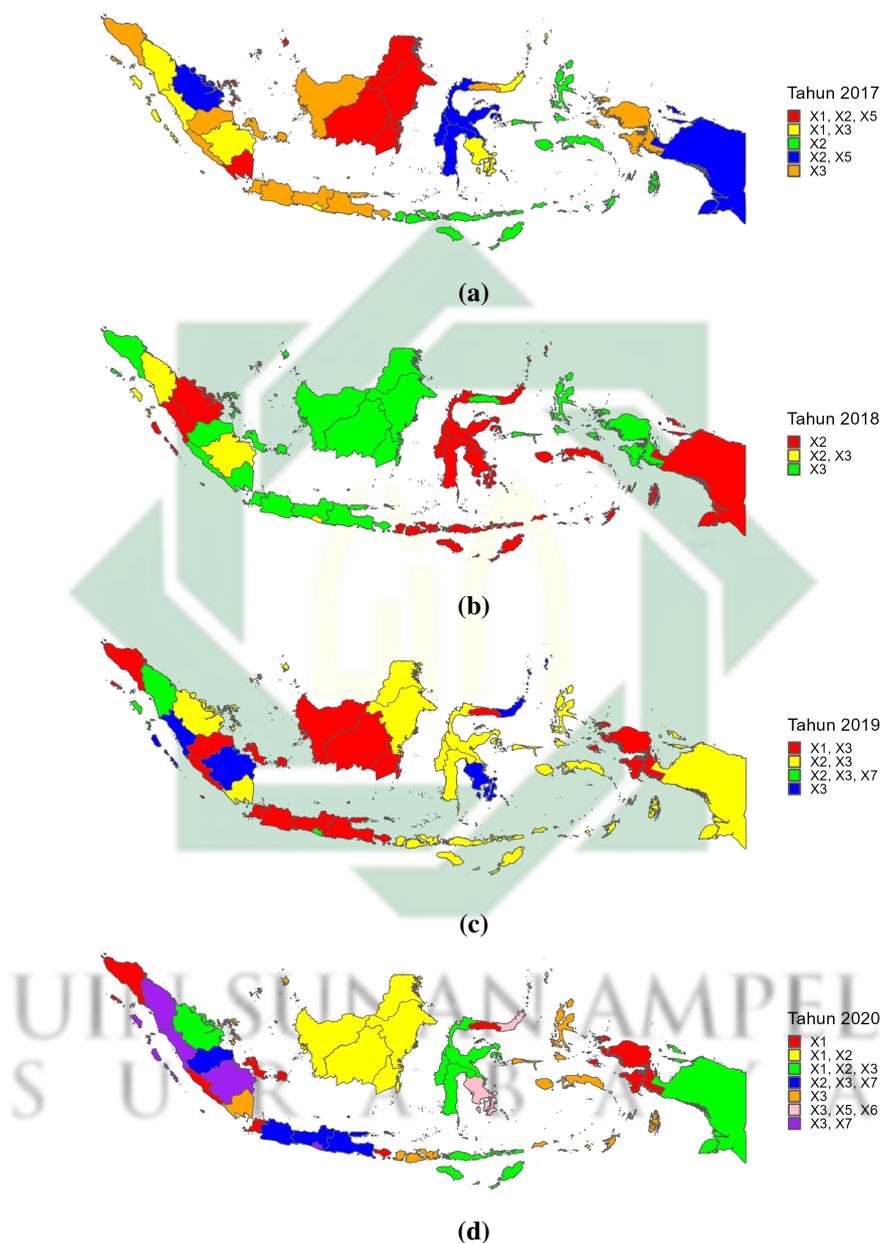
analisis model GTWR *Fixed Bisquare*. Selama periode tersebut, variabel luas perkebunan kelapa sawit (X_1) menjadi salah satu variabel yang signifikan dalam hampir setiap tahun dan kelompok. Hal ini menunjukkan bahwa perubahan dalam luas perkebunan kelapa sawit memiliki dampak yang signifikan terhadap tingkat deforestasi yang diamati. Penambahan atau pengurangan luas perkebunan kelapa sawit dapat berkontribusi pada perubahan tingkat deforestasi.

Selanjutnya, variabel PDRB pertambangan (X_2) juga merupakan variabel yang signifikan dalam beberapa tahun dan kelompok. Hal ini menandakan bahwa perubahan dalam PDRB pertambangan dapat berpengaruh terhadap tingkat deforestasi. Peningkatan atau penurunan PDRB pertambangan dapat berdampak pada tingkat deforestasi yang teramati. Variabel luas hutan (X_3) juga secara konsisten signifikan dalam rentang waktu tersebut. Perubahan dalam luas hutan memiliki hubungan yang signifikan dengan tingkat deforestasi. Pengurangan luas hutan dapat berkontribusi pada peningkatan tingkat deforestasi. Terakhir, variabel luas perkebunan kopi (X_6) juga termasuk dalam variabel yang signifikan pada beberapa tahun dan kelompok. Perubahan dalam luas perkebunan kopi dapat berdampak pada tingkat deforestasi yang diamati.

UIN SUNAN AMPEL
S U R A B A Y A

Visualisasi kedua model dengan nilai AIC terendah yaitu model GTWR

Fixed Gaussian.



Gambar 4.15 Peta Variabel Signifikan model GTWR Fixed Gaussian tahun 2017-2020

Dalam **Gambar (4.15)**, menggunakan pembobot "Fixed Gaussian" pada tahun 2017, terdapat identifikasi 5 kelompok variabel independen yang signifikan. Kelompok pertama terdiri dari variabel luas perkebunan kelapa sawit (X_1),

kelompok kedua terdiri dari variabel PDRB pertambahan (X_2), luas hutan (X_3), dan jumlah penduduk (X_5), kelompok ketiga terdiri dari variabel luas perkebunan kopi (X_6), kelompok keempat terdiri dari variabel luas hutan (X_3) dan jumlah penduduk (X_5), dan kelompok kelima terdiri dari variabel luas perkebunan kelapa sawit (X_1) dan luas hutan (X_3).

Pada tahun 2018, terdapat identifikasi 3 kelompok variabel signifikan. Kelompok pertama terdiri dari variabel luas hutan (X_3), kelompok kedua terdiri dari variabel PDRB pertambahan (X_2), dan kelompok ketiga terdiri dari variabel PDRB pertambahan (X_2) dan luas hutan (X_3).

Selanjutnya, pada tahun 2019, terdapat identifikasi 4 kelompok variabel signifikan. Kelompok pertama terdiri dari variabel luas perkebunan kelapa sawit (X_1) dan luas hutan (X_3), kelompok kedua terdiri dari variabel PDRB pertambahan (X_2) dan luas hutan (X_3), kelompok ketiga terdiri dari variabel luas hutan (X_3), dan kelompok keempat terdiri dari variabel PDRB pertambahan (X_2), luas hutan (X_3), dan persentase penduduk miskin (X_7).

Terakhir, pada tahun 2020, terdapat identifikasi 7 kelompok variabel signifikan. Kelompok pertama terdiri dari variabel luas perkebunan kelapa sawit (X_1), kelompok kedua terdiri dari variabel PDRB pertambahan (X_2), luas hutan (X_3), dan persentase penduduk miskin (X_7), kelompok ketiga terdiri dari variabel luas perkebunan kelapa sawit (X_1) dan PDRB pertambahan (X_2), kelompok keempat terdiri dari variabel luas hutan (X_3), kelompok kelima terdiri dari variabel luas perkebunan kelapa sawit (X_1), PDRB pertambahan (X_2), dan luas hutan (X_3), kelompok keenam terdiri dari variabel luas hutan (X_3), luas perkebunan kopi (X_6), dan jumlah penduduk (X_5), dan kelompok ketujuh terdiri dari variabel luas hutan (X_3) dan persentase penduduk miskin (X_7).

Variabel yang secara konsisten muncul sebagai variabel yang paling dominan dalam masing-masing tahun. Pada tahun 2017, luas perkebunan kelapa sawit (X_1), luas hutan (X_3) menjadi variabel yang paling dominan karena muncul dalam tiga kelompok variabel signifikan. Hal ini menunjukkan bahwa luas hutan memiliki pengaruh yang kuat terhadap variabel dependen dalam konteks tersebut. Pada tahun 2018, luas hutan (X_3) juga tetap menjadi variabel yang paling dominan dengan muncul dalam dua kelompok variabel signifikan. Selanjutnya, pada tahun 2019 dan 2020, luas hutan (X_3) dan PDRB pertambangan (X_2) menjadi variabel yang paling dominan karena muncul dalam kelompok variabel signifikan pada kedua tahun tersebut.

Dengan demikian, luas perkebunan kelapa sawit (X_1), luas hutan (X_3) dan PDRB pertambangan (X_2) dapat dianggap sebagai variabel yang memiliki pengaruh yang paling dominan dalam analisis ini. Variabel lainnya, seperti luas perkebunan kelapa sawit (X_1), jumlah penduduk (X_5), luas perkebunan kopi (X_6), dan persentase penduduk miskin (X_7), juga memiliki kontribusi yang signifikan terhadap variabel dependen, namun tidak sekuat pengaruh luas perkebunan kelapa sawit, luas hutan dan PDRB pertambangan.

4.15. Relevansi Keislaman Terhadap Hasil Analisis GTWR (*Geographically and Temporally Weighted Regression*)

Keberadaan dominasi variabel signifikan dalam hasil analisis GTWR menggunakan pembobot Fixed Bisquare yang terdiri dari luas perkebunan kelapa sawit (X_1), PDRB pertambangan (X_2), luas hutan (X_3), dan luas perkebunan kopi (X_6) dalam pengaruh terhadap kasus deforestasi di Indonesia menunjukkan relevansi keislaman yang penting.

Pertama, variabel X_1 dan X_6 yang mewakili luas perkebunan kelapa sawit dan kopi dapat dikaitkan dengan prinsip keberlanjutan dalam Islam. Dalam agama Islam, pemeliharaan lingkungan alam termasuk hutan dianggap sebagai tanggung jawab umat manusia. Dalam Al-Qur'an, surah Al-A'raf ayat 56 Allah berfirman:

وَلَا تُفْسِدُوا فِي الْأَرْضِ بَعْدَ إِصْلَاحِهَا وَادْعُوهُ خَوْفًا وَطَمَعًا إِنَّ رَحْمَتَ اللَّهِ قَرِيبٌ مِّنَ الْمُحْسِنِينَ ﴿٥٦﴾

Artinya : *"Janganlah kamu berbuat kerusakan di bumi setelah diatur dengan baik. Berdoalah kepada-Nya dengan rasa takut dan penuh harap. Sesungguhnya rahmat Allah sangat dekat dengan orang-orang yang berbuat baik."* (Q.S Al-A'raf (7) : 56)

Berdasarkan ayat di atas, ekspansi perkebunan kelapa sawit dan kopi yang tidak dikelola dengan baik dapat berkontribusi pada deforestasi. Perkebunan kelapa sawit yang dibuka di daerah hutan atau lahan gambut yang sensitif secara ekologis dapat mengakibatkan kerusakan habitat dan hilangnya hutan alami. Oleh karena itu, penting untuk melestarikan dan melakukan penanaman pohon sebagai bentuk kebaikan.

Kemudian, variabel X_2 yang mewakili PDRB pertambangan dapat dihubungkan dengan prinsip keadilan dalam Islam. Keadilan sosial dan pemerataan ekonomi adalah prinsip penting dalam ajaran Islam. Dalam Al-Qur'an, Allah SWT berfirman dalam Surah Al-Hadid ayat 25.

لَقَدْ أَرْسَلْنَا رُسُلَنَا بِالْبَيِّنَاتِ وَأَنْزَلْنَا مَعَهُمُ الْكِتَابَ وَالْمِيزَانَ لِيَقُومَ النَّاسُ بِالْقِسْطِ
 وَأَنْزَلْنَا الْحَدِيدَ فِيهِ بَأْسٌ شَدِيدٌ وَمَنَافِعُ لِلنَّاسِ وَلِيَعْلَمَ اللَّهُ مَن يَنْصُرُهُ وَرُسُلَهُ بِالْغَيْبِ
 إِنَّ اللَّهَ قَوِيٌّ عَزِيزٌ ﴿١٥﴾

Artinya : ”Sungguh, Kami benar-benar telah mengutus rasul-rasul Kami dengan bukti-bukti yang nyata dan Kami menurunkan bersama mereka kitab dan neraca (keadilan) agar manusia dapat berlaku adil. Kami menurunkan besi yang mempunyai kekuatan hebat dan berbagai manfaat bagi manusia agar Allah mengetahui siapa yang menolong (agama)-Nya dan rasul-rasul-Nya walaupun (Allah) tidak dilihatnya. Sesungguhnya Allah Maha Kuat lagi Maha Perkasa.” (Q.S Al-Hadid (57) : 25)

Prinsip keadilan dalam surah Al-Hadid (57:25) menekankan pentingnya menghindari eksploitasi yang tidak adil terhadap sumber daya alam dan manusia. Dalam konteks PDRB pertambangan, implementasi prinsip keadilan dapat mencakup redistribusi keuntungan dan manfaat ekonomi yang diperoleh dari sektor pertambangan untuk memastikan keadilan dalam distribusi kekayaan dan pemerataan ekonomi bagi seluruh masyarakat, termasuk masyarakat lokal yang terdampak langsung oleh kegiatan pertambangan. Eksploitasi yang tidak bertanggung jawab dan berlebihan dapat merusak alam, terutama hutan, sehingga dapat menyebabkan deforestasi.

Selanjutnya, variabel X_3 yang mewakili luas hutan juga memiliki relevansi keislaman. Dalam Islam, hutan dianggap sebagai anugerah Allah yang harus dijaga dan dilestarikan. Sabda Nabi Muhammad SAW:

عَنْ أَنَسِ بْنِ مَالِكٍ قَالَ : قَالَ رَسُولُ اللَّهِ صَلَّى اللَّهُ عَلَيْهِ وَسَلَّمَ : (إِنْ قَامَتِ السَّاعَةُ
وَفِي يَدِ أَحَدِكُمْ فَسِيلَةٌ ، فَإِنْ اسْتَطَاعَ أَنْ لَا تَقُومَ حَتَّى يَغْرِسَهَا فَلْيَغْرِسْهَا)

روى أحمد (12902) ، والبخاري في "الأدب المفرد" (479)

Artinya : "Dari Anas bin Malik, Rasulullah Saw bersabda : "Jika Hari Kiamat tiba dan salah satu dari kalian memiliki pohon muda di tangannya, maka jika ia mampu sebelum terjadi hari kiamat untuk menanamnya, maka biarkan dia menanamnya" (HR. Ahmad (12902) & Al-Bukhari dalam "Al-Adab Al-Mufrad" (479))

Hadis ini mengingatkan akan tanggung jawab untuk menjaga kelestarian hutan dan membatasi tindakan yang dapat merusak hutan secara tidak terkendali. Islam mendorong penggunaan sumber daya alam, termasuk hutan, dengan bijaksana agar tetap berkelanjutan dan memberikan manfaat bagi kehidupan manusia serta generasi mendatang. Deforestasi, yang merupakan hilangnya luas hutan secara signifikan, bertentangan dengan prinsip keberlanjutan dan tanggung jawab manusia terhadap lingkungan yang diajarkan dalam Islam.

Dalam kaidah fikih disebutkan:

مَا لَا يَتِمُّ الْوَجِبُ إِلَّا بِهِ فَهُوَ وَاجِبٌ

Artinya : "Sesuatu yang membawa kepada kewajiban, maka itu hukumnya wajib."

Hukum menjaga lingkungan adalah wajib, sebagaimana yang dijelaskan oleh Yusuf Qardhawi dalam bukunya "Ri'ayah al-Bi'ah fiy Syari'ah al-Islam", bahwa memelihara lingkungan sama halnya dengan menjaga lima tujuan dasar

Islam (*maqashid al-syari'ah*). Sebab, kelima tujuan dasar tersebut bisa terwujud jika lingkungan dan alam semesta mendukungnya. Jika deforestasi merupakan tindakan yang merugikan maka reboisasi menjadi wajib sebab dapat memberikan manfaat yang besar bagi kehidupan. Oleh karena itu, memelihara lingkungan memiliki hukum yang sama dengan *maqashid al-syari'ah* (Ridwan, 2001).



UIN SUNAN AMPEL
S U R A B A Y A

BAB V

PENUTUP

5.1. Kesimpulan

Berdasarkan analisis yang telah dilakukan dalam memodelkan kasus deforestasi menggunakan metode GTWR (*Geographically and Temporally Weighted Regression*) dengan menggunakan tujuh variabel yang diduga menjadi penyebab kasus deforestasi di Indonesia tahun 2017 hingga 2020 dapat disimpulkan sebagai berikut :

1. Pemodelan kasus deforestasi di Indonesia tahun 2017-2020 dengan metode GTWR dibutuhkan parameter-parameter pembangun model diantaranya parameter τ , parameter spasial λ , parameter temporal μ , *bandwidth* spasial-temporal, jarak spasial-temporal d_{ij}^{ST} yang kemudian digunakan untuk membangun matriks pembobot menggunakan fungsi pembobot *Fixed Gaussian* dan *Fixed Bisquare*. Selanjutnya dilakukan estimasi parameter berdasarkan Persamaan (2.26), sebagai contoh berikut model GTWR *Fixed Bisquare* untuk daerah Aceh tahun 2020 dengan variabel yang signifikan.

$$\hat{Y}_{\text{bisquare}}^{\text{Aceh}} = -8.43550 - 11.5690x_1 - 4.5591x_2 + -9.2746x_3$$

2. Pemodelan dengan metode GTWR (*Geographically and Temporally Weighted Regression*) menghasilkan variabel yang signifikan untuk setiap lokasi, kemudian variabel-variabel tersebut dikelompokkan dan

divisualisasikan dalam bentuk peta. Pada model GTWR dengan metode *Fixed Gaussian* untuk kasus deforestasi di Indonesia, dilakukan pengelompokan berdasarkan variabel yang signifikan pada tahun 2017, didapatkan 5 kelompok. Pada tahun 2018, terdapat 3 kelompok. Pada tahun 2019, terdapat 4 kelompok. Dan pada tahun 2020, terdapat 7 kelompok. Variabel-variabel signifikan yang mendominasi dalam pengelompokan tersebut adalah luas perkebunan kelapa sawit (X_1), PDRB pertambangan (X_2), luas hutan (X_3), jumlah populasi/penduduk (X_5), jumlah produksi kayu bulat (X_6), dan luas perkebunan kopi (X_7). Pada model GTWR dengan metode *Fixed Bisquare* untuk kasus deforestasi di Indonesia, dilakukan pengelompokan berdasarkan variabel yang signifikan pada tahun 2017, didapatkan 3 kelompok. Pada tahun 2018, terdapat 3 kelompok. Pada tahun 2019, terdapat 4 kelompok. Dan pada tahun 2020, terdapat 4 kelompok. Variabel-variabel signifikan yang mendominasi dalam pengelompokan tersebut adalah luas perkebunan kelapa sawit (X_1), PDRB pertambangan (X_2), luas hutan (X_3), dan luas perkebunan kopi (X_6).

3. Dalam memodelkan kasus deforestasi di Indonesia pada tahun 2017-2020, metode GTWR dengan pembobot *Fixed Gaussian* dan pembobot *Fixed Bisquare* memberikan hasil yang lebih akurat dibandingkan dengan metode regresi linier. Hal ini dapat dilihat dari peningkatan nilai R^2 pada model GTWR *Fixed Gaussian* sebesar 79.74% dan R^2 pada model GTWR *Fixed Bisquare* sebesar 87.85%. Selain itu, nilai AIC (Akaike Information Criterion) juga dapat digunakan untuk membandingkan kualitas model, dimana nilai AIC yang lebih rendah menunjukkan model yang lebih baik. Dalam kasus ini, model GTWR dengan pembobot *Fixed Gaussian* memiliki

nilai AIC sebesar 573.192, sedangkan model GTWR dengan pembobot *Fixed Bisquare* memiliki nilai AIC sebesar 606.8902. Hal ini menunjukkan bahwa model GTWR *Fixed Gaussian* memiliki kualitas yang lebih baik dibandingkan dengan model GTWR *Fixed Bisquare*, karena memiliki nilai AIC yang lebih rendah.

5.2. Saran

GTWR (*Geographically and Temporally Weighted Regression*) menggunakan operator sederhana, yaitu penjumlahan, untuk mengukur jarak spasial-temporal. Operator ini digunakan untuk menggabungkan jarak spasial dan jarak temporal secara linear sebagai berikut.

$$d_{ij}^{ST} = d_S^2 \oplus d_T^2 = \lambda d_S^2 + \mu d_T^2$$

λ dan μ adalah bobot untuk menyeimbangkan efek yang berbeda dikarenakan jarak ruang dan waktu diukur menggunakan satuan yang berbeda. Spesifikasi tersebut mengimplikasikan bahwa sistem koordinat spasial-temporal memiliki sifat tegak lurus, yang berarti jarak yang diukur dalam dimensi ruang tidak memiliki pengaruh terhadap jarak temporal. Oleh karena itu, spesifikasi tersebut menyiratkan bahwa metode yang menggunakan kombinasi linier antara jarak spasial dan jarak temporal mungkin tidak cocok untuk memodelkan interaksi spasial-temporal dengan baik. Untuk itu disarankan kedepannya perlu didefinisikan operator yang lebih kompleks sebagai penyusun model Interaksi GTWR (*Geographically and*

Temporally Weighted Regression) sebagai berikut (Wu et al., 2014).

$$d_{ij}^{ST} = \begin{cases} d_S^2 \oplus d_T^2 = \lambda d_{ij}^S + \mu d_{ij}^T + 2\sqrt{\lambda\mu} d_{ij}^S d_{ij}^T \cos(\xi) & , j_i \leq t_i \\ d_{ij}^{ST} = \infty & , j_i > t_i \end{cases}$$



UIN SUNAN AMPEL
S U R A B A Y A

DAFTAR PUSTAKA

- Adiningrum, T. Z., Prahutama, A., and Santoso, R. (2018). Pemodelan Deforestasi Hutan Lindung Di Indonesia Menggunakan Model Geographically and Temporally Weighted Regression (Gtwr). *Jurnal Gaussian*, 7(3):314–325.
- Adrianto, H. A., Spracklen, D. V., Arnold, S. R., Sitanggang, I. S., and Syaufina, L. (2020). Forest and land fires are mainly associated with deforestation in Riau Province, Indonesia. *Remote Sensing*, 12(1):1–12.
- Ahmed, A. D., Abdulwahhab, B. I., and Abdulah, E. K. (2021). Estimation of the Parameters of Mixed Frechet Distribution and Its Employment in Simple Linear Regression. *Turkish Journal of Computer and Mathematics Education*, 12(10):5077–5081.
- Algifari (1997). *Analisis Statistik untuk Bisnis dengan Regresi, Korelasi dan Nonparametrik*. Yogyakarta : BPF, 1 edition.
- An-Nabhani, Syaikh; Abdul Rouf, M. H. A. L. M. M. L. M. Y. A. (2014). *Ringkasan Riyadhush Shalihini : Abu Zakaria Yahya bin Syaraf bin Hasan bin Husain AN-Nawawi (Imam An-Nawawi) / Syaikh An-Nabhani*. Depok :: Keira Publishing.
- Ardhana, I. P. G. (2016). Dampak Laju Deforestasi Terhadap Hilangnya Keanekaragaman Hayati Di Indonesia. *Journal of Biological Sciences*, 129(2):120–129.
- Astuti, P., Debatara, N. N., and Sulistianingsih, E. (2018). Analisis Kemiskinan dengan Pemodelan Geographically Weighted Regression (GWR) di Provinsi

- Nusa Tenggara Timur. *Buletin Ilmiah Matematika Statistika dan Terapannya*, 7(3):169–176.
- Ayuningtyas, D. (2022). Degradasi dan Deforestasi Hutan di Kalimantan Timur. 1(September 12):1–12.
- Azkie, Q. and Setiawan, E. P. (2022). Pemodelan Gizi Buruk pada Balita di Provinsi Jawa Timur Menggunakan Geographically Weighted Regression (GWR). *Proceedings of the National Seminar on Mathematics, Statistics, and Its Applications*, pages 302–311.
- Bai, D., Dong, Q., Khan, S. A. R., Li, J., Wang, D., Chen, Y., and Wu, J. (2022). Spatio-temporal heterogeneity of logistics CO₂ emissions and their influencing factors in China: An analysis based on spatial error model and geographically and temporally weighted regression model. *Environmental Technology and Innovation*, 28:102791.
- Bilhaq, M. A. M. (2022). Perihal Deforestasi Di Indonesia Dalam Tinjauan Al-Qur'an Dan Hadis. 8(1):90–123.
- Conita and Purwaningsih, T. (2018). Under-Five Mortality Rate Modeling Using Geographically and Under-Five Mortality Rate Modeling Using Geographically and Temporal Weighted Regression (Gtwr) in Central Java. *Ahmad Dahlan International Conference on Mathematics and Mathematics Education Universitas Ahmad Dahlan*, (February):13–14.
- Damayanti, A. H. and Agustin Nuriani Sirodj, D. (2022). Pemodelan Geographically Weighted Regression dengan Fungsi Pembobot Fixed Gaussian Kernel untuk Kasus Tingkat Partisipasi Angkatan Kerja Wanita di Provinsi Aceh. *Bandung Conference Series: Statistics*, 2(2):291–298.

- Debataraja, N., Kusnandar, D., Mahalalita, R., and Imro'ah, N. (2021). Penerapan Model Geographically Dan Temporally Weighted Regression Pada Kecelakaan Lalu Lintas. *Jurnal Siger Matematika*, 2(1):19–24.
- Fotheringham, A. S., Lu, B., Charlton, M., and Harris, P. (2014). Geographically weighted regression with a non-Euclidean distance metric: A case study using hedonic house price data. *International Journal of Geographical Information Science*, 28(4):660–681.
- Greenpeace, I. (2019). Indonesia: Annual Deforestation Rates Increase Again.
- Gunarso, P., Hartoyo, M. E., Agus, F., and Killeen, T. J. (2013). Oil Palm and Land Use Change in Indonesia , Malaysia and Papua New Guinea. *Reports from the Technical Panels of RSPOs 2nd Greenhouse Gas Working Group*, pages 29–64.
- Harianto, Nugroho, W. H., and Sumarminingsih, E. (2021). Geographically and Temporally Weighted Regression Model with Gaussian Kernel Weighted Function and Bisquare Kernel Weighted Function. *IOP Conference Series: Materials Science and Engineering*, 1115(1):012063.
- Hong, Z., Mei, C., Wang, H., and Du, W. (2021). Spatiotemporal effects of climate factors on childhood hand, foot, and mouth disease: a case study using mixed geographically and temporally weighted regression models. *International Journal of Geographical Information Science*, 35(8):1611–1633.
- Hu, X. (2022). Tax Competition , Spatial Effect , and Environmental Pollution : An Empirical Analysis of the GTWR Model Abstract :. *The International Journal Of Business & Management*, 10(8):183–193.
- Irawan, R. C., Nugraha, A. L., and Firdaus, H. S. (2020). Analisis Tingkat

- Kekumuhan pada Permukiman menggunakan Model Geographically Weighted Regression (GWR) (Studi Kasus : Kota Surakarta, Jawa Tengah). *Jurnal Geodesi Undip*, 9(2):145–154.
- Jamaludin, J., De Alban, J. D. T., Carrasco, L. R., and Webb, E. L. (2022). Spatiotemporal analysis of deforestation patterns and drivers reveals emergent threats to tropical forest landscapes. *Environmental Research Letters*, 17(5).
- Kalang, L. and Eboy, O. V. (2021). Penggunaan analisis ruang dalam penyelidikan pandemik covid-19: satu tinjauan. *Jurnal Kinabalu*, 27(1):151–165.
- Kamaliah, N. (2022). Pelatihan Distance Learning: Strategi Pembelajaran Analisis Data Kuantitatif bagi Peserta Kelas Sosial. *JIRA: Jurnal Inovasi dan Riset Akademik*, 3(1):62–70.
- Khoeriyah, R. Y. and Hajarisman, N. (2021). Regresi Terboboti Geografis Semiparametrik (RTG-S) untuk Pemodelan Indeks Pembangunan Kesehatan Masyarakat Kabupaten/Kota di Sumatera Utara. *Jurnal Riset Statistika*, 1(1):43–50.
- KLHK (2020). Status Lingkungan Hidup dan Kehutanan 2020. pages 14–50.
- Koç, T. (2022). Bandwidth Selection in Geographically Weighted Regression Models via Information Complexity Criteria. *Journal of Mathematics*, 2022(Cv).
- Kopczewska, K. and Ćwiakowski, P. (2021). Spatio-temporal stability of housing submarkets. Tracking spatial location of clusters of geographically weighted regression estimates of price determinants. *Land Use Policy*, 103(October 2020).
- Kurkcuoglu, M. A. S. (2022). Analysis of the Energy Justice in Natural Gas

- Distribution with Geographically Weighted Regression. *Energy Reports*, 9:325–337.
- Liao, X., Fang, C., Shu, T., and Ren, Y. (2023). Spatiotemporal impacts of urban structure upon urban land-use efficiency : Evidence from 280 cities in China. *Habitat International*, 131(November 2022):102727.
- Liu, Q., Wu, R., Zhang, W., Li, W., and Wang, S. (2020). The varying driving forces of PM2.5 concentrations in Chinese cities: Insights from a geographically and temporally weighted regression model. *Environment International*, 145(March):106168.
- Lutfiani, N., Mariani, S., and Sugiman (2019). Pemodelan Geographically Weighted Regression (GWR) dengan Fungsi Pembobot Kernel Gaussian dan Bi-square. *UNNES Journal of Mathematics*, 5(1):82–91.
- Ma, X., Zhang, J., Ding, C., and Wang, Y. (2018). A geographically and temporally weighted regression model to explore the spatiotemporal influence of built environment on transit ridership. *Computers, Environment and Urban Systems*, 70(December 2017):113–124.
- Mangka, A., Amrah Husma, and Jahada Mangka (2022). Pelestarian Lingkungan Hidup dalam Pandangan Syariat Islam. *BUSTANUL FUQAHA: Jurnal Bidang Hukum Islam*, 3(2):205–221.
- Mardiatmoko, G. (2020). Pentingnya Uji Asumsi Klasik Pada Analisis Regresi Linier Berganda. *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, 14(3):333–342.
- Marizal, M. and Atiqah, H. (2022). Pemodelan Indeks Pembangunan Manusia di

- Indonesia dengan Geographically Weighted Regression (GWR). *Jurnal Sains Matematika dan Statistika*, 8(2):133.
- Mawitjere, P. M., Tulung, J. E., and Wangke, S. J. C. (2022). The Effect Of Customer Satisfaction On Repeat Purcuse Intention (Case Study; Dishwangshing Soap In Sub-District Poigar). *Jurnal EMBA*, 10(1):1–10.
- Miettinen, J., Shi, C., and Liew, S. C. (2019). Deforestation rates in insular Southeast Asia between 2000 and 2010. *Global Change Biology*, 17(7):2261–2270.
- Nisa, R. F., Sugito, S., and Hakim, A. R. (2022). Pemodelan Mixed Geographically Weighted Regression Dengan Adaptive Bandwidth Untuk Angka Harapan Hidup (Studi Kasus : Angka Harapan Hidup di Jawa Tengah). *Jurnal Gaussian*, 11(1):67–76.
- Nordiansyah, M., Meiditasari, C. N., Fatimah, F., Saprudin, S., and Juniar, A. (2022). Peranan Intensitas Modal , Ukuran Perusahaan , Komisarisi Independen dan Leverage Pada Agresivitas Pajak. *YUME : Journal of Management*, 5(3):310–319.
- Nurhalizah and Sitompul, P. (2022). Analysis of Ordinary Least Square and Geographically Weighted Regression on the Human Development Index of North Sumatra 2021 Analisis Ordinary Least Square dan Geographically Weighted Resgression pada Indeks Pembangunan Manusia Sumatera Utara. *Formosa Journal of Applied Sciences (FJAS)*, 1(6):981–1000.
- Oshan, T. M., Li, Z., Kang, W., Wolf, L. J., and Stewart Fotheringham, A. (2019). MGWR: A python implementation of multiscale geographically

- weighted regression for investigating process spatial heterogeneity and scale. *ISPRS International Journal of Geo-Information*, 8(6).
- Pamungkas, R. A., Yasin, H., and Rahmawati, R. (2016). Perbandingan Model GWR dengan Fixed dan Adaptive Bandwidth Untuk Persentase Penduduk Miskin di Jawa Tengah. *Jurnal Gaussian*, 5(3):535–544.
- Pan, D., Xu, Z., Lu, X., Zhou, L., and Li, H. (2020). 3D scene and geological modeling using integrated multi-source spatial data: Methodology, challenges, and suggestions. *Tunnelling and Underground Space Technology*, 100(January 2019):103393.
- Pan, Y., Yuan, Q., Ma, J., and Wang, L. (2022). Improved Daily Spatial Precipitation Estimation by Merging Multi-Source Precipitation Data Based on the Geographically Weighted Regression Method: A Case Study of Taihu Lake Basin, China. *International Journal of Environmental Research and Public Health*, 19(21):13866.
- Permai, S. D., Christina, A., and Santoso Gunawan, A. A. (2021). Fiscal decentralization analysis that affect economic performance using geographically weighted regression (GWR). *Procedia Computer Science*, 179(2020):399–406.
- Poor, E. E., Frimpong, E., Imron, M. A., and Kelly, M. J. (2019). Protected area effectiveness in a sea of palm oil : A Sumatran case study. *Biological Conservation journal*, 234(March):123–130.
- Pradana, G. W., Djaing, H., Kurniawan, B., and Febriani, A. P. (2022). Implementation of REDD+ Policies in Indonesia to Reducing Deforestation Amid Rising Earth's Temperature. *IOP Conference Series: Earth and Environmental Science*, 1111(1).

- Purhadi, Sari, D. N., Aini, Q., and Irhamah (2021). Geographically weighted bivariate zero inflated generalized Poisson regression model and its application. *Heliyon*, 7(7):e07491.
- Putra, A. D. and Oktora, S. I. (2022). Spatial-Temporal Analysis of Deforestation in Sumatera Island 2011-2019. *Proceedings of The International Conference on Data Science and Official Statistics*, 2021(1):590–609.
- Putri, F. E., Mukhsar, Baharuddin, Abapihi, B., Ruslan, and Agusrawati (2022). Pemodelan Indeks Pembangunan Manusia di Indonesia dengan Geographically Weighted Regression (GWR). *Jurnal Sains Matematika dan Statistika*, 8(2):34–49.
- Rahmadhana, I. A. Z. and Utomo, A. P. (2022). Ketimpangan Pendapatan dan Determinan PDRB Per Kapita Kabupaten / Kota di Pulau Sulawesi Tahun 2017-2020 Pendekatan Geographically Weighted Panel Regression. *Seminar Nasional Official Statistics*, pages 823–832.
- Rahmi, M. M., Zurba, N., Islama, D., Lubis, F., Suriani, M., Marlian, N., Khairi, I., and Nasution, M. A. (2022). Mitigasi Perubahan Iklim Melalui Penanaman Mangrove Di Desa Lhok Bubon Kecamatan Samatiga Kabupaten Aceh Barat. 6(April):29–35.
- Ramadhan, I. N., Agusrawati, Mukhsar, Bhriddin, and Baharuddin (2022). Analisis Model Regresi Berganda Dan Geographically Weighted Regression Pada Jumlah Kendaraan Sepeda Motor. *Jurnal Matematika, Komputasi dan Statistika*, 2(1):1–7.
- Rath, S., Tripathy, A., and Tripathy, A. R. (2020). Prediction of new active cases of coronavirus disease (COVID-19) pandemic using multiple linear regression

- model. *Diabetes and Metabolic Syndrome: Clinical Research and Reviews*, 14(5):1467–1474.
- Rhamdhani, R., Akhbar, A., and Hasriani, H. (2020). Pemodelan Spasial Deforestasi Di Kesatuan Pengelolaan Hutan Lindung (KPHL) Unit VI Dolago Tanggunung Provinsi Sulawesi Tengah. *Mitra Sains*, (2000):104–120.
- Ridho, M. R., Widhanarto, G. O., and Muin, S. (2022). Estimasi Karbon Tersimpan Di Atas Permukaan Tanah Kawasan Hutan Produksi Dusun Sebaju Kecamatan Nanga Pinoh Wilayah Kph Kabupaten Melawi Muhammad. *Jurnal Lingkungan Hutan Tropis*, 1(April):332–345.
- Ridwan, M. (2001). *FIQH EKOLOGI Membangun Fiqh Ekologis Untuk Pelestarian Kosmos*. pages 77–88.
- Rifky Pontoh, M. and Alfu Ilmy, E. (2022). Peran Pekerjaan Layak dalam Upaya Pengentasan Kemiskinan di Indonesia: Pendekatan dengan Indikator Pekerjaan Tidak Tetap dan Analisis Regresi Linier Berganda (The Role of Decent Work in Poverty Reduction in Indonesia: Approach with Precarious Employment I. *dan Teknologi Informasi*, 01(01):40–51.
- Romadhoni, R., Yanti, R., and ... (2022). Analisis Faktor Hasil Produksi Kelapa Sawit Menggunakan Regresi Linier Berganda Studi Kasus: Koperasi Unit Desa (KUD) Setia Kawan Desa Koto Damai. *Formosa Journal of ...*, 1(4):217–234.
- Salsabila, A. H. and Nurwati, N. (2020). Deforestasi Dan Migrasi Penduduk Ke Ibu Kota Baru Kalimantan Timur: Peran Sinergis Pemerintah Dan Masyarakat. *Prosiding Penelitian dan Pengabdian kepada Masyarakat*, 7(1):27.
- Saputra, H. Y. and Radam, I. F. (2022). Accessibility model of BRT stop locations

- using Geographically Weighted regression (GWR): A case study in Banjarmasin, Indonesia. *International Journal of Transportation Science and Technology*.
- Sarathy, J. and Vadhan, S. (2022). Analyzing the Differentially Private Theil-Sen Estimator for Simple Linear Regression. *Proceedings of ACM Conference (Conference'17)*, 1(1).
- Sartika, E. (2020). Pemodelan Tingkat Pengangguran di Jawa Barat dengan Analisis Geographically Weighted Regression (GWR). *Jurnal Penelitian dan Gagasan Sains dan Matematika Terapan*, 12(12):30–43.
- Setiawan, C. J., Anthony, D., Asyifa, M. Z., and Izzati, W. A. (2021). Peran Budaya Hutan Larangan Adat Riau Sebagai Contoh Solusi Pelestarian Ekosistem Di Indonesia. *Jurnal Kewarganegaraan*, 5(2):768–773.
- Shewa, G. A. and Ugwuowo, F. I. (2023). A new hybrid estimator for linear regression model analysis : Computations and simulations. *Scientific African*, 19:e01441.
- Shihab, M. Q. (2007). *Secercah Cahaya Ilahi: Hidup Bersama Al-Quran*. Bandung: Mizan.
- Sholihin, M., Mohamad Soleh, A., and Djuraidah, A. (2017). Geographically and Temporally Weighted Regression (GTWR) for Modeling Economic Growth using R. *IJCSN -International Journal of Computer Science and Network*, 6(65):800–805.
- Sifriyani, Mandang, I., Amijaya, F. D. T., Sholihin, M., and Dani, A. T. R. (2022). a Spatio-Temporal Description of Covid-19 Cases in East Borneo Using Improved

- Geographically and Temporally Weighted Regression (I-Gtwr). *Communications in Mathematical Biology and Neuroscience*, 2022:1–22.
- Supuwingsih, N. N., Januhari, N. N. U., Suniantara, I. K. P., & Hanief, S. (2022). *Integrasi Data Spasial Dan Data Non Spasial Sistem Informasi Geografis*. Media Sains Indonesia.
- Sutro, Yundari, and Martha, S. (2020). Pemodelan Fixed Effect Geographically Weighted Panel Regression untuk Indeks Pembangunan Manusia di Kalimantan Barat. *Buletin Ilmiah Math. Stat. dan Terapannya (Bimaster)*, 09(3):413–422.
- Syahputra, I. D. and Karim, A. (2016). Perbandingan Metode Ordinary Least Square (OLS) dan Regresi Robust. *Seminar Nasional Pendidikan, Sains dan Teknologi Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Muhammadiyah Semarang*, pages 127–131.
- Triscowati, D. W., Bangun, R. H., and Haryanto, S. (2018). Spatial-temporal Kemiskinan di Pulau Jawa Menggunakan Geographically and Temporally Weighted Regression. (October 2019).
- Ulfie Safitri and Amaliana, L. (2021). Model Geographically Weighted Regression dengan Fungsi Pembobot Adaptive dan Fixed Kernel pada Kasus Kematian Ibu di Jawa Timur. *Jurnal Statistika dan Aplikasinya*, 5(2):208–220.
- Wang, X. (2022). Research on the prediction of per capita coal consumption based on the ARIMA–BP combined model. *Energy Reports*, 8:285–294.
- Wu, B., Li, R., and Huang, B. (2014). A geographically and temporally weighted autoregressive model with application to housing prices. *International Journal of Geographical Information Science*, 28(5):1186–1204.

- Xie, C., Yu, D., Lin, C., Zheng, X., and Peng, B. (2022). Exploring the Spatiotemporal Impacts of the Built Environment on Taxi Ridership Using Multisource Data. *Sustainability (Switzerland)*, 14(10).
- Yasin, H., Puhadi, P., and Choiruddin, A. (2022). Estimasi Parameter Dan Pengujian Hipotesis Model Geographically Weighted Generalized Gamma Regression. *Jurnal Gaussian*, 11(1):140–152.
- Zhang, Z., Li, J., Fung, T., Yu, H., Mei, C., Leung, Y., and Zhou, Y. (2021). Multiscale geographically and temporally weighted regression with a unilateral temporal weighting scheme and its application in the analysis of spatiotemporal characteristics of house prices in Beijing. *International Journal of Geographical Information Science*, 35(11):2262–2286.
- Zhou, Q., Wang, C., and Fang, S. (2019). Application of geographically weighted regression (GWR) in the analysis of the cause of haze pollution in China. *Atmospheric Pollution Research*, 10(3):835–846.
- Zou, C., Zhu, J., Lou, K., and Yang, L. (2022). Coupling coordination and spatiotemporal heterogeneity between urbanization and ecological environment in Shaanxi Province, China. *Ecological Indicators*, 141(May):109152.