

**PEMODELAN *GEOGRAPHICALLY WEIGHTED
REGRESSION* MENGGUNAKAN PEMBOBOT
KERNEL *FIXED* DAN *ADAPTIVE* PADA KASUS
TINGKAT PENGANGGURAN TERBUKA DI
INDONESIA**

SKRIPSI

Disusun untuk memenuhi salah satu syarat
memperoleh gelar Sarjana Matematika



Mila Rizki Ramadayani
1305617031

PROGRAM STUDI MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS NEGERI JAKARTA
2021

LEMBAR PERSETUJUAN HASIL SIDANG SKRIPSI
PEMODELAN *GEOGRAPHICALLY WEIGHTED REGRESSION*
MENGGUNAKAN PEMBOBOT KERNEL *FIXED* DAN *ADAPTIVE*
PADA KASUS TINGKAT PENGANGGURAN TERBUKA
DI INDONESIA

Nama : Mila Rizki Ramadayani
No. Registrasi : 1305617031

	Nama	Tanda Tangan	Tanggal
Penanggung Jawab			
Dekan	: <u>Prof. Dr. Muktiningsih N. M.Si.</u> NIP. 196405111989032001		07-02-2022
Wakil Penanggung Jawab			
Wakil Dekan I	: <u>Dr. Esmar Budi, S.Si., MT.</u> NIP. 197207281999031002		04-02-2022
Ketua	: <u>Dr. Lukita Ambarwati, S.Pd., M.Si.</u> NIP. 197210262001122001		02-02-2022
Sekretaris	: <u>Dr. Yudi Mahatma, M.Si.</u> NIP. 197610202008121001		29-12-2021
Penguji	: <u>Drs. Sudarwanto, M.Si., DEA</u> NIP. 196503251993031003		03-01-2022
Pembimbing I	: <u>Ir. Fariani Hermin Indiyah, MT.</u> NIP. 196002111987032001		07-01-2022
Pembimbing II	: <u>Ibnu Hadi, M.Si.</u> NIP. 198107182008011017		07-01-2022

Dinyatakan lulus ujian skripsi tanggal: 17 Desember 2021

SURAT PERNYATAAN KEASLIAN SKRIPSI

Saya yang bertanda tangan di bawah ini, mahasiswa Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Jakarta.

Nama : Mila Rizki Ramadayani

No. Registrasi : 1305617031

Program Studi : Matematika

Dengan ini menyatakan bahwa skripsi yang saya buat dengan judul "**Pemodelan Geographically Weighted Regression Menggunakan Pembobot Kernel Fixed dan Adaptive pada Kasus Tingkat Pengangguran Terbuka di Indonesia**" adalah

1. Dibuat sendiri, mengadopsi hasil kuliah, buku-buku, dan referensi acuan yang tertera di dalam referensi pada skripsi saya.
2. Bukan merupakan hasil duplikasi skripsi yang telah dipublikasikan atau pernah dipakai untuk mendapatkan gelar sarjana di Universitas lain kecuali pada bagian-bagian sumber informasi dicantumkan berdasarkan tata cara referensi yang semestinya.

Pernyataan ini dibuat dengan sesungguhnya dan saya bersedia menanggung segala akibat yang timbul jika pernyataan saya tidak benar.

Jakarta, 15 Oktober 2021



Mila Rizki Ramadayani

ABSTRACT

MILA RIZKI RAMADAYANI. *Geographically Weighted Regression Modelling Using Fixed and Adaptive Kernel Weighted in Cases of Unemployment Rate in Indonesia. Thesis, Mathematics Study Program, Faculty Mathematics and Natural Science, State University of Jakarta. October 2021.*

Unemployment Rate (UR) is an indicator for measuring the unemployment according to the concept of employment. Number of UR increased in the last year by 1.84% where August 2019 was at 5.23% and August 2020 to 7.07%, this is due to the impact of the Covid-19 pandemic in Indonesia. One of the analysis to find out the factors that affect TPT in Indonesia is by using multiple linear regression with the Ordinary Least Square (OLS) method. Research with the OLS method produces symptoms of heterokedasticity, indicating that Data has more information. Observation continues on checking the spatial aspects (location). Data type results show that research uses spatial data because it contains spatial heterogeneity Research with OLS methods produces symptoms of heterocedasticity, indicating that Data has more information. Observation continues on checking the spatial aspects (location). Data type results show that research uses spatial data, because it contains spatial heterogeneity. Data Spatial is data that contains location information (latitude, longitude) and descriptive information (attributes). Spatial data analysis using a point approach is by the Geographically Weighted Regression method (GWR). Analysis of the GWR method is the development of global regression into weighted regression, resulting in a model that is local. The author uses GWR with Fixed Gaussian, Adaptive Gaussian kernel weighting, Fixed Bi-Square, and Adaptive Bi-Square. Comparison of modelling for Unemployment cases in Indonesia between Multiple Linear Regression and GWR model produces that GWR Adaptive Bi-Square better, review value of the R^2 , AIC and JKG. The ability of the GWR Adaptive Bi-Square model explains the effect of UR on factors (Labor Force or economically active, Health Complaint and Poverty Percentage) by 89.1% while the global regression model 46.1%.

Keywords: *Unemployment Rate(UR), Spatial Data, GWR, and Kernel Weight*

ABSTRAK

MILA RIZKI RAMADAYANI. Pemodelan *Geographically Weighted Regression* Menggunakan Pembobot Kernel *Fixed* dan *Adaptive* pada Kasus Tingkat Pengangguran Terbuka di Indonesia. Skripsi, Program Studi Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Jakarta. Oktober 2021.

Tingkat Pengangguran Terbuka (TPT) merupakan indikator untuk mengukur angka pengangguran menurut konsep ketenagakerjaan. Jumlah TPT mengalami peningkatan dalam setahun terakhir sebesar 1.84% dimana Agustus 2019 berada di angka 5.23% dan Agustus 2020 menjadi 7.07%, hal demikian terjadi karena dampak dari pandemi Covid-19 di Indonesia. Salah satu analisis untuk mengetahui faktor-faktor yang mempengaruhi TPT di Indonesia yaitu regresi linear berganda dengan metode *Ordinary Least Square* (OLS). Penelitian dengan metode OLS menghasilkan gejala heterokedastisitas, menandakan bahwa data memiliki informasi lebih. Pengamatan berlanjut pada pengecekan terdapatnya aspek *spatial* (lokasi). Hasil tipe data menunjukkan bahwa penelitian menggunakan data spasial karena mengandung heterogenitas spasial. Data spasial merupakan data yang mengandung informasi lokasi (*latitude, longitude*) dan informasi deskriptif (*attribute*). Analisis data spasial menggunakan pendekatan titik yaitu dengan metode *Geographically Weighted Regression* (GWR). Analisis metode GWR merupakan pengembangan regresi global menjadi regresi terboboti, sehingga menghasilkan model yang bersifat lokal. Penulis menggunakan GWR dengan kernel pembobot *Fixed Gaussian*, *Adaptive Gaussian*, *Fixed Bi-Square*, dan *Adaptive Bi-Square*. Perbandingan pemodelan untuk kasus pengangguran di Indonesia antara Regresi Linear Berganda dengan model GWR menghasilkan bahwa GWR *Adaptive Bi-Square* lebih baik, meninjau dari nilai R^2 , AIC dan JKG. Kemampuan model GWR *Adaptive Bi-Square* menjelaskan pengaruh TPT terhadap faktor-faktor (Angkatan kerja, Keluhan Kesehatan dan Persentase Kemiskinan) sebesar 89.1% sedangkan model regresi global sebesar 46.1%.

Kata Kunci . *TPT, Data Spasial, GWR, dan Pembobot Kernel.*

KATA PENGANTAR

Assalamualaikum Warahmatullahi Wabarakatuh

Alhamdulillah *rabbi'l'alamin*, Segala puji dan syukur kepada Allah SWT yang telah melimpahkan rahmat, hidayah dan karunia-Nya kepada penulis, sehingga penulis bisa menyelesaikan skripsi dengan judul "**Pemodelan *Geographically Weighted Regression* Menggunakan Pembobot Kernel *Fixed* dan *Adaptive* pada Kasus Tingkat Pengangguran Terbuka di Indonesia**". Tugas ini disusun untuk memenuhi persyaratan dalam penyelesaian Program Sarjana (S1) di program studi Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Jakarta.

Perjalanan panjang dalam menyelesaikan skripsi, tentunya banyak hambatan dan rintangan namun akhirnya penulis bisa melaluinya. Penulis menyadari penyelesaian tugas akhir ini tidak terlepas dari bantuan, arahan, bimbingan serta dukungan dari berbagai pihak. Untuk itu, pada kesempatan ini penulis menyampaikan terima kasih yang sebesar-besarnya kepada :

1. Ibu Prof. Dr. Muktiningsih N, M.Si., selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Jakarta.
2. Ibu Dr. Lukita Ambarwati, S.Pd.,M.Si., selaku Ketua Program Studi Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Jakarta.
3. Ibu Dr. Eti Dwi Wiraningsih, S.Pd., M.Si., selaku Dosen Pembimbing Akademik.
4. Ibu Ir. Fariani Hermin Indiyah, MT., selaku Dosen Pembimbing I yang selalu memberikan nasihat, arahan, motivasi dan dukungan selama menyelesaikan tugas akhir ini.
5. Bapak Ibnu Hadi, M.Si., selaku Dosen Pembimbing II yang selalu memberikan nasihat, arahan, motivasi dan dukungan selama menyelesaikan tugas akhir.

6. Segenap dosen pengajar dan civitas akademik Program Studi Matematika, terimakasih atas segala ilmu, pengajaran, bimbingan dan pengetahuan yang diberikan selama masa kuliah.
7. Kementrian Riset dan Perguruan Tinggi (Kemenristekdikti) yang pernah memberikan penulis Beasiswa PPA saat awal semester, dan memberikan Beasiswa Bidikmisi sejak semester tiga hingga akhir.
8. Kedua Orang Tua, ayahanda Imhar dan Ibunda Siti Aisyah, serta Kakak-adik penulis Karina, Prita dan Naufal , terimakasih atas segala nasihat, bimbingan, dukungan, kasih sayang, serta selalu mendo'akan penulis agar selalu diberikan kemudahan dalam menyelesaikan kuliah.
9. Sahabat seperjuangan Nur Afini, Ayu, Tiana , Riha,Nimas yang telah banyak kebersamai, memberikan semangat, motivasi juga mengisi masa-masa perkuliahan, dan Siti Julpia yang memberikan masukan dan semangat penulis untuk menyelesaikan tugas akhir ini.
10. Sahabat penulis Alfina, Peya, Anna, Ridha, dan Kuyyok yang selalu memberikan semangat,dukungan, dan menghibur saya ketika lelah.
11. Teman-teman seperjuangan Matematika 2017 , yang telah kebersamai masa perkuliahan, selalu memberikan dukungan satu sama lain, semangat dan motivasi.
12. Semua pihak yang tidak dapat disebutkan satu persatu yang sudah membantu penulis dalam menyelesaikanpenulisan naskah skripsi ini.

Rasa hormat dan terimakasih kepada semua pihak yang telah membantu. Akhir kata penulis menyadari sepenuhnya bahwa penulisan tugas akhir ini masih jauh dari sempurna, hal ini karena terbatasnya pengetahuan dan pengalaman yang dimiliki penulis. Oleh karena itu penulis mengharapkan saran dan kritik yang membangun dari pembaca. Semoga Skripsi ini bisa bermanfaat dan mendorong penelitian-penelitian berikutnya.

Jakarta, Oktober 2021
Mila Rizki Ramadayani

DAFTAR ISI

ABSTRACT	ii
ABSTRAK	iii
KATA PENGANTAR	iv
DAFTAR ISI	vi
DAFTAR TABEL	ix
DAFTAR GAMBAR	x
I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Batasan Masalah	4
1.4 Tujuan Penelitian	5
1.5 Manfaat Penelitian	5
II Kajian Pustaka	6
2.1 Tingkat Pengangguran Terbuka (TPT)	6
2.1.1 Angkatan Kerja	7
2.1.2 Keluhan Kesehatan	7
2.1.3 Persentase Penduduk Miskin	7
2.2 Regresi Linear Berganda	8
2.2.1 Estimasi Paramater Model Regresi Linear Berganda	9
2.2.2 Uji Asumsi Klasik	10
2.2.3 Uji Simultan (Uji F)	13
2.2.4 Uji parsial (Uji T)	14
2.3 Statistika Deskriptif	15
2.4 Data Spasial	16
2.4.1 Uji Heterogenitas Spasial	16
2.4.2 Uji Autokorelasi Spasial	17
2.5 Pemodelan GWR	20
2.5.1 Estimasi Parameter GWR	20

2.5.2	Sifat-sifat Penaksir Paramater	23
2.6	Penentuan Bandwidth	23
2.7	Pembobot GWR	25
2.7.1	Fungsi Jarak Invers	25
2.7.2	Fungsi Kernel Fixed Bi-Square	26
2.7.3	Fungsi Kernel Adaptive Bi-Square	26
2.7.4	Fungsi Kernel Fixed Gaussian	27
2.7.5	Fungsi Kernel Adaptive Gaussian	27
2.8	Uji Hipotesis Model GWR	27
2.8.1	Pengujian Kelayakan Model	27
2.8.2	Pengujian Parameter Model GWR	28
2.9	Pemilihan Model Terbaik	29
2.9.1	Koefisien Determinasi (R^2)	29
2.9.2	Akaike Information Criterion (AIC)	30
III Metodologi Penelitian		31
3.1	Pendekatan Penelitian	31
3.2	Populasi dan sampel penelitian	31
3.3	Variabel Penelitian	31
3.4	Sumber Data	32
3.5	Tahapan Analisis Data	32
3.6	Diagram Alir	33
IV Hasil dan Pembahasan		35
4.1	Deskripsi Data	35
4.2	Uji Asumsi Klasik	38
4.2.1	Homoskedastisitas	39
4.2.2	Uji Normalitas	39
4.2.3	Uji Multikolinearitas	40
4.2.4	Uji Autokorelasi	40
4.3	Regresi Linear Berganda	41
4.4	Data Spasial	43
4.4.1	Uji Heterogenitas Spasial	43
4.4.2	Autokorelasi Spasial	44
4.5	Pemodelan Geographically Weighted Regression	47
4.5.1	Uji Kesesuaian Model GWR	51

4.5.2	Pengujian Parsial Parameter Model GWR	52
4.6	Perbandingan Model GWR dengan Regresi Linear Berganda . .	56
V	Penutup	58
5.1	Kesimpulan	58
5.2	Saran	59
	DAFTAR PUSTAKA	61
	LAMPIRAN	64

DAFTAR TABEL

2.1	Keputusan Autokorelasi	13
2.2	Tabel ANOVA	14
4.1	Descriptive Statistics	35
4.2	Uji Glejser	39
4.3	Uji Kolmogorov-smirnov	40
4.4	Coefficient	40
4.5	Hasil Uji Durbin Watson	41
4.6	Parameter Regresi	41
4.7	ANOVA	42
4.8	Uji T	42
4.9	Uji Breusch-Pagan	44
4.10	Morans X1	45
4.11	Morans X2	46
4.12	Morans X3	46
4.13	Sebaran Estimasi Fixed Gaussian	48
4.14	Sebaran Estimasi Adaptive Gaussian	49
4.15	Sebaran Estimasi Fixed Bi-square	50
4.16	Sebaran Estimasi Adaptive Bi-Square	50
4.17	Uji Kelayakan Model	51
4.18	Nilai (R^2), AIC dan JKG	57

DAFTAR GAMBAR

1.1	Tingkat Pengangguran Terbuka di Indonesia Tahun 2016-2020	2
2.1	<i>Queen Contiguity</i>	18
2.2	Bandwidth	24
3.1	Diagram Alir	34
4.1	Tingkat Pengangguran Terbuka	36
4.2	Angkatan Kerja	37
4.3	Keluhan Kesehatan	37
4.4	Persentase Penduduk Miskin	38
4.5	Scatterplot lag TPT	44
4.6	Scatterplot lag X1	45
4.7	Scatterplot lag X2	46
4.8	Scatterplot lag X3	47
4.9	Variabel yang signifikan pada GWR Fixed Gaussian	52
4.10	Peta Kelompok Wilayah Berdasarkan Faktor yang Signifikan menggunakan Fixed Gaussian	53
4.11	Variabel yang signifikan pada GWR Adaptif Bi-Square	54
4.12	Peta Kelompok Wilayah Berdasarkan Faktor yang Signifikan Menggunakan Adaptive Bi-Square	56
5.1	Data Penelitian	64
5.2	Hasil Model GWR dengan Adaptive Bi-Square	65
5.3	Uji Heterokedastisitas	71
5.4	Uji Normalitas	71
5.5	Uji Multikolinearitas	71
5.6	Uji Autokorelasi	72
5.7	Uji F	72
5.8	Uji T	72
5.9	Estimasi Parameter Fixed Gaussian	74
5.10	Estimasi Parameter Adaptive Gaussian	76
5.11	Estimasi Parameter Fixed Gaussian	78
5.12	Estimasi Parameter Adaptive Gaussian	80

BAB I

PENDAHULUAN

1.1 Latar Belakang

Bermula dari mewabahnya virus corona di Indonesia, beberapa aktivitas rutin masyarakat dihentikan sejenak. Kebijakan *lockdown* ini dilakukan untuk melindungi kesehatan diri sendiri dan orang lain. Pemberlakuan *lockdown* di beberapa wilayah Indonesia berlangsung cukup lama sehingga berdampak negatif di beberapa sektor. Salah satunya pada sektor sentral di kehidupan sehari-hari yaitu sektor perekonomian. Sebelumnya China yang memiliki dampak paling serius namun itu juga cukup mengkontraksi perekonomian Indonesia, dimana perhitungan pertumbuhan ekonomi di Indonesia menurut Badan Pusat Statistik (BPS) di kuartal kedua 2020 juga mengalami kontraksi -5.32 persen.

Pertumbuhan ekonomi sejalan juga dengan kondisi ketenagakerjaan di Indonesia. Pada bulan Agustus 2020, SMERU Research Institute merilis catatan bahwa krisis ekonomi yang terjadi di Indonesia terutama bidang ketenagakerjaan berdampak pengangguran meningkat. Dampak yang mungkin akan dialami oleh beberapa negara saat pandemi corona, yaitu resesi. Menurut *National Bureaus of Economic Research* (NBER) AS, resesi adalah penurunan signifikan dalam aktivitas ekonomi yang tersebar, berlangsung dalam beberapa bulan, biasanya ditandai penurunan PDB riil, lapangan kerja, dan produksi industri. Hal ini terjadi dikarenakan selama pandemi banyak aktivitas dihentikan sementara, pekerjaan dirumahkan, diberlakukannya pengurangan upah atau gaji, bahkan banyak karyawan mengalami Pemutusan hubungan Kerja (PHK). Dampak seperti ini bisa menjadi pemicu kedepan pencari kerja akan jauh lebih banyak daripada penyerapan tenaga kerja sehingga angka pengangguran meningkat.

Pengangguran Terbuka adalah kondisi dimana seseorang tidak sama sekali bekerja dan berusaha mencari pekerjaan. Indikator yang biasa digunakan untuk mengukur angka pengangguran menurut konsep ketenagakerjaan disebut Tingkat Pengangguran Terbuka (TPT). Fungsi indikator ini dalam persen

maupun unit/orang berguna sebagai bahan pertimbangan pemerintah untuk pembukaan lapangan pekerjaan baru dan mengetahui keadaan angkatan kerja saat ini. Seorang penduduk dikatakan sebagai angkatan kerja apabila berada di usia kerja yaitu 15 tahun ke atas. Data Badan Pusat Statistik menyatakan bahwa jumlah TPT dalam setahun terakhir meningkat sebesar 1.84 persen, pada agustus 2019 persentase TPT 5.23 persen menjadi 7.07 persen pada Agustus 2020, Kenaikan ini cukup signifikan. Seiring dengan angkatan kerja meningkat maka Persentase TPAK (Tingkat Persentase Angkatan Kerja) pun meningkat sebesar 0.24 persen poin. Dampak dari Covid-19 pada ketenagakerjaan memang sangat berarti dimana 29,12 juta orang (14.28 persen) penduduk usia kerja yang terkena dampaknya, yang mencakup bukan angkatan kerja, pengangguran, pengurangan jadwal kerja dan sementara tidak bekerja.



Gambar 1.1: Tingkat Pengangguran Terbuka di Indonesia Tahun 2016-2020

Dalam lima tahun ke belakang grafik TPT menunjukkan bahwa pada tahun 2016 sampai dengan tahun 2019 persentase TPT sedikit demi sedikit menurun menandakan perubahan yang baik, namun memasuki tahun 2020 angka TPT meningkat signifikan, karena menjadi sektor yang terdampak pada Covid-19. Indonesia juga sedang dalam masa bonus demografi dimana penduduk usia produktif meningkat, sehingga persaingan dunia kerja pun cukup tinggi. Untuk menulis dan membuat suatu kesimpulan tentang permasalahan ini maka cara preventif yang bisa dilakukan yaitu dengan memprediksi fak-

tor yang mempengaruhi besarnya angka pengangguran. Kondisi ekonomi dan pendidikan penduduk yang beragam di setiap daerahnya membuat kontribusi yang signifikan terhadap status TPT di wilayah tersebut, Indonesia yang memiliki 34 Provinsi, memiliki nilai persentase TPT yang berbeda disetiap daerahnya. Adanya perbedaan tersebut menjadikan kondisi ekonomi dan pendidikan merupakan masalah spasial sebab faktor geografis pada suatu wilayah mempengaruhi meningkatnya angka TPT.

Pengembangan analisis regresi linear sederhana yang menggunakan dua atau lebih variabel bebas yaitu regresi linear berganda, dimana dalam penerapannya bertujuan untuk mengetahui faktor yang mempengaruhi variabel terikat. Regresi dalam penelitian ini menganalisis selain faktor dari TPT juga melibatkan aspek spasial. Hal ini karena setiap variabel dependen berasal dari lokasi berbeda sehingga mengindikasikan ketergantungan satu dengan lainnya. Dalam pendekatan statistik, ketika data berorientasi pada letak geografis maka dapat disebut dengan data spasial, dimana di dalamnya mengandung dua unsur penting yang membedakan dengan model data lainnya yaitu terdapatnya informasi lokasi (*spatial*) dan deskriptif (*attribute*). Ilustrasi Peta merupakan penyajian data yang paling tepat pada data spasial. Model analisis seperti ini dibutuhkan konsen lebih karena lokasi pengamatan yang berdekatan memiliki hubungan yang erat, sehingga menimbulkan efek spasial. Adanya aspek spasial menunjukkan bahwa setiap lokasi mempunyai karakteristik lingkungan, kondisi sosial budaya dan geografis yang berbeda. Perbedaan ini sangat memungkinkan munculnya heterogenitas spasial. Apabila data spasial mengandung heterogenitas spasial maka digunakan pendekatan titik, salah satunya adalah metode *Geographically Weighted Regression* (GWR).

GWR merupakan metode statistik yang menggunakan informasi geografis yaitu *longitude* dan *latitude*. Analisa metode GWR merupakan bagian dari pengembangan regresi global menjadi regresi yang terboboti. Parameter penduga setiap model berbeda untuk setiap wilayah. Hal ini terjadi karena setiap lokasi memberikan bobot yang berbeda juga masing masing koefisien regresi variabel bebas tergantung lokasi data diamati. Kelebihan model GWR dibanding dengan regresi klasik menurut jurnal-jurnal terkait yaitu dapat memberikan model secara lokal.

Pada penelitian sebelumnya (Meila,2017) menggunakan metode GWR pada kasus pneumonia balita di Provinsi Jawa Barat. Penelitiannya menyimpulkan bahwa pemodelan kasus tersebut dilakukan dengan *fixed gaussian* dan

menghasilkan model GWR lebih baik dari regresi lokal. Lutfiani (2019) yang meneliti model GWR dengan pembobot *bi-square* dan *gaussian* pada kasus kemiskinan di Jawa Tengah tahun 2014 menyimpulkan bahwa GWR lebih baik dengan pembobot *gaussian* pada kasus tersebut, penulis juga ingin melakukan pemodelan dengan membandingkan pembobot fungsi kernel berbeda pada setiap pengamatan. Penulisan skripsi ini menggunakan empat kernel berbeda yaitu *fixed gaussian*, *adaptive gaussian*, *fixed bi-square* dan *adaptive bi-square*, sehingga mampu menemukan kernel GWR terbaik pada model TPT. Pemodelan GWR pada studi kasus Tingkat Pengangguran Terbuka (TPT) di Indonesia menggunakan beberapa faktor yaitu angkatan kerja (X1), keluhan kesehatan (X2) dan persentase penduduk miskin (X3). Berdasarkan faktor dan latar belakang yang tertulis, maka penulis ingin menyusun karya ilmiah ini dengan judul "Pemodelan *Geographically Weighted Regression* (GWR) menggunakan pembobot kernel fixed dan adaptive pada kasus tingkat pengangguran terbuka di Indonesia".

1.2 Rumusan Masalah

1. Bagaimana langkah untuk memodelkan tingkat pengangguran terbuka dengan regresi linear berganda dan *geographically weighted regression*?
2. Faktor apa sajakah yang mempengaruhi pengangguran terbuka di Indonesia menggunakan GWR?
3. Manakah model terbaik antara model GWR dengan fungsi pembobot kernel dan model regresi dengan OLS dalam memodelkan TPT di Indonesia?

1.3 Batasan Masalah

1. Data yang digunakan merupakan data TPT dan faktor yang mempengaruhinya tahun 2020 di Indonesia.
2. Pendekatan data spasial menggunakan titik yaitu dengan GWR.
3. Fungsi pembobot kernel yang digunakan pada model adalah Fixed Gaussian, Adaptive Gaussian, Fixed Bi-Square dan Adaptive Bi-Square .

1.4 Tujuan Penelitian

1. Mengetahui dan menerapkan langkah memodelkan tingkat pengangguran terbuka di Indonesia
2. Mengetahui apakah TPT di Indonesia dipengaruhi oleh faktor geografis
3. Mengetahui model terbaik antara model GWR dengan fungsi pembobot kernel dan model regresi dengan OLS dalam memodelkan TPT di Indonesia.

1.5 Manfaat Penelitian

1. Diharapkan bisa memberikan informasi sebagai pertimbangan kepada Pemerintah setiap Provinsi di Indonesia dalam mengatasi Tingkat Pengangguran Terbuka (TPT).
2. Menambah wawasan peneliti mengenai metode *Geographically Weighted Regression* dan data spasial.
3. Penulisan dan hasil penelitian diharapkan dapat memberikan informasi dan gambaran untuk peneliti selanjutnya yang berkaitan dengan *Geographically Weighted Regression*.

BAB II

Kajian Pustaka

2.1 Tingkat Pengangguran Terbuka (TPT)

Pengangguran merupakan istilah untuk seseorang yang tidak bekerja sama sekali, mencari pekerjaan, dan bekerja kurang dari dua kali seminggu . Menurut BPS (2021) Tingkat pengangguran terbuka adalah indikator yang digunakan dalam mengukur tenaga kerja yang tidak diserap oleh pasar kerja dan menggambarkan kurang termanfaatkannya pasokan tenaga kerja. Angka TPT di Indonesia memang jauh lebih baik jika dibanding tahun 1990-an, dimana titik perubahannya terjadi pada tahun 2000-an. Namun jumlah pengangguran setiap tahun meningkat. Hal ini karena jumlah penduduk meningkat cepat dan dibutuhkannya penyerapan tenaga kerja yang optimal. Kondisi ini menjadi suatu tantangan pemerintah juga dalam menstimulasi terciptanya lapangan pekerjaan baru yang mampu menampung pengangguran muda yang terus bertambah. Jika permasalahan pengangguran di Indonesia dapat diatasi maka kondisi saat bonus demografis seperti ini bisa menjadi kesempatan untuk Indonesia agar bisa menjadi negara maju. Peluang emas ini menjadi tantangan untuk seluruh masyarakat terutama millennial dalam mencari pekerjaan dan kreativitas pola pikir.

Jimmy Ginting (2016) memberikan definisi bonus demografi sebagai ledakan penduduk usia produktif yang diperkirakan berlangsung di Indonesia tahun 2020-2030. Saat ini Indonesia masih berada dalam masa bonus demografi. Memperbaiki dan meningkatkan kualitas pemuda di Indonesia adalah upaya yang sangat dibutuhkan dalam menghadapi angkatan kerja yang terus meningkat. TPT dijadikan tolok ukur untuk melihat kondisi pengangguran. Definisi dari Tingkat Pengangguran Terbuka (TPT) sebagai perbandingan banyaknya pengangguran terhadap banyaknya angkatan kerja. Diantara faktor yang mempengaruhi pengangguran yaitu angkatan kerja, keluhan kesehatan, dan persentase penduduk miskin.

2.1.1 Angkatan Kerja

Menurut Badan Pusat Statistik (BPS), angkatan kerja adalah penduduk yang berumur 15 tahun ke atas yang bekerja, atau punya pekerjaan namun sementara tidak bekerja alias menganggur. Angka pengangguran diambil dari angkatan kerja yang belum bekerja maupun tidak bekerja. Angkatan kerja mampu mempengaruhi TPT. Semakin banyak angkatan kerja juga beresiko terhadap meningkatnya TPT.

2.1.2 Keluhan Kesehatan

Kondisi kesehatan seseorang mampu mempengaruhi produktivitas dalam sehari-hari. Saat pandemi seperti ini banyak kondisi tubuh mengalami penurunan stamina, sehingga akan mudah terserang penyakit dan virus. Demikian data yang terhimpun bahwa angka keluhan kesehatan meningkat di masa seperti ini. Keluhan kesehatan merupakan kondisi seseorang yang mengalami gangguan kesehatan atau kejiwaan. Karena keluhan kesehatan mampu mempengaruhi produktivitas seseorang maka kesehatan berpengaruh juga pada sektor ketenagakerjaan. Sehingga angka keluhan kesehatan pada saat pandemi mampu mempengaruhi Tingkat Pengangguran Terbuka (TPT).

2.1.3 Persentase Penduduk Miskin

Kemampuan dalam memenuhi kebutuhan sehari-hari ataupun kebutuhan dasar merupakan faktor yang mendukung seseorang untuk bekerja. Apabila seseorang tidak bekerja maka hal itu bisa berdampak ketidakmampuan dari sisi ekonomi dalam memenuhi kebutuhan sehari-hari. Tingkat pengangguran erat kaitannya dengan Angka kemiskinan, dimana pendekatan ketidakmampuan dari sudut pandang ekonomi disebut kemiskinan. Menurut BPS (2021) Penduduk miskin merupakan penduduk yang memiliki rata-rata pengeluaran per kapita per bulan di bawah Garis Kemiskinan. Garis kemiskinan terbagi dua yaitu Garis Kemiskinan makanan dan non-makanan. Kebutuhan Non makanan seperti kebutuhan rumah, sandang pendidikan dan kesehatan.

$$\text{Garis Kemiskinan (GK)} = \text{GK makanan} + \text{GK nonmakanan}$$

2.2 Regresi Linear Berganda

Analisis regresi adalah metode umum untuk mendapatkan fungsi prediksi untuk memprediksi nilai variabel respon Y menggunakan variabel prediktor (x_1, \dots, x_k) . Regresi memiliki konsep istimewa yaitu bisa menemukan ada tidaknya hubungan linear dan pengaruh signifikan antara faktor-faktor yang diteliti. Regresi linear berganda digunakan untuk mendapati adanya pengaruh interaksi dua atau lebih variabel bebas terhadap variabel terikat. Dalam kehidupan sehari-hari regresi ini lebih sesuai untuk digunakan karena satu faktor memungkinkan dipengaruhi oleh banyak faktor. Menurut Suharjo (2008) variabel dependen tidak hanya dapat dijelaskan oleh satu variabel independen saja tetapi perlu dijelaskan oleh beberapa variabel independen.

Berikut adalah model umum dari regresi linear berganda:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \varepsilon \quad (2.1)$$

Ketika kasus dimana penelitian menggunakan sebanyak n pengamatan, model yang terbentuk adalah:

$$Y_i = \beta_0 + \sum_{k=1}^p \beta_k X_{ik} + \varepsilon_i$$

dengan $i = 1, 2, \dots, n$ pengamatan. Jika dijabarkan dalam bentuk persamaan linearnya bentuknya sebagai berikut:

$$y_1 = \beta_0 + \beta_1 x_{11} + \beta_2 x_{12} + \dots + \beta_p x_{1p} + \varepsilon_1$$

$$y_2 = \beta_0 + \beta_1 x_{21} + \beta_2 x_{22} \dots + \beta_p x_{2p} + \varepsilon_2$$

$$\vdots$$

$$y_n = \beta_0 + \beta_1 x_{n1} + \beta_2 x_{n2} + \dots + \beta_p x_{np} + \varepsilon_n$$

bentuk di atas dapat juga disederhanakan dengan penulisan :

$$Y = X\beta + \varepsilon \quad (2.2)$$

Y merupakan vektor $n \times 1$, X merupakan vektor $n \times (k + 1)$ dan $\hat{\beta}$ merupakan vektor $(k + 1) \times 1$. Diberikan dalam bentuk matriks :

$$X = \begin{pmatrix} 1 & x_{11} & x_{12} & \dots & x_{1k} \\ 1 & x_{21} & x_{22} & \dots & x_{2k} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \dots & x_{nk} \end{pmatrix}, Y = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}, \hat{\beta} = \begin{pmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{pmatrix}$$

dimana :

Y : Variabel dependen

$X_{i1}, X_{i2}, \dots, X_{ip}$: Variabel independen

$\beta_0, \beta_1, \dots, \beta_k$: Parameter yang nilainya belum diketahui

ε_i : Sisa atau error untuk pengamatan ke- i , $\varepsilon \sim IIDN(0, \sigma^2)$

2.2.1 Estimasi Paramater Model Regresi Linear Berganda

Estimasi parameter beta bertujuan melengkapi koefisien dari setiap parameter pada model regresi linear berganda yang dianalisis. Metode yang digunakan untuk mendapatkan paramater pada model di sini yaitu *Ordinary Least Square (OLS)* atau biasa disebut metode kuadrat terkecil. Metode OLS dijalankan menggunakan nilai *error* kuadrat yang perhitungannya lebih mudah menggunakan matriks untuk menghitung taksiran kuadrat terkecil dari $\beta_0, \beta_1, \dots, \beta_k$. Dapat ditunjukkan secara matematis bahwa estimasi kuadrat terkecil $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k$ dari parameter $\beta_0, \beta_1, \dots, \beta_k$ diperoleh dengan menggunakan jumlah kuadrat error dengan asumsi galat $\varepsilon \sim (0, \sigma^2 I)$. Berikut adalah bentuk persamaan galat yang didapat dari persamaan umum (2.2) :

$$\varepsilon = Y - X\hat{\beta}$$

1. Membentuk persamaan Jumlah Kuadrat Error

$$\begin{aligned} JKG &= e^T e \\ &= (Y - X\hat{\beta})^T (Y - X\hat{\beta}) \\ &= (Y^T - \hat{\beta}^T X^T)(Y - X\hat{\beta}) \\ &= Y^T Y - Y^T X\hat{\beta} - \hat{\beta}^T X^T Y + \hat{\beta}^T X^T X\hat{\beta} \\ &= Y^T Y - 2Y^T X\hat{\beta} + \hat{\beta}^T (X^T X)\hat{\beta} \\ &= Y^T Y - 2(X^T Y)^T \hat{\beta} + \hat{\beta}^T (X^T X)\hat{\beta} \end{aligned}$$

2. Mendiferensialkan JKG terhadap $\hat{\beta}$, lalu hasilnya disamakan dengan nol

$$\begin{aligned}
\frac{\partial(JKG)}{\partial\hat{\beta}} &= -2X^TY + (X^TX)\hat{\beta} + (X^TX)^T\hat{\beta} \\
0 &= -2X^TY + 2(X^TX)\hat{\beta} \\
-2X^TY + 2(X^TX)\hat{\beta} &= 0 \\
2(X^TX)\hat{\beta} &= 2X^TY \\
(X^TX)\hat{\beta} &= X^TY \\
\hat{\beta} &= (X^TX)^{-1}X^TY
\end{aligned}$$

Persamaan ini diketahui sebagai persamaan normal. Solusi dari persamaan normal ini adalah

$$\hat{\beta} = (X^TX)^{-1}X^TY$$

dimana :

$$X^TX = \begin{pmatrix} n & \sum_{i=1}^n x_{i1} & \dots & \sum_{i=1}^n x_{i1} \\ \sum_{i=1}^n x_{i1} & \sum_{i=1}^n x_{i1}^2 & \dots & \sum_{i=1}^n x_{i1}x_{ik} \\ \vdots & \vdots & \ddots & \vdots \\ \sum_{i=1}^n x_{ik} & \sum_{i=1}^n x_{ik}x_{i1} & \dots & \sum_{i=1}^n x_{ik}^2 \end{pmatrix}, \quad X^TY = \begin{pmatrix} \sum_{i=1}^n y_i \\ \sum_{i=1}^n x_{i1}y_i \\ \vdots \\ \sum_{i=1}^n x_{ik}y_i \end{pmatrix}$$

Prediksi nilai terbaik Y untuk item yang dipilih secara acak dari populasi, dengan

$$\hat{Y}(x_1, \dots, x_k) = \hat{\beta}_0 + \hat{\beta}_1x_1 + \dots + \hat{\beta}_kx_k$$

2.2.2 Uji Asumsi Klasik

Terdapat empat tahapan uji yang harus dilakukan untuk memeriksa validnya suatu model, berikut tahapannya:

Homoskedastisitas

Pengujian homoskedastisitas untuk mengetahui kesamaan pada varians antara residual satu pengamatan ke pengamatan lainnya pada suatu model. Hasilnya bila ternyata ditemukan adanya persamaan varians dan residual maka disebut homoskedastisitas sebaliknya jika ditemukan perbedaan disebut heteroskedastisitas (Kurniyanti,2019). Homoskedastisitas berasal dari kata *homoscedasticity*, dimana *homo* memiliki arti sama dan *scedasticity* sebaran, sehingga homoskedastisitas berarti mempunyai varians sama atau secara matematis

dapat ditulis sebagai berikut:

$$E(U_i^2) = \sigma^2, i = 0, 1, \dots, n$$

Pada penulisan ini terdapat dua metode untuk menentukan homoskedastisitas atau heteroskedastisitas yaitu dengan grafik *scatterplot* dan Uji Glejser. Berikut hipotesis dari Uji Glejser :

H_0 : $\sigma_1^2 = \sigma_2^2 = \dots = \sigma_p^2 = \sigma$ (Tidak terjadi heteroskedastisitas)

H_1 : Terdapat minimal satu $\sigma_k^2 \neq \sigma$ dengan $k = 1, 2, \dots, p$ (Terjadi heteroskedastisitas)

Statistik uji:

$$F = \frac{\frac{[\sum_{i=1}^p (|\hat{e}_i| - |\bar{e}|)^2]}{p}}{\frac{[\sum_{i=1}^p (|e_i| - |\bar{e}|)^2]}{n-p-1}}$$

keterangan :

\hat{e}_i : taksiran nilai residual ke- i

\bar{e}_i : rata-rata nilai residual

e_i : nilai residual

n : Banyaknya pengamatan

p : Banyaknya variabel bebas

Jika melihat grafik *scatterplot* apabila titik-titik menggambarkan pola maka terjadi heteroskedastisitas, begitu juga sebaliknya. Sedangkan Glejser pada konsep ujinya mengkorelasikan variabel bebas dengan *unstandardized residual*. Hasilnya jika nilai $sig > 0.05$ maka disimpulkan tidak mengandung heteroskedastisitas.

Normalitas

Persyaratan dalam pengujian regresi yang harus dipenuhi tentunya data harus berdistribusi normal. Data harus diuji apakah memiliki distribusi normal. Melihat grafik histogram menjadi salah satu cara pengecek kenormalan data yaitu jika data masih berada dalam kontrol dengan posisi bentuk lonceng ditengah. Selain dengan grafik dapat dilakukan juga dengan pengujian yaitu uji *Kolmogorov-Smirnov*, dengan hipotesis :

H_0 : Residual berdistribusi normal.

H_1 : Residual tidak berdistribusi normal.

Statistik Uji :

$$D = |S(x) - F_0(x)|$$

keterangan :

$F_0(x)$ = Fungsi distribusi komulatif teoritis.

$S(x)$ = Fungsi distribusi sampel.

Dengan dasar pengambilan keputusan, tolak H_0 jika $|D| > q_{1-\alpha}$, dan q merupakan nilai pada tabel Kolmogorov smirnov , atau pengambilan keputusan pada uji ini juga dapat dilihat juga pada baris *Unstandardized residual* dengan ketentuan jika nilai *sig* memenuhi ($p > 0.05$) maka data dikatakan berdistribusi normal. Syarat untuk melakukan regresi yaitu data harus berdistribusi normal.

Multikolinearitas

Uji Multikonearitas ini dilakukan karena menggunakan model regresi linear berganda, dimana model memiliki 2 atau lebih variabel independen. Multikolinearitas terjadi saat diantara variabel bebas berkorelasi linear sempurna. Kondisi ini menyimpang dari regresi linear, sehingga perlu dilakukan pengujian dahulu saat melakukan pemodelan. Pengecekan multikolinearitas dapat melihat nilai VIF setiap variabelnya pada tabel *coefficients* dari hasil SPSS. Kriteria pengambilan keputusan dengan menggunakan nilai VIF.

$$VIF = \frac{1}{1 - R_k^2}$$

Dengan :

R_k^2 : Koefisien determinasi antara x_i dengan variabel independen lainnya dan ($k = 1, 2, \dots, p$).

Jika nilai VIF < 10 dan nilai *tolerance* > 0.1 maka model tidak mengandung multikolinearitas. Namun bilamana VIF > 10 dan *tolerance* < 0.1 maka terindikasi adanya multikolinearitas atau memiliki korelasi yang kuat antar variabel bebas (Myers dalam Putri,2018). Pengaruh yang terjadi saat memiliki korelasi kuat yaitu nilai standar error yang besar dan kekuatan dalam memprediksinya tidak stabil juga tidak handal.

Uji Autokorelasi

Pengujian ini dilakukan guna mengetahui terdapat tidaknya korelasi antar pengamatan yang diurutkan berdasarkan waktu. Dalam menemukan korelasi menggunakan nilai residual, metode yang digunakan yaitu Durbin-Watson , hipotesis uji Durbin-Watson :

$H_0 : \rho = 0$ (Tidak terdapat autokorelasi)

$H_1 : \rho \neq 0$ (Terdapat autokorelasi).

dengan statistik uji :

$$d = \frac{\sum_{i=1}^p (e_i - e_{i-1})^2}{\sum_{i=1}^p e_i^2}$$

Mendeteksi keberadaan autokorelasi pada model menggunakan nilai kritis batas atas (d_U) dan batas bawah (d_L). Berikut disajikan tabel untuk mengetahui korelasi :

Tabel 2.1: Keputusan Autokorelasi

Kriteria	Keterangan
$0 < d < d_L$	Menolak hipotesis nol , ada autokorelasi positif
$4 - d_L \leq d \leq 4$	Menolak hipotesis nol, terdapat autokorelasi positif
$d_L \leq d \leq d_U$	Daerah keraguan, tidak ada keputusan
$4 - d_U \leq d \leq 4 - d_L$	Daerah keraguan, tidak ada keputusan
$d_U \leq d \leq 4 - d_U$	Terima H_0 , tidak ada autokorelasi positif atau negatif.

2.2.3 Uji Simultan (Uji F)

Pengujian yang paling penting dalam regresi salah satunya adalah uji F. Setidaknya terdapat variabel independen yang berpengaruh terhadap variabel dependen, sehingga uji F untuk mengetahui bagaimanakah pengaruh semua variabel independen secara seluruh (simultan) terhadap variabel dependen. Untuk mengujinya bisa menggunakan tabel anova yang diperoleh dari software SPSS. Dengan kriteria pengambilan keputusan model Signifikan ketika $F_{hitung} > F_{table}$ dan kolom signifikansi yaitu $sig < \alpha$ (selang kepercayaan).

Dan sebaliknya jika $F_{hitung} < F_{table}$ dan nilai $sig >$ nilai alpha ($\alpha = 0.05$) maka model tidak signifikan.

a. Pengujian Hipotesis

$H_0 : \beta_0 = \beta_1 = \dots = \beta_p = 0$ (Tidak ada pengaruh variabel independen dengan variabel dependen)

$H_1 : \beta_k \neq 0; k = 1, \dots, p$ (Terdapat pengaruh variabel independen dengan variabel dependen)

b. Statistik Uji

$$F_{hit} = \frac{\frac{JKR}{p}}{\frac{JKG}{n-p-1}}$$

dimana :

p = Banyaknya variabel bebas yang digunakan dalam penelitian

$$JKR = \widehat{\beta}' X' y - n\bar{y}^2$$

$$JKG = y' y - \widehat{\beta}' X' y$$

$$JKT = \sum_{i=1}^n (y_i - \bar{y})^2 = y' y - n\bar{y}^2$$

c. Daerah Kritis

Tolak H_0 jika $F_{hitung} > F_{\alpha; p, (n-p-1)}$

dengan p derajat bebas sebagai pembilang dan $(n-p-1)$ derajat bebas sebagai penyebut dan α atau taraf nyata 5

Tabel 2.2: Tabel ANOVA

Sumber Variasi	DB	Jumlah Kuadrat	Kuadrat Total	F_{hit}	F_{table}
Regresi	p	JKR	$\frac{JKR}{p}$	$\frac{JKR/p}{JKG/(n-p-1)}$	$F_{(p; n-p-1); \alpha}$
Galat	$n - p - 1$	JKG	$\frac{JKG}{n-p-1}$		
Total	$n - 1$	JKT			

2.2.4 Uji parsial (Uji T)

Uji parsial atau bisa dikenal dengan uji T, fungsinya yaitu akan menguji pengaruh masing masing variabel independen terhadap variabel dependen.

Pemeriksaan ini bisa diartikan sebagai uji yang mengukur perbedaan dua atau lebih mean antar kelompok.

a. Pengujian Hipotesis

$H_0 : \beta_k = 0$ (Koefisien regresi ke- i tidak berpengaruh nyata ke- y)

$H_1 : \beta_k \neq 0$ ($k = 0, 1, \dots, p$) (Koefisien regresi ke- i berpengaruh nyata terhadap y)

b. Statistik Uji

$$t_{hit} = \frac{\widehat{\beta}_k}{SE_{(\widehat{\beta}_k)}}$$

$$SE_{(\widehat{\beta}_k)} = \sqrt{C_{(p+1)}S}$$

keterangan :

β_k : Nilai koefisien pengamatan ke- k ; $k = 0, 1, \dots, p$

$SE_{(\beta_k)}$: Standar error koefisien pada pengamatan ke- k ; $\sqrt{C_{(p+1)}S}$ unsur ke $(p + 1)$ diagonal $(xx)^{-1}$

S : Akar dari kuadrat rata-rata galat

c. Daerah Kritis

Tolak H_0 jika $t_{hit} > t_{((n-p-1); \frac{\alpha}{2})}$

dengan α atau taraf nyata 5 %

2.3 Statistika Deskriptif

Statistik Deskriptif merupakan metode statistik dalam penyajian dan mendeskripsikannya sehingga mudah dibaca dan dipahami. Menurut Walpole (1995) Metode dalam penyajian data terbagi dua yaitu statistika deskriptif dan statistik inferensial. Namun dalam penulisan ini penulis menggunakan statistik deskriptif karena memberikan suatu gambaran dan keterangan mengenai suatu keadaan. Salah satu penyajian data yang mudah dipahami adalah peta.

2.4 Data Spasial

Data yang mengandung unsur geografis dan menggunakan koordinat lintang dan bujur sebagai dasar referensi disebut data spasial. Data spasial memiliki dua bagian penting yaitu informasi lokasi (*spatial*) dan informasi deskriptif (*attribute*). Informasi lokasi mencakup letak suatu daerah berdasarkan koordinat geografis, sedangkan informasi deskriptif mencakup objek yang terdapat pada lokasi seperti populasi, kode pos dan sebagainya. Penyajian data spasial biasanya dalam bentuk titik dan peta.

Pada penelitian terhadap data spasial dibutuhkan konsen lebih karena menyelesaikan masalah berbasis lokasi sehingga memungkinkan terjadinya korelasi antar lokasi yang berdekatan, sesuai hukum Tobler I yang berbunyi : "segala sesuatu yang berhubungan satu dengan lainnya, tetapi sesuatu yang dekat lebih mempunyai pengaruh daripada sesuatu yang jauh". Pada data spasial adanya perbedaan kondisi wilayah, karena karakteristik lingkungan dan geografis memungkinkan terjadi heterogenitas. Data spasial termasuk dependen karena diperoleh dari lokasi yang berbeda-beda.

2.4.1 Uji Heterogenitas Spasial

Penggunaan data spasial bertujuan untuk mengetahui hubungan dan model matematis antara variabel terkait. Langkah pertama yang dilakukan dalam menganalisis yaitu analisis regresi spasial. Pengujian pada regresi spasial yang menjadi salah satu bagian terpenting yaitu uji heterogenitas spasial. Menurut Caraka (2017) heterogenitas spasial terjadi ketika salah satu peubah bebas memberikan respon yang tidak sama pada lokasi berbeda dalam satu penelitian. Solusi untuk menyelesaikan data yang mengandung heterogenitas spasial menurut Fotheringham (2002) adalah dengan pendekatan titik regresi spasial, disebut *Geographically Weighted Regression*. Uji ini menjadi syarat pembentukan model data spasial dengan metode GWR. Metode uji keberadaan heterogenitas spasial yaitu dengan Breusch-Pagan Berikut langkah-langkahnya :

a. Pengujian Hipotesis

$H_0 : \sigma_1^2 = \sigma_2^2 = \dots = \sigma_n^2 = \sigma^2$ (Tidak terdapat heterogenitas spasial)

$H_1 : \exists \sigma_i^2 \neq \sigma_j^2$ dengan $i \neq j ; i, j = 1, 2, \dots, n$. (Terdapat heterogenitas spasial)

b. Statistik Uji

$$BP = \frac{1}{2} b^T Z (Z^T Z)^{-1} Z^T b$$

keterangan :

$b : \frac{e_i^2}{\sigma^2} - 1$

Z : Variabel dependen ukuran ($n \times 1$)

e_i^2 : Residual kuadrat pada pengamatan ke- i

σ^2 : Varians dari e_i^2

c. Daerah Kritis

H_0 ditolak jika $BP > \chi_{(\alpha,p)}^2$ dimana p banyaknya variabel independen dan $\alpha = 5\%$.

2.4.2 Uji Autokorelasi Spasial

Autokorelasi spasial menjadi bagian penting dalam analisis data spasial, karna dalam data spasial terdapat pengaruh lokasi. Autokorelasi spasial merupakan analisis untuk mengetahui pengaruh antar lokasi pengamatan atau mendeteksi kolerasi antar lokasi. Pengujian autokorelasi ini juga untuk mengetahui desain penyebaran karakteristik dan keterkaitan antar lokasi di dalamnya. Dalam perhitungannya terdapat matriks pembobot yang mengilustrasikan hubungan kedekatan antar pengamatan. Matriks ini disebut dengan matriks bobot spasial (*Spatial Weight Matrix*). Penentuan hubungan ketetanggaan dapat ditentukan dari sisi persinggungan perbatasan wilayah atau bisa disebut *contiguity*. Menurut Kosfeld dalam (Wuryandari,2014) penentuan grid umum ketetanggaan beberapa cara yaitu *Rook Contiguity*, *Bishop Contiguity* dan *Queen Contiguity*. Penelitian ini menggunakan menggunakan konsep ketetanggaan *Queen Contiguity* dimana daerah pengamatannya ditentukan berdasarkan sisi dan sudut yang bersinggungan dengan daerah pengamatan.

Matriks bobot yang digunakan W_{ij}^* berupa pembobot dari *queen contiguity* yang terstandarisasi, artinya diberikan bobot yang sama rata untuk tetangga terdekat dan yang lainnya 0. Dikatakan dekat apabila jarak euclidean masih

	Unit C1	Unit B2	Unit C2	
	Unit B1	Unit A	Unit B3	
	Unit C4	Unit B4	Unit C3	

Gambar 2.1: *Queen Contiguity*

berada dalam *bandwidth* ($d_{ij} < b$).

$$W_{ij} = \begin{cases} 1 & : \text{untuk lokasi } i \text{ yang berdekatan dengan } j \\ 0 & : \text{lainnya} \end{cases}$$

$$W_{ij}^* = \frac{W_{ij}}{\sum_{j=1}^n W_{ij}}$$

Statistik uji yang dapat dilakukan pada pengujian autokorelasi spasial adalah nilai Moran I . Uji moran mengetahui eksistensi dependensi spasial. Menurut Bekti (2012) indeks moran merupakan pengembangan dari korelasi pearson. Indeks moran berguna untuk mengindikasikan adanya ketergantungan spasial antar provinsi terhadap variabel respon. Nilai Indeks moran yang berada di interval $-1 \leq I < 0$ artinya menunjukkan autokorelasi negatif, sedangkan apabila nilainya berada di interval $0 < I \leq 1$ menunjukkan autokorelasi positif. Jika memiliki autokorelasi yang positif maka datanya cenderung membentuk kelompok karena nilai-nilai yang mirip, jika autokorelasi negatif maka datanya cenderung tidak mirip nilainya dan tidak berkelompok. Berikut langkah uji Moran :

a. Pengujian Hipotesis

$H_0 : I = 0$ (Tidak ada ketergantungan spasial)

$H_1 : I \neq 0$ (Terdapat ketergantungan spasial)

b. Statistik Uji

$$Z_{hitung} = \frac{I - I_0}{\sqrt{\text{var}(I)}}, N(0, 1)$$

Koefisien Moran I didefinisikan dengan :

$$I = \frac{n \sum_{i=1}^n \sum_{j=1}^n w_{ij} (y_i - \bar{y})(y_j - \bar{y})}{\sum_{i=1}^n \sum_{j \neq 1}^n w_{ij} \sum_{i=1}^n (y_i - \bar{y})^2}$$

,

$$E(I) = I_0 = -\frac{1}{n-1}$$

,

$$\text{var}(I) = \frac{n^2 S_1 - n S_2 + 3 S_0^2}{(n^2 - 1) S_0^2} - [E(I)]^2$$

$$, S_1 = \frac{1}{2} \sum_{i \neq j}^n (w_{ji} + w_{ij})^2 ; S_2 = \sum_{i=1}^n (w_{i0} + w_{0i})^2 ; S_0 = \sum_{i=1}^n \sum_{j=1}^n w_{ij} ;$$

$$w_{i0} = \sum_{j=1}^n w_{ij} ; w_{0i} = \sum_{j=1}^n w_{ji}$$

keterangan :

I = Nilai moran I

\bar{y} = Rata- rata variabel respon

\bar{x} = Mean dari data

$\text{var}(I)$ = Varians moran I

$E(I)$ = Nilai harapan moran I

n = Banyaknya lokasi kejadian i

w_{ij} = Elemen pada pembobot terstandarisasi antara daerah i dan j

$i, j = 1, 2, \dots, n$

c. Daerah Kritis

Tolak H_0 apabila $|Z_{hitung}| > Z_{\frac{\alpha}{2}}$ dengan $\alpha = 0.05$

2.5 Pemodelan GWR

Geographically Weighted Regression merupakan metode regresi spasial dengan pendekatan titik yang berbasis wilayah. Model ini menghitung parameter atas setiap lokasi pengamatan atau dengan kata lain memperhitungkan lokasi data pengamatan (Ira,2016). Bentuk model GWR dalam perhitungannya yaitu vektor titik. GWR termasuk dalam geostatistik yang merupakan gabungan perpaduan disiplin ilmu geologi, teknik pertambangan, matematika dan statistik. Model GWR juga merupakan pengembangan regresi lokal dengan *Ordinary Least Square (OLS)* menjadi regresi terboboti dengan *Weighted Least Square (WLS)* yang memperhatikan efek spasial. Parameter pada setiap wilayah memiliki nilai yang berbeda-beda, karena dijalankan pembobotan berdasarkan lokasi pengamatan.

Faktor geografis pada model mempengaruhi variabel dependen, Berikut model GWR untuk lokasi ke- i :

$$Y_i = \beta_0(u_i, v_i) + \sum_{k=1}^p \beta_k(u_i, v_i)X_{ik} + \varepsilon_i \quad (2.3)$$

keterangan :

$i = 1, \dots, n$

Y_i = Variabel dependen lokasi ke- i

(u_i, v_i) = Koordinat lintang bujur pada lokasi ke- i

$\beta_0(u_i, v_i)$ = Konstanta GWR

$\beta_k(u_i, v_i)$ = Parameter atau koefisien regresi ke- k

X_{ik} = Variabel prediktor ke- k pada lokasi ke- i

ε_i = Residual dengan asumsi $\varepsilon \sim IIDN(0, \sigma^2)$.

(Fotheringham , Brunsdon , dan Charlton ,2002)

2.5.1 Estimasi Parameter GWR

Metode yang digunakan untuk mengetahui penaksiran parameter di setiap model GWR yaitu metode *Weighted Least Square (WLS)*, dimana setiap lokasi diberikan bobot yang berbeda sesuai dengan titik pengamatan dimana data tersebut diambil. Nilai bobot memiliki peran penting pada setiap observasi. Notasi pembobot yang digunakan pada setiap lokasi adalah $w_j(u_i, v_i)$ dengan $j = 1, 2, \dots, n$ lokasi. Setiap parameter diduga dengan meminumkan jumlah ku-

adrat galat. Estimasi parameter GWR $\beta_k(u_i, v_i)$ untuk setiap variabel ke- k pada lokasi pengamatan ke- i , sebagai berikut:

$$\widehat{\beta}(u_i, v_i) = [X^T W(u_i, v_i) X]^{-1} X^T W(u_i, v_i) Y$$

Ket :

$\widehat{\beta}(u_i, v_i)$ = Parameter duga lokasi ke- i

X = Matriks variabel prediktor berukuran $nx(p + 1)$

$W(u_i, v_i)$ = Matriks bobot lokasi ke- i berukuran nxn

Y = Vektor variabel respon berukuran $nx1$

Metode untuk mendapat penaksir parameter digunakan *Weighted Least Square* (WLS) dimana memberikan pembobot berbeda untuk setiap lokasi dimana data tersebut dikumpulkan. Misalkan pembobot untuk setiap lokasi ke- i adalah $w_j(u_i, v_i), j = 1, 2, \dots, n$. Sehingga bobot lokasi j pada lokasi i dinyatakan $w_j(u_i, v_i)$. Koefisien regresi lokasi pengamatan yang terdapat di (2.3) ditaksir dengan menambahkan unsur pembobot, kemudian meminimumkan jumlah kuadrat error sehingga diperoleh :

$$\sum_{j=1}^n W_j(u_i, v_i) \varepsilon_i^2 = \sum_{j=1}^n W_j(u_i, v_i) [Y_i - \beta_0(u_i, v_i) - \sum_{k=1}^p \beta_k(u_i, v_i) X_{ik}^2]^2 \quad (2.4)$$

matriks pembobot setiap lokasi ke- i dinyatakan sebagai berikut :

$$\mathbf{W}(\mathbf{u}_i, \mathbf{v}_i) = \begin{pmatrix} w_{i1} & 0 & \dots & 0 \\ 0 & w_{i2} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & w_{in} \end{pmatrix}$$

$$W(u_i, v_i) = \text{diag}[w_1(u_i, v_i), w_2(u_i, v_i), \dots, w_n(u_i, v_i)]$$

Pembobot berupa matriks diagonal, elemen diagonalnya merupakan fungsi pembobot dari lokasi pengamatan. Penyelesaian Persamaan (2.4) diatas di misalkan koordinat $(u_i, v_i) = l$ dan dinyatakan dalam bentuk matriks adalah

:

$$\begin{aligned}
\varepsilon^T W(u_i, v_i) \varepsilon &= [Y - X\beta(u_i, v_i)]^T W(u_i, v_i) [Y - X\beta(u_i, v_i)] \\
\varepsilon^T W_l \varepsilon &= (Y - X\beta_l)^T W_l (Y - X\beta_l) \\
&= (Y^T - \beta_l^T X^T) W_l (Y - X\beta_l) \\
&= Y^T W_l Y - Y^T W_l X \beta_l - \beta_l^T X^T W_l Y + \beta_l^T X^T W_l X \beta_l \quad (2.5) \\
&= Y^T W_l Y - (Y^T W_l X \beta_l)^T - \beta_l^T X^T W_l Y + \beta_l^T X^T W_l X \beta_l \\
&= Y^T W_l Y - \beta_l^T X^T W_l Y - \beta_l^T X^T W_l Y + \beta_l^T X^T W_l X \beta_l \\
&= Y^T W_l Y - 2\beta_l^T X^T W_l Y + \beta_l^T X^T W_l X \beta_l
\end{aligned}$$

dengan

$$X\beta(u_i, v_i) = \beta^T(u_i, v_i)X^T \text{ dan } \beta_l = \begin{pmatrix} \beta_0(u_i, v_i) \\ \beta_1(u_i, v_i) \\ \vdots \\ \beta_k(u_i, v_i) \end{pmatrix}$$

(Yasin, 2011)

Selanjutnya minimumkan jumlah kuadrat errornya dengan mendifferensialkan persamaan (2.5) terhadap $\beta^T(u_i, v_i)$ atau β_l^T . Diperoleh :

$$\begin{aligned}
\frac{\partial(\varepsilon^T W_l \varepsilon)}{\partial \beta_l^T} &= \frac{\partial(Y^T W_l Y - 2\beta_l^T X^T W_l Y + \beta_l^T X^T W_l X \beta_l)}{\partial \beta_l^T} \\
&= 0 - 2X^T W_l Y + X^T W_l X \beta_l + W_l (X^T \beta_l^T X)^T \\
&= -2X^T W_l Y + X^T W_l X \beta_l + X^T W_l X \beta_l \\
&= -2X^T W_l Y + 2X^T W_l X \beta_l
\end{aligned}$$

$$2X^T W_l Y = 2X^T W_l X \beta_l$$

$$X^T W_l Y = X^T W_l X \beta_l$$

$$\beta_l = (X^T W_l X)^{-1} X^T W_l Y$$

karena l dimisalkan (u_i, v_i) , maka didapat estimator parameter GWR

$$\hat{\beta}(u_i, v_i) = (X^T W(u_i, v_i) X)^{-1} X^T W(u_i, v_i) Y \quad (2.6)$$

(Maulani, 2013).

2.5.2 Sifat-sifat Penaksir Paramater

Sifat penaksir $\widehat{\beta}(u_i, v_i)$ dari model GWR merupakan penaksir yang tak bias untuk $\beta(u_i, v_i)$

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

dan matriks kovariannya adalah sebagai berikut:

$$\begin{aligned} Cov[\widehat{\beta}(u_i, v_i)] &= Cov[(X^T W(u_i, v_i) X)^{-1} X^T W(u_i, v_i) Y] \\ &= (X^T W(u_i, v_i) X)^{-1} X^T W(u_i, v_i) Cov[Y] ((X^T W(u_i, v_i) X)^{-1} X^T W(u_i, v_i))^T \\ &= (X^T W(u_i, v_i) X)^{-1} X^T W(u_i, v_i) (\sigma^2 I) W(u_i, v_i) X (X^T W(u_i, v_i) X)^T \\ &= G G^T \sigma^2 \end{aligned}$$

dengan $G = (X^T W(u_i, v_i) X)^{-1} X^T W(u_i, v_i)$

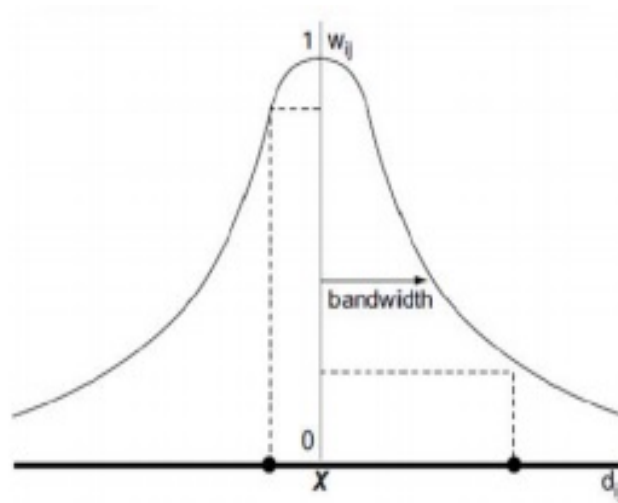
(Caraka, 2017)

2.6 Penentuan Bandwidth

Salah satu instrumen penting pada regresi spasial dalam mengukur baik atau tidaknya suatu model yaitu nilai *bandwidth*. Secara teori, *bandwidth* diartikan sebagai *radius* dari titik lokasi pusat sebagai acuan dalam penentuan bobot setiap wilayah untuk model regresi. Ketika pengamatan masih dalam radius artinya model pada lokasi tersebut masih dianggap memiliki pengaruh, maka model dapat diberi bobot. *Bandwidth* dikatakan dekat jika jarak euclidean (d_{ij}) masih berada dalam radius ($d_{ij} < b$)

Pemilihan *bandwidth* yang tepat akan mempengaruhi fungsi kernel, sehingga sangatlah penting metode pemilihan *bandwidth*. *Bandwidth* yang optimum mampu mengatur variansi dan bias dari model. Varian yang besar akan menyebabkan nilai *bandwidth* mengecil karna akan sedikit pengamatan yang berbeda dengan radius. Juga sebaliknya nilai *bandwidth* yang besar menyebabkan varians mengecil. Untuk menghindari heterogen dari varian, haruslah nilai *bandwidth optimum*. Menurut (Fortheringham dkk.,2002) terdapat beberapa metode penentuan bandwidth optimum yaitu :

1. Cross Validation (CV)



Gambar 2.2: Bandwidth

Perhitungan pada CV melibatkan dua kelompok data yaitu data validasi dan riil yang bersumber dari populasi lalu menghasilkan model relatif sama. Metode CV mampu mendapatkan kurva terbaik regresi, sehingga nilai *bandwidth* optimum. Berikut persamaan CV secara matematis :

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

dimana $\hat{y}_{\neq i}$ merupakan penduga y_i dimana lokasi pengamatan (u_i, v_i) dihilangkan dari proses estimasi guna mendapat radius yang optimal, sehingga mendapat CV minimum.

2. Akaike Information Criterion (AIC)

AIC adalah metode sebagai estimator kesalahan prediksi di luar sampel, dan didapat relatif kualitas model. Konsep AIC memperkirakan kualitas setiap model, relatif terhadap model lainnya .

$$AIC = 2k - 2\ln(\hat{L})$$

3. Bayesian Information Criterion (BIC)

Dalam statistik, kriteria informasi Bayesian(BIC) adalah kriteria pemilihan model diantara sekumpulan model terbatas. Nilai BIC yang rendah termasuk model yang terbaik. Hal ini didasarkan pada fungsi kemung-

kinan dan erat kaitannya dengan AIC.

$$BIC = \ln(n)k - 2\ln(\hat{L})$$

dengan L merupakan nilai maksimum likelihood, n menyatakan banyaknya sampel dan k jumlah parameter.

2.7 Pembobot GWR

Analisis model yang memperhatikan aspek spasial memerlukan pembobotan dalam perhitungannya. Hubungan kedekatan (neighboring) antarlokasi pengamatan dinyatakan dalam bentuk matriks pembobot W_{ij} (Bekti,2012). Elemen pada matriks berisi W_{ij} yang menyatakan kedekatan lokasi i dengan lokasi j . Pembobotan diberikan berdasarkan letak dari lokasi amatan, jika lokasi berada dekat dengan lokasi amatan diberikan bobot lebih besar sedangkan jika semakin jauh dari lokasi amatan maka bobot akan semakin mengecil. Pembobot yang terdapat pada model regresi spasial merupakan salah satu aspek yang sangat penting. Parameter $\beta_k(u_i, v_i)$ juga dipengaruhi oleh letak dan bobot. Jika bobotnya semakin besar maka lebih berpengaruh. Sedangkan pembobot dengan fungsi kernel mampu memberikan bandwidth optimum dimana nilainya sesuai dengan keadaan data. Terdapat 2 jenis fungsi kernel pada GWR yaitu fungsi fixed kernel dan adaptive kernel, (Wheeler dan Antonia, 2010). Fungsi kernel merupakan fungsi kontinu, simetris dan terbatas. Berikut jenis-jenis pembobot menurut (Fortheringham, Brundson, & Charlton, 2002)

2.7.1 Fungsi Jarak Invers

Pembobot dalam GWR dapat menggunakan Fungsi jarak invers, dimana akan diberikan bobot 1 jika titik lokasi j berada dalam radius, sedangkan diberikan bobot 0 jika lokasi j berada di luar radius. Fungsi dapat dituliskan seperti berikut :

$$W_j(u_i, v_i) = \begin{cases} 1 & : \text{jika } d_{ij} < b \\ 0 & : \text{jika } d_{ij} > b \end{cases}$$

dengan d_{ij} merupakan jarak euclidean antara titik lokasi pengamatan ke- i

dengan pengamatan ke- j (Fortheringham, Brundson, & Charlton, 2002). *Bandwidth* atau dianalogikan sebagai radius suatu kurva, dimana ketika suatu lokasi pengamatan masih berada dalam bandwidth artinya dianggap mempengaruhi dalam bentuk parameter di titik lokasi pengamatan ke- i . Fungsi pada jarak invers merupakan fungsi kontinu dan monoton turun. Nilai d_{ij} didefinisikan sebagai berikut

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

d_{ij} merupakan jarak euclidean antara lokasi (u_i, v_i) ke lokasi (u_j, v_j) dan b (bandwidth) merupakan parameter non negatif atau biasa disebut parameter penghalus.

2.7.2 Fungsi Kernel Fixed Bi-Square

Fungsi kernel pada pembobot GWR ini mengikut fungsi ganda *bi-weight* atau biasa disebut *bi-square*. Pada pembobot *Fixed bi-square* memiliki *bandwidth* yang sama untuk semua lokasi.

$$W_j(u_i, v_i) = \begin{cases} (1 - (\frac{d_{ij}}{b})^2)^2 & : \text{jika } d_{ij} \leq b \\ 0 & : \text{lainnya} \end{cases}$$

dengan $W_j(u_i, v_i)$ merupakan matriks pembobot spasial untuk setiap lokasi, d_{ij} sebagai jarak euclidean. Fungsi kernel diberikan bobot nol jika lokasi- j berada di luar radius b , dan apabila lokasi- j berada dalam radius akan diberi bobot sesuai fungsi kernel.

2.7.3 Fungsi Kernel Adaptive Bi-Square

Fungsi kernel ini sama seperti fungsi di atas, yang membedakan hanyalah nilai *bandwidth* yang berbeda untuk semua lokasi.

$$W_j(u_i, v_i) = \begin{cases} (1 - (\frac{d_{ij}}{b})^2)^2 & : \text{jika } d_{ij} \leq b \\ 0 & : \text{lainnya} \end{cases}$$

dimana $W_j(u_i, v_i)$ merupakan matriks pembobot, d_{ij} merupakan jarak euclidean dan *bandwidth* (b) yang diberikan berdasarkan banyaknya lokasi dekat pengamatan. Jadi Fungsi kernel adaptif ini memiliki nilai *bandwidth* yang berbeda untuk setiap titik lokasi pengamatan (Lutfiani,2017). Dikarenakan sifat dari fungsi kernel yang mampu menyesuaikan kondisi pengamatan.

2.7.4 Fungsi Kernel Fixed Gaussian

Fungsi ini biasa disebut kernel normal (*gaussian*), pembobot kernel dapat ditulis sebagai berikut :

$$W_j(u_i, v_i) = \exp\left[-\frac{1}{2}\left(\frac{d_{ij}}{b}\right)^2\right]$$

dimana $W_j(u_i, v_i)$ menyatakan sebagai matriks pembobot untuk fixed Gaussian, dan d_{ij} adalah jarak euclidean. Formulasi pada kernel *fixed* maupun *adaptive* Gaussian sama. Perbedaannya terletak pada nilai *bandwidth* dan b merupakan *bandwidth* yang sama yang digunakan untuk setiap lokasi.

2.7.5 Fungsi Kernel Adaptive Gaussian

Fungsi *adaptive gaussian* merupakan pembobot kernel normal dengan nilai *bandwidth* yang berbeda untuk setiap lokasi. Fungsi dapat dituliskan sebagai berikut:

$$W_j(u_i, v_i) = \exp\left[-\frac{1}{2}\left(\frac{d_{ij}}{b_{i(q)}}\right)^2\right]$$

dengan $W_j(u_i, v_i)$ merupakan matriks pembobot untuk setiap lokasi, d_{ij} sebagai jarak antar lokasi pengamatan, dan $b_{i(q)}$ merupakan *bandwidth* adaptif atau berbeda untuk setiap titik lokasi yang menetapkan q sebagai jarak antar lokasi yang berdekatan dengan lokasi i .

2.8 Uji Hipotesis Model GWR

Pengujian ini dilakukan untuk mengetahui signifikansi pengaruh dari faktor geografis dari suatu model, sama seperti pada model regresi global dimana terdapat uji secara simultan (Uji F) dan uji parsial (Uji T).

2.8.1 Pengujian Kelayakan Model

Pengujian dengan hipotesis :

$H_0 : \beta_k(u_i, v_i) = \beta_k, k = 1, 2, \dots, n$ (Tidak ada pengaruh faktor geografis pada model)

$H_1 :$ Paling sedikit ada satu $\beta_k(u_i, v_i)$ yang berhubungan dengan lokasi (u_i, v_i) (Terdapat pengaruh geografis)

Statistik Uji

$$F_{hit} = \frac{SSE(H_0)/df_1}{SSE(H_1)/df_2}$$

dengan :

$$SSE(H_0) : Y * T(I - H)Y \text{ dimana } H = X(X^T X)^{-1} X^T$$

$$df_1 = n - p - 1$$

$$SSE(H_1) = Y^T (I - S)^T (I - S) Y$$

$$df_2 = (n - 2tr(S) + tr(S^T S))$$

dimana S merupakan matriks proyeksi dari model GWR, dengan proyeksi y ke \hat{y}

$$S = \begin{pmatrix} x_1^t [X'W(u_1, v_1)X]^{-1} X'W(u_1, v_1) \\ x_2^t [X'W(u_2, v_2)X]^{-1} X'(u_2, v_2) \\ \vdots \\ x_n^t [X'W(u_n, v_n)X]^{-1} X'(u_n, v_n) \end{pmatrix}$$

I merupakan matriks identitas ordo n . Dengan kriteria pengambilan keputusan apabila $F_{hit} > F_{table}(F_{(\alpha; df_1, df_2)})$ maka tolak H_0 dengan kata lain terdapat pengaruh geografis sehingga termasuk kedalam model yang layak atau kategori *goodness of fit* lebih baik dari regresi global.

2.8.2 Pengujian Parameter Model GWR

Jika pengujian model seluruhnya sudah dijalankan dan terindikasi mempengaruhi maka setidaknya terdapat satu variabel bebas yang memiliki pengaruh, selanjutnya diperlukan pengujian lebih lanjut untuk mengetahui setiap parameter model GWR yang memiliki pengaruh pada variabel respon dengan Uji secara parsial (Uji T). Hipotesisnya :

$H_0 : \beta_k(u_i, v_i) = 0$ (Tidak ada pengaruh variabel bebas terhadap variabel respon)

$H_1 : \beta_k(u_i, v_i) \neq 0$ (Terdapat pengaruh signifikan antara variabel bebas terhadap respon)

Statistik Uji

$$t_{hit} = \frac{\hat{\beta}_k(u_i, v_i)}{SE[\hat{\beta}_k(u_i, v_i)]}$$

dimana $SE[\hat{\beta}_k(u_i, v_i)] = \sqrt{var \hat{\beta}_k(u_i, v_i)}$.

$\widehat{\beta}_k(u_i, v_i)$ merupakan penaksiran yang tak bias, efisien dan juga konsisten bagian $\beta(u_i, v_i)$. Hasil dari perhitungan t_{hit} memiliki kriteria pengambilan keputusan yaitu apabila $|t_{hit}| > t_{\frac{\alpha}{2}; df_2}$ maka tolak H_0 .

2.9 Pemilihan Model Terbaik

2.9.1 Koefisien Determinasi (R^2)

Dalam model regresi linear, koefisien determinasi digunakan untuk melihat seberapa besar variansi dalam data pengamatan yang dapat menjelaskan model. Koefisien determinasi (R^2) dan nilai AIC yang kecil dapat dijadikan untuk membandingkan manakah model yang terbaik untuk data. Nilai R^2 yang kecil atau semakin mendekati nol artinya kemampuan model terbatas dalam menjelaskan. Sebaliknya jika nilai R^2 mendekati 1 maka kemampuan model dalam menjelaskan pengaruh variabel bebas terhadap terikat sangat kuat. Berikut adalah koefisien determinasi pada regresi linear berganda :

$$R^2 = \frac{JKR}{JKT} = \frac{\widehat{\beta}_k^T X^T y - n\bar{y}^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

Sedangkan dalam model GWR koefisien determinasi dapat ditentukan dengan persamaan berikut :

$$R_i^2 = \frac{JKT_{GWR} - JK S_{GWR}}{JKT_{GWR}}$$

$$JKT_{GWR} = \sum_{j=1}^n w_{ij} (Y_j - \bar{Y})^2$$

$$JK S_{GWR} = \sum_{j=1}^n (Y_j - \bar{Y}_j)^2$$

Keterangan:

JKT_{GWR} = Jumlah kuadrat total model GWR

$JK S_{GWR}$ = Jumlah kuadrat residual model GWR

w_{ij} = Pembobot lokasi pengamatan ke- j dari lokasi pengamatan ke- i

2.9.2 Akaike Information Criterion (AIC)

Pada sebelumnya AIC bisa digunakan untuk mencari *bandwidth optimum* namun sedikit berbeda dari formulasi. Nilai AIC yang mampu digunakan sebagai bahan pertimbangan mendapatkan model terbaik yaitu formulasinya mengandung matriks proyeksi dan banyaknya parameter. Nilai AIC yang semakin kecil menunjukkan model semakin baik. Kriteria AIC dirumuskan dengan :

$$AIC = 2n \ln(\sigma) + \ln(2\pi) + n + tr(s)$$

dimana :

n : banyaknya parameter

σ : nilai estimator standar deviasi dari residual

S : Matriks proyeksi atau hat matriks.

$tr(s)$: trace dari matriks proyeksi.

π : 3.14

BAB III

Metodologi Penelitian

3.1 Pendekatan Penelitian

Metode penelitian ini menggunakan pendekatan kuantitatif, dimana pengolahan data berupa angka sebagai alat analisis sehingga menghasilkan penemuan yang dapat dicapai dengan prosedur statistik. Teknik Pengumpulan data pada kepenulisan ini menggunakan studi pustaka, karna penulis melakukan kegiatan kepustakaan melalui jurnal-jurnal terdahulu, buku, dan penelitian terdahulu sebagai acuan dalam penelitian ini.

3.2 Populasi dan sampel penelitian

Populasi yang digunakan pada penulisan penelitian yaitu data penduduk di Indonesia meliputi 34 Provinsi. Sementara dalam penelitian ini tidak memerlukan sampel karena data yang diperoleh termasuk data jadi yang tersedia pada publikasi di website BPS Indonesia, meliputi data pengangguran terbuka, angkatan kerja, keluhan kesehatan, dan persentase penduduk miskin.

3.3 Variabel Penelitian

Variabel pada penelitian ini menggunakan dua variabel yaitu variabel dependen (Y) dan variabel independen (X). Adapun macam-macam variabelnya yaitu:

Y : Tingkat Pengangguran Terbuka (TPT).

X_1 : Angkatan Kerja

X_2 : Keluhan Kesehatan

X_3 : Persentase Penduduk Miskin

3.4 Sumber Data

Data yang digunakan penelitian ini yaitu data sekunder, dengan menggunakan dokumen atau catatan tertulis yang sudah dipublikasikan. Data mengenai tingkat pengangguran terbuka di Indonesia tahun 2020 dan faktor yang mempengaruhinya diperoleh dari publikasi Statistik Indonesia 2021 yang dapat diakses di *website* bps.go.id.

3.5 Tahapan Analisis Data

Langkah penelitian terbagi menjadi dua metode yaitu regresi linear berganda dan *Geographically Weighted Regression* (GWR). Pengolahan data menggunakan alat bantu *software excel*, SPSS ,R , qgis dan Geoda.

1. Melakukan analisis dengan Regresi Linear Berganda
 - a. Menghimpun data dan menyusun di *excel*.
 - b. Menginput data pada spss lalu melakukan analisis.
 - c. Menaksir model regresi global.
 - d. Melakukan uji asumsi klasik sehingga memenuhi normalitas, tidak mengandung multikolinearitas, tidak terdapat autokorelasi dan homoskedastisitas.


2. Melakukan Uji Spasial
 - a. Memeriksa terdapatnya heterogenitas spasial dengan uji *breusch-pagan*. Jika data mengandung heterogenitas maka selanjutnya dilakukan analisis GWR.
 - b. Menguji autokorelasi spasial dengan menggunakan uji Morans.

3. Melakukan analisis dengan GWR
 - a. Menginput data dalam bentuk txt ke R
 - b. Memilih *bandwidth* yang akan digunakan pada pemodelan
 - c. Menentukan d_{ij} jarak euclidean antara lokasi (u_i, v_i)
 - d. Menentukan pembobot dengan menggunakan fungsi pembobot kernel
 - e. Mendapat model untuk setiap daerah
 - f. Menganalisis variabel yang signifikan di setiap lokasi
 - g. Membuat peta tematik dengan aplikasi Geoda dan Qgis

- h. Membandingkan model GWR dengan regresi linear berganda dari nilai R^2
- i. Menarik kesimpulan

3.6 Diagram Alir

Proses Penelitian dimulai dengan mengumpulkan data, lalu input data pada *software excel*. Untuk mengetahui kevalidan suatu model dilakukan uji asumsi klasik, jika tidak terpenuhi terutama pada asumsi homogenitas ragam, maka dilanjutkan dengan uji heterogenitas spasial lalu dilanjutkan proses menemukan model GWR sehingga didapat beberapa model dari GWR. Tidak terpenuhinya asumsi kehomogenan berimplikasi bahwa setiap pengamatan memiliki informasi yang lebih dan mendapatkan bobot yang berbeda dari pengamatan umumnya. Sifat dari metode kuadrat terkecil pun menjadi bias, karena tidak akan menghasilkan ragam yang minimum. Disisi lain dalam mengetahui apakah model GWR lebih baik dari model regresi linear berganda, maka penulis menggunakan hasil regresi linear berganda walaupun presisi/kecermatan pada penduga OLS menjadi lebih kecil jika dibandingkan dengan penduga yang mengakomodir ketidakhomogenan ragam (Rawlings, Pantula dan Dickey, 1998). Mencari model terbaik didapat dalam memodelkan TPT di Indonesia, dengan melihat nilai R^2 dan AIC sehingga didapat suatu kesimpulan dalam penelitian.



Gambar 3.1: Diagram Alir

BAB IV

Hasil dan Pembahasan

4.1 Deskripsi Data


Pada penelitian analisis model Geographically Weighted Regression (GWR) di sini menggunakan 4 variabel yang terdiri dari satu variabel dependen yaitu Tingkat Pengangguran Terbuka (TPT) dan tiga variabel independen yaitu angkatan kerja (X1), keluhan kesehatan (X2) dan persentase penduduk miskin (X3). Gambaran umum mengenai informasi data yang digunakan, disajikan secara deskriptif sebagai berikut :

Tabel 4.1: Descriptive Statistics

	N	Minimum	Maximum	Mean	Std. Deviation	Variance
Y	34	3.32	10.95	6.0388	2.01092	4.044
X1	34	63.4	74.32	68.0642	2.91368	8.49
X2	34	31.48	61.32	44.685	6.77758	45.936
X3	34	4.45	26.8	10.8056	5.41299	29.3

Dari Tabel 4.1 kita mengetahui bahwa terdapat 34 data provinsi di Indonesia untuk setiap variabelnya. Rata-rata persentase tingkat pengangguran di Indonesia 2020 sebesar 6.03 % tentunya mengalami kenaikan jika dibandingkan dengan tahun sebelumnya 2019 yaitu 4.68 % . Berikut disajikan pada Gambar 4.1 peta penyebaran pengangguran terbuka di Indonesia.

Dari peta Indonesia pada masalah pengangguran di Indonesia masih banyak titik wilayah yang memiliki warna cukup gelap artinya masih memiliki pengangguran dengan jumlah yang tak sedikit. Ketidakseimbangan dan bahkan ketimpangan pada ketersediaan lapangan kerja terhadap jumlah pencari kerja terbilang banyak membuat pengangguran ini semakin meningkat. Persentase tingkat pengangguran terbuka yang memiliki kategori sangat tinggi di Indonesia pada 2020 terdapat 4 provinsi yaitu provinsi DKI Jakarta, Banten, Jawa Barat dan Kepulauan Riau. Kondisi tingkat pengangguran Indonesia yang




Gambar 4.1: Tingkat Pengangguran Terbuka

cukup banyak atau termasuk kategori menengah terdapat 13 provinsi yaitu Bali, Maluku, Kalimantan Timur, Sumatera Barat, Sumatera Utara, Papua Barat, Sulawesi Utara, Jawa Timur, Jawa Tengah, Aceh, Kalimantan Barat, Sulawesi Selatan dan Riau. Pada Kategori tpt rendah terdapat 17 provinsi yaitu Bangka Belitung, Gorontalo, Sumatera selatan, Bengkulu, Lampung, NTB, Jambi, Yogyakarta, Kalimantan selatan, Kalimantan utara, Sulawesi barat, Maluku utara, Kalimantan Tengah, NTT, Sulawesi tenggara, Sulawesi Tengah dan Papua. Tingginya angka persentase TPT beberapa faktor diantaranya penulis rangkum pada kesatuan variabel independen.

Faktor yang pertama yaitu Angkatan Kerja, dimana diduga sangat berpengaruh. Angka ini didapat dari membandingkan penduduk Angkatan kerja dengan banyak penduduk usia kerja saat ini, sehingga masih satu jalur dengan tersedia atau tidaknya lapangan pekerjaan. Rata- Rata Angkatan Kerja di Indonesia tahun 2020 yaitu tercatat 68.04%, dengan gambaran sebaran di Indonesia jika disajikan dalam bentuk peta.

Persentase Angkatan Kerja Tertinggi yang tergolong tinggi terdapat di 5 provinsi di Indonesia, mayoritasnya terletak pada beberapa provinsi di Nusa Tenggara, persentase tertinggi yaitu provinsi Bali dengan persentase 74.32%, dan tidak jauh dari Bali yaitu Nusa Tenggara Timur memiliki angkatan kerja tertinggi kedua yaitu 73.11%. Angkatan kerja yang tergolong sedang terdapat di 15 provinsi. Sedangkan Provinsi dengan persentase angkatan kerja rendah terdapat 14 provinsi dimana provinsi dengan angkatan terendah terletak di Sulawesi Selatan dengan 63.4%.

Faktor Kedua yang diduga mempengaruhi yaitu Keluhan Kesehatan. Fak-



Gambar 4.2: Angkatan Kerja

tor ini diambil berdasarkan kondisi saat ini yang cukup berdampak pada perekonomian di Indonesia yaitu Pandemi selama virus Covid-19 menyebar ke Indonesia dalam waktu yang tidak sebentar. Dengan demikian kuantitas aktivitas pun menurun juga tidak sedikit masyarakat Indonesia yang mengalami sakit dan penurunan stamina. Rata- Rata Keluhan Kesehatan di Indonesia 2020 yaitu mencapai 44.68% . Berikut penulis sajikan gambaran kuantitas dari keluhan kesehatan di Indonesia



Gambar 4.3: Keluhan Kesehatan

Persentase Keluhan Kesehatan di Indonesia mayoritas berada di rata-rata yaitu sebanyak 21 provinsi di Indonesia. Namun masih beberapa yang memiliki persentase tinggi sebanyak 3 wilayah yaitu Bali, Aceh, dan Sumatera Barat dengan berturut-turut 61.32% , 57.92% , dan 57.25% . Sedangkan Provinsi dengan kategori keluhan kesehatan yang rendah terdapat 10 provinsi, dengan yang terendah yaitu Kalimantan Tengah dan Kalimantan Selatan ya-

itu berturut-turut 31.48% dan 32.52%.

Faktor ketiga yang diduga yaitu persentase penduduk miskin. Seiring dengan terus berjalannya lini ekonomi dan sosial pengangguran dan kemiskinan sering dijadikan tolok ukur sehingga data yang terlihat seolah olah saling mempengaruhi naik turunnya dua faktor berdampingan tersebut. Persentase rata-rata penduduk miskin di Indonesia yaitu 10.8% . Berikut penulis sajikan kondisi sebaran penduduk miskin di Indonesia.



Gambar 4.4: Persentase Penduduk Miskin

Indonesia sebagai negara berkembang memiliki tingkat penduduk miskin tidak cukup tinggi namun masih memiliki penduduk dengan kategori miskin. Provinsi di Indonesia yang tergolong persentase penduduk miskin tertinggi yaitu terletak di Provinsi Papua, Papua Barat, Nusa Tenggara Timur dan Maluku dengan persentase berturut-turut 26.8% , 21.7% , 21.21% dan 17.99%. Penduduk miskin dengan kategori sedang terdapat 12 provinsi, sedangkan persentase penduduk miskin rendah cukup banyak yaitu terdapat 18 provinsi dimana terendah terletak di Provinsi Bali dengan 4.45%.

4.2 Uji Asumsi Klasik

Pengujian dilakukan guna mengetahui model yang dihasilkan nantinya memenuhi atau tidaknya asumsi pada regresi.

4.2.1 Homoskedastisitas

Uji homoskedastisitas dimana untuk mengetahui bahwa data pada galat/error dipengaruhi tidaknya oleh faktor lain. Model regresi dikatakan baik bila tidak terjadi gejala heteroskedastisitas maka haruslah memiliki kesamaan varians dari residual (konstan), sehingga dilakukan pengujian statistik menggunakan uji Glejser dibantu dengan software SPSS 16. Kaidah kerja uji ini dengan meregresikan variabel independen terhadap nilai absolute residual kriteria pengambilan keputusan Jika nilai signifikansi lebih besar dari 0.05 maka data homoskedastisitas , dan sebaliknya jika kurang dari 0.05 maka data terjadi gejala heteroskedastisitas. Berikut hasil uji disajikan pada table 4.2

Tabel 4.2: Uji Glejser

	signifikansi	Keterangan
(constant)	0.00	
X1	0.00	Heteroskedastisitas
X2	0.286	Homoskedastisitas
X3	0.744	Homoskedastisitas

Terlihat pada hasil di atas bahwa data mengandung gejala heteroskedastisitas sehingga mungkin dipengaruhi oleh faktor lain. Heteroskedastisitas di sini mengakibatkan beberapa pengamatan mengandung informasi lebih . Demikian juga pengamatan kasus pengangguran ini, mendapatkan bobot yang lebih besar dibandingkan pengamatan lainnya. Faktor yang dimaksud di sini kemungkinan besar yaitu faktor lokasi atau spasial. Kondisi data seperti ini perlu dilakukan penanganan lanjut yaitu dengan mengecek apakah data termasuk data spasial. Jika demikian hasil dengan OLS nantinya mengandung presisi yang rendah disebabkan ketidakhomogenan ragam.

4.2.2 Uji Normalitas

Pada model Regresi data yang berdistribusi harus memenuhi asumsi kenormalan. Pengujian normalitas di sini menggunakan Kolmogorov smirnov dengan hipotesis :

H_0 = Galat berdistribusi normal

H_1 = Galat tidak berdistribusi normal

dengan kriteria uji tolak H_0 jika $|D| > q_{(34;0.05)}$

Berikut hasil uji Kolmogorov smirnov :

Tabel 4.3: Uji Kolmogorov-smirnov

	$ D $	P-value
Galat	0.09	0.200

Tabel 4.3 menunjukkan bahwa $|D| = 0.09 < q_{(34,0.05)} = 0.224$ dan nilai p -value > 0.05 , sehingga disimpulkan data berdistribusi normal.

4.2.3 Uji Multikolinearitas

Uji Multikolinearitas bertujuan untuk memastikan bahwa antar variabel independen tidak terjadi multikolinearitas artinya tidak terdapat hubungan linear yang kuat antar variabel bebas. Uji ini memanfaatkan nilai dari VIF dan tolerance dengan ketentuan apabila $VIF < 10$ dan $tolerance > 0.1$ maka kondisi seperti ini dinyatakan tidak terjadi multikolinearitas. Pengujian dilakukan dengan bantuan software SPSS dengan melihat pada table *coefficent*. Hasil uji multikolinearitas disajikan dalam tabel berikut:

Tabel 4.4: Coefficient

	Tolerance	VIF
X1	0.837	1.194
X2	0.977	1.024
X3	0.828	1.208

Berdasarkan hasil pada tabel 4.4 semua variabel memenuhi syarat tidak terjadi multikolinearitas. Jadi data yang digunakan tidak memiliki hubungan linear yang kuat antara variabel bebas.

4.2.4 Uji Autokorelasi

Uji autokorelasi dilakukan untuk mengetahui eksistensi korelasi antar sampel berdasarkan urutan waktu, dengan melihat nilai residual pada pengamatan

satu dengan lainnya. Pada data yang baik tidak terjadi gejala autokorelasi. Menurut beberapa penelitian autokorelasi sering muncul pada observasi data runtun waktu. Pengujian autokorelasi di sini menggunakan uji Durbin Watson. Berikut disajikan hasil ujinya :

Tabel 4.5: Hasil Uji Durbin Watson

Nilai d	dl	du	$4 - dl$	$4 - du$	Kriteria
1.684	1.271	1.652	2.729	2.348	$1.652 < 1.684 < 2.348$

Dari hasil tabel 4.5 keputusan yang diambil adalah terima H_0 yang artinya data tidak mengandung autokorelasi, dikarenakan nilai d berada pada $du_{(3;34)} < d < 4 - du_{(3;34)}$ sehingga tidak ada autokorelasi positif ataupun negatif. Setelah memenuhi semua uji asumsi klasik maka model regresi yang dibentuk terbilang *valid*.

4.3 Regresi Linear Berganda

Analisis pada Regresi linear bertujuan untuk mengetahui pengaruh suatu variabel dengan variabel yang diduga berpengaruh. Dalam penelitian ini penulis ingin mengetahui pengaruh angkatan kerja, keluhan kesehatan dan penduduk miskin terhadap tingkat pengangguran terbuka di Indonesia. Estimasi parameter pada regresi linear berganda didapat dengan metode Ordinary least square (OLS), perhitungan dengan *software* R 3.4.1 . Berikut hasil analisisnya :

Tabel 4.6: Parameter Regresi

Variabel	Estimasi Parameter
Intercept	29.760
X1	-0.395
X2	0.085
X3	-0.058

Model dapat dibentuk dalam persamaan regresi linear berganda , yaitu :

$$Y = 29.760 - 0.395X_1 + 0.085X_2 - 0.058X_3$$

Untuk mengetahui apakah model yang terbentuk benar memiliki pengaruh, maka terlebih dahulu dilakukan pengujian. Pengujian di sini terbagi dua yaitu uji secara simultan dan parsial.

Pengujian secara keseluruhan atau simultan, berguna untuk mengetahui secara keseluruhan terdapat atau tidaknya pengaruh variabel independen terhadap variabel dependen. Menggunakan tabel Analisis of Variance (ANOVA) maka dapat diketahui nilai F_{hitung} . Kriteria tolak H_0 (memiliki pengaruh signifikan) jika $F_{hit} > F_{tabel}$. Berikut disajikan hasil anova :

Tabel 4.7: ANOVA

Sumber Variasi	DB	Jumlah Kuadrat	Kuadrat Total	F_{hit}	F_{tabel}
Regresi	3	61.522	20.507	8.544	2.92
Galat	30	71.923	2.397		
Total	33	133.445			

Berdasarkan hasil table 4.7 $F_{hit} = 8.554 > F_{(0.05;3;30)} = 2.92$ artinya setidaknya terdapat variabel independen yang memiliki pengaruh signifikan terhadap variabel TPT . Artinya model yang terbentuk sesuai dengan regresi karna memiliki pengaruh.

Pengujian parsial menggunakan Uji T . Uji dilakukan untuk mengetahui pastinya variabel apa saja yang memiliki pengaruh terhadap variabel dependen. Kriteria uji yaitu suatu variabel memiliki pengaruh signifikan jika $|t_{hit}| > t_{(n-p-1, \frac{0.05}{2})}$ atau dapat juga melihat nilai $sig < 0.05$ maka memiliki pengaruh yang signifikan. Berikut hasil pengujian

Tabel 4.8: Uji T

Variabel	T_{hit}	Sig	Kesimpulan
Intercept	4.370	0.00	Signifikan
X1	-3.912	0.00	Signifikan
X2	2.121	0.042	Signifikan
X3	-1.062	0.297	Tidak Signifikan

Berdasarkan nilai hasil Uji $|t_{hit}| > t_{(n-p-1, \frac{0.05}{2})} = 2.042$ dan nilai signifikansi < 0.05 terdapat 2 variabel yang memenuhi. Variabel yang memiliki pengaruh

signifikan pada model Tingkat Pengangguran Terbuka (TPT) yaitu angkatan kerja dan keluhan kesehatan, sehingga model regresi linear berganda yang terbaik :

$$\hat{Y} = 29.760 - 0.395X_1 + 0.085X_2$$

Konstanta sebesar 29.760 artinya jika angkatan kerja (X_1) dan Keluhan Kesehatan (X_2) nilainya nol, maka persentase TPT (\hat{Y}) bernilai 29.76 . Jika variabel independen lainnya bernilai tetap dan angkatan kerja mengalami kenaikan 1% , maka persentase TPT (\hat{Y}) mengalami penurunan sebesar 0.395. Persentase keluhan kesehatan jika mengalami kenaikan satu satuan (%) maka tingkat pengangguran akan mengalami kenaikan sebesar 0.085.

Koefisien determinasi (R^2) pada model regresi linear berganda sebesar 46.1%. Kondisi seperti mengartikan bahwa variansi variabel independen yang digunakan dalam model mampu menjelaskan sebesar 46.1% variabel persentase TPT, sisanya dipengaruhi atau dijelaskan oleh variabel lain yang tidak terdapat dalam penelitian ini. Model regresi ini memiliki nilai AIC sebesar 131.9619.

4.4 Data Spasial

Karena pengujian sebelumnya menghasilkan bahwa data terpengaruh oleh faktor lain, maka penulis ingin menguji keberadaan faktor tersebut. Karena faktor lokasi yang diduga menjadi bagian dari data uji, maka dilakukanlah uji heterogenitas spasial sebagai syarat uji regresi spasial dan uji autokorelasi untuk mengetahui korelasi

4.4.1 Uji Heterogenitas Spasial

Bagian yang paling penting dari uji regresi spasial yaitu uji heterogenitas spasial. Pengujian statistik yang digunakan yaitu Uji Breusch-Pagan (BP). Penerapan uji ini dilakukan dengan meresidu kuadrat terhadap variabel independen. Kriteria uji ini adalah jika *p-value* kurang dari 0.05 maka mengandung heterogenitas spasial, berlaku juga sebaliknya jika lebih dari 0.05 maka tidak ada gejala heterogenitas spasial. Berikut hasil uji BP:

Terlihat bahwa pada table 4.9 nilai P-value < 0.05 maka data mengandung heterogenitas spasial, selain itu bisa juga dilihat dari nilai BP $\chi^2_{(0.05,3)}$ dimana


Tabel 4.9: Uji Breusch-Pagan

Nilai BP	df	P-value
10.506	3	0.01472

$10.506 > 7.815$. Maka dapat disimpulkan data mengandung heterogenitas spasial, artinya data yang digunakan termasuk data spasial.

4.4.2 Autokorelasi Spasial

Pengujian statistik autokorelasi spasial yang digunakan pada penelitian ini yaitu Uji Moran. Penerapan aplikasi ini dibantu dengan *software* geoda. Jika nilai indeks moran $-1 < I < 0$ maka artinya memiliki autokorelasi yang negative, namun jika $0 < I < 1$ maka menunjukkan autokorelasi yang positif. Berikut hasil dari moran scatter plot pada Tingkat Pengangguran terbuka di Indonesia:



Gambar 4.5: Scatterplot lag TPT

Nilai Indeks Moran(I) pada TPT yaitu 0.453 , maka

$$I = \frac{n \sum_{(i=1)}^n \sum_{j=1}^n w_{ij} (y_i - \bar{y})(y_j - \bar{y})}{\sum_{i=1}^n \sum_{j \neq 1}^n w_{ij} \sum_{i=1}^n (y_i - \bar{y})^2} = 0.453$$

$$E(I) = \frac{-1}{n-1} = -0.0303$$

$$Var(I) = \frac{n^2 S_1 - n S_2 + 3 S_0^2}{(n^2 - 1) S_0^2} - [E(I)]^2 = 4.043786$$

Hasil di atas akan digunakan untuk mengetahui adanya korelasi spasial, dengan hipotesis berikut


H_0 : Tidak terdapat autokorelasi spasial

H_1 : Terdapat autokorelasi spasial

Kriteria penolakan H_0 Jika $|Z(I)| > Z_{\frac{\alpha}{2}}$ dengan $\alpha = 0.05$, berikut hasil pengujian :

$$Z(I) = \frac{I - E(I)}{\sqrt{Var(I)}} = \frac{0.453 - (-0.0303)}{\sqrt{4.043786}} = 0.24034$$

Dari hasil perhitungan $|Z(I)| > Z_{\frac{\alpha}{2}}$, yaitu $0.24034 > -1.95996$, maka keputusannya adalah tolak H_0 artinya terdapat autokorelasi spasial pada tingkat pengangguran terbuka di Indonesia 2020. Pada Gambar 4.5 nilai I berada di antara 0 dan 1 yaitu 0.453 sehingga termasuk autokorelasi spasial positif. Berikut disajikan hasil autokorelasi setiap variabel :




Gambar 4.6: Scatterplot lag X1

Tabel 4.10: Morans X1

Variabel	I	$Var(I)$	$Z(I)$	Keputusan
X1	0.373	8.48952	0.13842	Autokorelasi spasial positif

Dari gambar 4.6 terlihat bahwa nilai indeks moran 0.373 yang artinya memiliki autokorelasi yang positif pada angkatan kerja. Terlihat pada gambar bahwa terdapat 11 lokasi yang terdapat di kuadran I artinya memiliki nilai pengamatan yang tinggi dan dikelilingi daerah dengan nilai yang tinggi juga. Pada kuadran 2 terdapat 5 lokasi ysng artinya lokasi tersebut memiliki nilai yang rendah namun dikelilingi nilai yang tinggi. Pada kuadran 3 terdapat 8

lokasi yang artinya memiliki nilai rendah dan dikelilingi nilai pengamatan yang rendah juga. Dan pada kuadran 4 terdapat 6 lokasi dengan nilai yang tinggi namun dikelilingi dengan nilai rendah.



Gambar 4.7: Scatterplot lag X2

Tabel 4.11: Morans X2

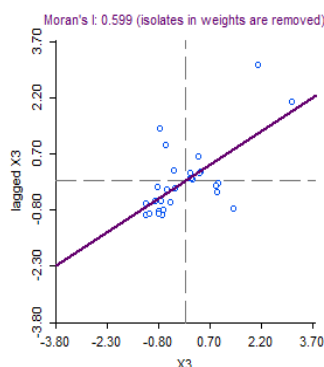
Variabel	I	$Var(I)$	$Z(I)$	Keputusan
X2	0.25	45.9536	0.04136	Autokorelasi spasial positif

Gambar 4.7 menunjukkan bahwa nilai indeks moran 0.250 yang artinya terdapat aukorelasi yang positif pada persentase keluhan kesehatan. Scatter menunjukkan 9 lokasi pada kuadran I dengan nilai tinggi dan bertetangga dengan lokasi nilai tinggi juga. Selanjutnya terdapat 6 lokasi memiliki nilai pengamatan yang rendah namun bertetangga dengan nilai pengamatan yang tinggi. Kuadran tiga terdapat 9 lokasi dengan nilai pengamatan yang rendah dan dikelilingi juga oleh nilai pengamatan yang rendah. Pada kuadran IV terdapat 6 lokasi dengan nilai pengamatan yang tinggi dan dikelilingi oleh nilai pengamatan yang rendah.

Tabel 4.12: Morans X3

Variabel	I	$Var(I)$	$Z(I)$	Keputusan
X3	0.599	29.3005	0.11626	Autokorelasi spasial positif

Gambar 4.8 menunjukkan nilai indeks moran yaitu 0.599 artinya memiliki



Gambar 4.8: Scatterplot lag X3

autokorelasi positif pada persentase penduduk miskin. Jika dilihat dari grafik scatterplot terdapat 6 lokasi yang memiliki nilai pengamatan yang tinggi dan bertetangga dengan nilai yang tinggi juga. Terdapat 3 lokasi dengan nilai pengamatan yang rendah dan bertetangga dengan nilai pengamatan yang tinggi. Sedangkan pada kuadran 3 terdapat 13 lokasi dengan nilai kemiskinan yang rendah dan dikelilingi oleh nilai yang rendah juga. Terdapat 4 lokasi dengan nilai kemiskinan yang tinggi dan dikelilingi nilai kemiskinan yang tinggi.

4.5 Pemodelan Geographically Weighted Regression

Ketika data mengandung heterogenitas spasial maka pemodelan dapat dilakukan dengan pendekatan titik yaitu dengan Geographically weighted Regression (GWR). Metode ini merupakan regresi spasial, sehingga dapat menunjukkan adanya pengaruh letak geografis terhadap regresi. Salah satu instrumen yang penting di sini yaitu *bandwidth*. *Bandwidth* merupakan radius dari titik lokasi pengamatan sebagai acuan untuk menentukan bobot setiap wilayah. Pembobotan pada model regresi dipengaruhi oleh *bandwidth* itu sendiri dengan sifat *bandwidth* yang *adaptive* dan *fixed*. Jenis dari pembobotan juga terbagi dua yaitu kernel Gaussian dan kernel Bi-square.

Metode regresi spasial ini memang memiliki keunikan dimana model memerlukan pembobot dalam perhitungannya. Parameter regresi pun mengandung bobot dan koordinat lokasi, sehingga pembobotan menjadi sangat penting dalam model GWR. Pembobotan yang diberikan pun berdasarkan letak

lokasi pengamatan dimana semakin dekat dengan lokasi maka akan diberikan bobot yang semakin besar dan demikian juga sebaliknya. Penulis membagi penelitian dengan empat bobot yaitu:

- Fixed Gaussian

Pada kernel *Gaussian fixed* maka nilai bandwidth yang diperoleh hanya satu nilai yang optimum. Metode CV dapat menemukan nilai bandwidth optimum dimana nilainya sama untuk semua lokasi. Perhitungan hasil nilai bandwidth (b) terletak pada lampiran 5. Didapatkan dengan melihat nilai CV yang paling kecil, nilai bandwidth (b) yang paling optimum yaitu 5.334214. Setelah mendapatkan b dan pembobot untuk setiap wilayah provinsi maka didapatkan estimasi parameter regresi untuk setiap wilayah. *Output* hasil terletak pada lampiran. Berikut penulis sajikan nilai sebaran dari penduga parameter.

Tabel 4.13: Sebaran Estimasi Fixed Gaussian

	Min	Median	Max
Intercept	19.78295	36.186340	56.425761
X1	-0.823326	-0.473132	-0.210060
X2	-0.149969	0.090014	0.149627
X3	-0.193790	-0.055773	0.200615

Tabel 4.13 menunjukkan bahwa variabel angkatan kerja (X1) memiliki koefisien yang selalu negatif dengan rentang -0.823326 sampai -0.210060. Sementara pada koefisien keluhan kesehatan terdapat nilai negatif dan positif. Besarnya pengaruh keluhan kesehatan terhadap pengangguran terbuka sekitar interval -0.149969 sampai 0.149627. Hal ini terjadi juga pada koefisien persentase penduduk miskin bernilai negatif dan positif, dengan besar pengaruh berkisar -0.193790 sampai 0.200615.

Setiap lokasi menghasilkan model yang berbeda, berikut sampel model GWR pada suatu provinsi :

$$Y_{Jakarta} = 54.78055 - 0.7976142X1 + 0.132989749X2 + 0.026983833X3.$$

- Adaptive Gaussian

Pada kernel Adaptif Gaussian nilai bandwidth yang diperoleh hanya Se-

banyak lokasi pengamatan yaitu dalam penelitian ini 34. Metode CV dapat menemukan bandwidth optimum untuk bandwidth semua lokasi. Perhitungan hasil nilai bandwidth terletak pada lampiran 5. Setelah mendapat nilai bandwidth dan didapatkan pembobot untuk setiap wilayah provinsi maka didapatkan estimasi parameter regresi untuk setiap wilayah. *Output* hasil terletak pada lampiran 5. Berikut penulis sajikan nilai sebaran dari penduga parameter :

Tabel 4.14: Sebaran Estimasi Adaptive Gaussian

	Min	Median	Max
Intercept	19.320341	31.284880	82.539618
X1	-1.268195	-0.396746	-0.239325
X2	0.023952	0.091884	0.152472
X3	-0.174613	-0.055882	0.369537

Tabel 4.14 menunjukkan bahwa variabel angkatan kerja (X1) memiliki koefisien regresi yang selalu negatif dengan rentang -1.268195 sampai -0.239325. Terjadi juga pada koefisien persentase penduduk miskin bernilai negatif, dengan besar pengaruh berkisar antara -0.174613 sampai -0.174613. Sementara kernel adaptif Gaussian pada koefisien keluhan kesehatan bernilai positif. Besarnya pengaruh keluhan kesehatan terhadap pengangguran terbuka sekitar interval 0.023952 sampai 0.152472 .

Berikut sampel model GWR yang terbentuk dari suatu provinsi :

$$Y_{Jakarta} = 71.66661 + -1.0666241X1 + 0.12632881X2 + 0.205416864X3.$$

- Fixed Bi-square

Pada pembobot kernel fixed bi-square langkahnya sama saja, yang membedakan hanya formulasi dari pembobot bisquare. Bandwidth yang digunakan pada fixed bisquare ini merupakan bandwidth yang sama untuk setiap lokasi pengamatan. Metode menemukan bandwidth optimum dilakukan dengan melihat nilai CV yang paling minimum. Selanjutnya dicari pembobot sehingga ditemukan estimasi parameter pada model GWR untuk setiap lokasi pengamatan yang berbeda-beda. *Output* dari nilai bandwidth dan estimasi parameter terletak pada lampiran 5. Berikut nilai sebaran dari penduga parameter :

Tabel 4.15: Sebaran Estimasi Fixed Bi-square

	Min	Median	Max
Intercept	19.690109	36.229741	50.309221
X1	-0.725232	-0.489966	-0.061339
X2	-0.325141	0.086031	0.145159
X3	-0.184303	-0.054546	0.199935

Tabel 4.15 menunjukkan bahwa penduga parameter dari angkatan kerja (X1) dan persentase penduduk miskin(X3) bernilai negatif dengan masing- masing memiliki besaran pengaruh X1 sebesar -0.725232 sampai dengan -0.061339 dan pada X3 berkisar -0.184303 sampai 0.199935. Sedangkan pada variabel keluhan kesehatan memiliki nilai penduga yang negatif dan positif, dengan besaran pengaruh dari -0.184303 sampai 0.199935.

Berikut sampel model GWR yang terbentuk dengan menggunakan pembobot kernel fixed bi-square :

$$Y_{Jakarta} = 49.20784 + -0.71057268X1 + 0.13298866X2 + -0.016613989X3.$$

- Adaptive Bi-Square

Pembobot pada adaptif bisquare memiliki langkah dan formulasi yang sama dengan fixed bi-square, namun memiliki perbedaan pada bandwidth. Penggunaan badwidth di sini memiliki nilai yang berbeda untuk setiap wilayah karena menyesuaikan jarak antar lokasi. Metode pencarian *bandwidth* juga digunakan menggunakan CV dan estimasi parameter untuk setiap lokasi memiliki nilai yang berbeda. *Output* dari bentuk model GWR terletak pada lampiran 5. Berikut penulis sajikan singkat nilai penduga parameter :

Tabel 4.16: Sebaran Estimasi Adaptive Bi-Square

	Min	Median	Max
Intercept	15.319670	36.101383	89.437373
X1	-1.398103	-0.482105	-0.188436
X2	-0.049349	0.080284	0.206029
X3	-0.266926	-0.058491	0.468898

Dilihat dari tabel 4.16 nilai penduga parameter pada angkatan kerja

maupun persentase miskin selalu bernilai negatif dengan besaran pengaruh masing masing berkisar -1.398103 sampai -0.482105 dan -0.266926 sampai -0.058491. Sedangkan pada variabel keluhan kesehatan cukup bervariasi nilai penduga parameternya dari nilai negatif sampai positif, dengan besaran pengaruh sebesar -0.049349 sampai 0.080284 .

Berikut sampel model GWR yang terbentuk dengan adaptive bi-square dari suatu provinsi :

$$Y_{Jakarta} = 87.30420 + -1.3357518X1 + 0.13494970X2 + 0.42269128X3$$

4.5.1 Uji Kesesuaian Model GWR

Pengujian ini dilakukan untuk mengetahui apakah model layak dan mengandung faktor geografis pada model. Pengujian ini terbagi dua uji yaitu dengan uji F dan Uji T pada GWR. Pertama dilakukan uji F dengan Hipotesis nol model tidak memiliki pengaruh geografis artinya sama saja dengan model regresi global, sedangkan hipotesis alternatifnya model memiliki pengaruh geografis. Kriteria pengambilan keputusan tolak H_0 jika $F_{hit} > F_{tabel}$ atau bisa dilihat dari nilai p value < 0.05 Berikut penulis sajikan hasil uji untuk setiap pembobot :

Tabel 4.17: Uji Kelayakan Model

Jenis Pembobot	F_{hit}	F_{tabel}	P -Value	Kesimpulan
Fixed Gaussian	2.6929	2.107143	0.01477	Tolak H_0
Adaptive Gaussian	2.7185	2.107143282	0.01435	Tolak H_0
Fixed Bi-square	2.132	2.010248	0.03643	Tolak H_0
Adaptive Bi-square	4.9882	2.380334	0.001468	Tolak H_0

Berdasarkan table 4.17 semua pembobot menunjukkan bahwa $F_{hit} > F_{table}$ maka H_0 ditolak artinya model-model yang dibentuk memiliki pengaruh geografis. Terdapat perbedaan signifikan antara model regresi global dengan model GWR pada penganalisisan menggunakan selang kepercayaan 95%. Hasil perhitungan terletak pada lampiran 5. Langkah selanjutnya dilakukan pengujian setiap parameter, untuk mengetahui variabel yang signifikan pada setiap lokasi pengamatan.

4.5.2 Pengujian Parsial Parameter Model GWR

Pada pengujian sebelumnya menunjukkan hasil untuk setiap kernel pada GWR memiliki pengaruh geografis secara keseluruhan. Artinya terdapat variabel yang memiliki pengaruh signifikan pada suatu lokasi, sehingga tidak semua lokasi penelitian memiliki pengaruh signifikan ke semua variabel. Untuk mengetahui signifikannya suatu variabel independen digunakan uji T GWR. Hasil perhitungan uji parsial (Uji t GWR) selengkapnya dapat dilihat di lampiran 5. Berikut penulis sajikan contoh hasil uji dengan dua kernel pembobot

1. Fixed Gaussian

Gambar 4.9: Variabel yang signifikan pada GWR Fixed Gaussian

No	Provinsi	Variabel Signifikan
1.	<u>Sumatera Barat, Riau, Jambi, Sumatera Selatan, Bengkulu, Kepulauan Riau, NTT, Kalimantan Timur, Sulawesi Utara, Sulawesi Tengah, Sulawesi Selatan, Sulawesi Tenggara, Gorontalo, Sulawesi Barat, Maluku, Maluku Utara, dan Papua Barat.</u>	X1
2.	<u>Lampung, Bangka Belitung, DKI Jakarta, Jawa Barat, Jawa Tengah, DI Yogyakarta, Jawa Timur, Banten, Bali, NTB, Kalimantan Barat, Kalimantan Tengah, dan Kalimantan Selatan.</u>	X1 dan X2
3.	<u>Kalimantan Utara</u>	X1 dan X3
4.	<u>Aceh, Sumatera Utara, dan Papua</u>	-

Hasil parameter signifikan pada *Fixed Gaussian* terbagi menjadi 3 kelompok parameter. Terdapat 3 provinsi yang tidak memiliki pengaruh signifikan yaitu Aceh, Sumatera Utara, dan Papua. Sedikitnya variasi dari klasifikasi signifikan, menunjukkan model GWR yang kurang identik dengan data spasial. Berikut sampel model yang GWR yang memiliki signifikan pada X1.

$$\hat{Y}_{Riau} = 37.26598 - 0.4770579X1$$

Model GWR yang terbentuk menjelaskan bahwa variabel independen X1 memiliki hubungan negatif terhadap variabel dependen Y, artinya semakin tinggi jumlah Angkatan kerja maka kasus Pengangguran Terbuka semakin menurun. Kasus tingkat pengangguran menurun sebesar 3.052898 persen apabila ang-

katan kerja bertambah satu persen.

Model GWR dengan X1 dan X2 sebagai variabel signifikan :


$$\hat{Y}_{JawaBarat} = 53.21730 - 0.7750969X1 + 0.140114129X2$$

Model yang terbentuk di Jawa Barat dengan pembobot *fixed Gaussian* menjelaskan bahwa jika variabel independen lainnya tetap dan angkatan kerja mengalami penurunan satu persen, maka TPT mengalami penurunan sebesar 0.7750969 persen. Sedangkan apabila keluhan kesehatan bertambah satu persen, maka TPT meningkat sebesar 0.140114129 persen dengan syarat variabel independen lainnya bernilai konstan.

Model GWR dengan X1 dan X3 sebagai variabel signifikan :

$$\hat{Y}_{KalimantanUtara} = 21.00834 - 0.2625210X1 - 0.193789598X3$$

Model GWR di Kalimantan Utara dengan *Fixed Gaussian* memiliki pengaruh signifikan dengan persentase angkatan kerja dan penduduk miskin terhadap pengangguran terbuka. Setiap angkatan kerja meningkat satu persen, maka TPT mengalami penurunan sebesar 0.262521 persen dengan persentase kemiskinan konstan. Sedangkan jika persentase penduduk miskin mengalami kenaikan satu persen maka TPT mengalami penurunan sebesar 0.193789598.



Gambar 4.10: Peta Kelompok Wilayah Berdasarkan Faktor yang Signifikan menggunakan Fixed Gaussian

2. Adaptif Bi-Square

Gambar 4.11: Variabel yang signifikan pada GWR Adaptif Bi-Square

No	Provinsi	Variabel Signifikan
1.	Sumatera Barat, Jambi, Kepulauan Riau, Jawa Barat, NTT, Sulawesi Utara, Sulawesi Tengah, Sulawesi Tenggara, Gorontalo, dan Sulawesi Barat.	X1
2.	Kalimantan Utara	X3
3.	Jawa Tengah, DI Yogyakarta, Jawa Timur, Bali, dan Kalimantan Selatan	X1 dan X2
4.	Kep. Bangka Belitung, DKI Jakarta, Banten, Maluku, Maluku Utara, Papua Barat, dan Papua	X1 dan X3
5.	Sumatera Selatan, Bengkulu dan Lampung	X1, X2, dan X3
6.	Aceh, Sumatera Utara, Riau, NTB, Kalimantan Barat, Kalimantan Tengah, Kalimantan Timur, dan Sulawesi Tengah	-

Berdasarkan hasil tabel dari variabel-variabel independen signifikan terhadap variabel TPT dengan adaptif bi-square terlihat bahwa model GWR terbagi ke dalam 5 kelompok sebaran model dan terdapat 8 provinsi yang tidak memiliki kesignifikanan. Jika dibandingkan dengan sebelumnya pada fixed gaussian, maka kelompok model signifikan adaptif bi square lebih bervariasi.

Adapun model GWR yang signifikan dengan angkatan kerja (X1) terdapat 10 lokasi, dengan sampel model GWR provinsi Jambi :

$$\hat{Y}_{Jambi} = 51.81006 - 0.7804129X1$$

Model GWR pada provinsi Jambi pada Variabel angkatan kerja memiliki hubungan negatif dan signifikan terhadap TPT. Artinya setiap kenaikan satu persen angkatan kerja dan variabel independen lainnya konstan, maka persentase pengangguran menurun sebesar 0.7804129.

Model GWR dengan variabel signifikan X3 :

$$\hat{Y}_{KalimantanUtara} = 19.85785 - 0.26692622X3$$

Pemodelan GWR pada provinsi Kalimantan Utara dengan adaptif bi-square memiliki hubungan yang negatif dengan persentase penduduk miskin (X3). Model menjelaskan bahwa setiap kenaikan satu persen penduduk miskin maka

angka pengangguran menurun sebesar 0.26692933 persen.

Sampel model GWR dengan X1 dan X2 sebagai Variabel signifikan :

$$\hat{Y}_{Bali} = 19.85785 - 0.2427081X1 + 0.10027643X2$$

Model GWR pada Provinsi Bali menunjukkan bahwa X1 dan X2 memiliki variabel yang signifikan terhadap TPT. Artinya setiap persentase angkatan kerja (X1) meningkat dan variabel bebas yang lain konstan maka persentase TPT meningkat sebesar 0.2427081 persen. Ketika variabel keluhan kesehatan meningkat satu satuan maka persentase pengangguran meningkat sebesar 0.10027643

Model GWR dengan variabel signifikan X1 dan X3 :


$$\hat{Y}_{Banten} = 88.73208 - 1.3659938X1 + 0.43858775X3$$

Model di atas menunjukkan bahwa variabel angkatan kerja (X1) dan persentase kemiskinan (X3) memiliki pengaruh signifikan dengan hubungan yang negatif dan positif. Setiap kenaikan satu satuan kenaikan angkatan kerja maka berdampak penurunan pengangguran terbuka sebesar 1.3659938 . Sedangkan untuk setiap kenaikan penduduk mislin satu satuan (persen) maka angka TPT mengalami kenaikan sebesar 0.43858757.

Sampel model dengan Variabel signifikan X1,X2, dan X3 untuk model GWR *Adaptive Bi-Square*

$$\hat{Y}_{Lampung} = 89.24538 - 1.3981035X1 + 0.17214502X2 + 0.46889757X3$$

Terdapat 3 provinsi yang memiliki model dengan semua variabel signifikan terhadap variabel TPT . Salah satunya Lampung dengan model yang terbentuk memiliki hubungan negatif antara angkatan kerja terhadap TPT, dimana setiap kenaikan angkatan kerja satu satuan maka persentase pengangguran mengalami penurunan sebesar 1.3981035. Sedangkan variabel keluhan kesehatan (X2) dan persentase kemiskinan (X3) memiliki pengaruh positif terhadap TPT. Artinya setiap kenaikan X2 dan X3 maka variabel TPT mengalami kenaikan sebesar 0.17214502 dan 0.46888757 persen.



Gambar 4.12: Peta Kelompok Wilayah Berdasarkan Faktor yang Signifikan Menggunakan Adaptive Bi-Square

4.6 Perbandingan Model GWR dengan Regresi Linear Berganda

Metode untuk mengetahui model yang terbaik antara model regresi global dan regresi spasial dapat menggunakan nilai koefisien determinasi (R^2) dan nilai *Akaike Information Criterion* (AIC). Semakin besar nilai R^2 dan semakin mendekati satu maka model akan semakin baik. Sedangkan apabila Nilai AIC semakin kecil maka akan semakin baik. Menurut Evana (2008), Model yang memiliki MAD (*Mean Absolute Deviation*) dan SSE (*Sum Square Error*) yang terkecil maka layak dipilih sebagai model prediksi terbaik. Kian hasil dari SSE/JKG bisa jadi pertimbangan juga dalam menentukan model terbaik. Penelitian ini terdiri dari 4 model GWR dengan pembobot berbeda dan 1 model regresi global. Hasil perbandingan nilai R^2 dan Nilai AIC disajikan dalam tabel 4.18.

Dari tabel 4.18 terlihat bahwa pemodelan tingkat pengangguran terbuka di Indonesia dengan metode GWR lebih baik dari regresi linear berganda, dimana nilai R^2 pada model GWR lebih besar. Nilai R^2 yang terkecil terdapat di model regresi linear berganda dan R^2 yang terbesar dimiliki model adaptif bi-square dengan 0.8919505. Kemampuan pembobot bi square yang menjelaskan

Tabel 4.18: Nilai (R^2), AIC dan JKG

Model	R^2	AIC	JKG
Regresi Linear Berganda	0.461	131.9619	71.92322
Fixed Gaussian	0.7998555	101.2162	26.70827
Adaptive Gaussian	0.8017365	100.7926	26.45726
Fixed Bi-square	0.7471976	106.9829	33.73520
Adaptive Bi-square	0.8919505	84.61524	14.41866

model dengan sangat baik diakibatkan *bandwidth* yang dapat menyesuaikan jarak antar provinsi yang diamati, sehingga dapat memberikan bobot yang sesuai. Nilai AIC pada hasil GWR pun jauh lebih kecil dibanding dengan model regresi linear berganda. Berdasarkan empat model GWR dicari lagi untuk model dengan kernel terbaik dalam memodelkan TPT di Indonesia, yaitu model GWR dengan pembobot adaptif bi-square. Artinya model dengan GWR adaptif bisquare mampu menjelaskan pengaruh tingkat pengangguran terbuka terhadap faktor-faktor nya sebesar 89.1% dan sisanya dijelaskan oleh faktor lainnya yang tidak terdapat pada penelitian ini.

BAB V

Penutup

5.1 Kesimpulan

Berdasarkan analisis dan pembahasan pada penelitian ini dengan studi kasus Tingkat Pengangguran Terbuka (TPT) di Indonesia, maka dapat disimpulkan bahwa :

1. Model Regresi Linear Berganda yang dihasilkan pada kasus pengangguran terbuka :

$$\hat{Y} = 29.760 - 0.395X_1 + 0.085X_2$$

Memiliki 2 faktor signifikan (angkatan kerja dan Keluhan Kesehatan) dari 3 faktor. Hasil uji asumsi klasik menunjukkan bahwa model regresi global memenuhi asumsi normalitas, non multikolinearitas, dan non autokorelasi, sedangkan model tidak memenuhi asumsi kehomogenan, sehingga pengaruh tidak memenuhi asumsi ini yaitu presisi atau pengamatan dari penduga dengan regresi linear berganda lebih kecil jika dibanding dengan model yang mampu mengakomodir ketidakhomogenan ragam.

2. Data yang digunakan mengandung heterogenitas spasial dan autokorelasi spasial sehingga dapat dikatakan data spasial. Analisis dilanjutkan dengan regresi spasial. Informasi tambahan dalam pengamatan yaitu *longitude* dan *latitude* untuk setiap provinsi di Indonesia.
3. Metode Geographically Weigted Regression menggunakan 4 pembobot berbeda yaitu *Fixed Gaussian*, *Adaptive Gaussian*, *Fixed Bi-Square*, dan *Adaptive Bi-Square* dimana menghasilkan kebaikan model dengan nilai *p-value* dari masing-masing kernel yaitu berturut-turut 0.01477, 0.01435, 0.03643, dan 0.001468. Dengan demikian dari hasil tersebut model memiliki pengaruh geografis menunjukkan perbedaan signifikan dengan re-

gresi global.

4. Pembobot kernel terbaik yang digunakan dalam penelitian Tingkat Pengangguran Terbuka (TPT) di Indonesia 2020 adalah kernel *Adaptive Bi-Square* dilihat dari nilai kebaikan model yang terkecil. kernel adaptif mampu menyesuaikan data lokasi provinsi dan faktor-faktor yang mempengaruhi dikatakan bervariasi.
5. Model dengan metode *Geographically Weighted Regression* adalah model terbaik dalam penelitian ini jika dibanding dengan Regresi linear berganda dengan metode OLS (*Ordinary Least Square*). Ditinjau dari nilai R^2 , AIC dan Jumlah Kuadrat Galat (JKG) menunjukkan hasil GWR kernel *Adaptive Bi-Square* merupakan model terbaik. Kemampuan model menjelaskan pengaruh angkatan kerja, keluhan kesehatan, dan persentase kemiskinan terhadap pengangguran terbuka di Indonesia sebesar 89.1 % dengan $\alpha = 0.05$
6. Model yang dihasilkan untuk setiap provinsi berbeda. Hasil akhir model penduga dari Tingkat Pengangguran Terbuka (TPT) di Indonesia terdapat dilampiran 2.

5.2 Saran

Saran untuk peneliti selanjutnya berdasarkan penelitian saat ini yaitu :

1. Penulisan Skripsi ini mengenai kasus tingkat pengangguran terbuka hanya menggunakan 3 faktor, diharapkan penelitian selanjutnya dapat menambahkan faktor-faktor lainnya yang mengandung efek spasial.
2. Diharapkan dalam penelitian selanjutnya dapat menggunakan data tidak hanya satu waktu (tahun), tetapi bisa menggunakan beberapa data deret waktu agar mampu membuat *forecasting* untuk kasus yang diteliti.

3. Lingkup penelitian dapat diperkecil lagi agar bisa lebih fokus pada hasil penelitian yang mencakup kota atau kabupaten di suatu provinsi.
4. Hasil akhir penelitian menunjukkan model GWR dengan adaptive bi-square pada kasus tingkat pengangguran terbuka menjadi yang terbaik. Penelitian selanjutnya bisa mengembangkan studi kasus ini dengan *adaptive Gaussian* yang terbaik.
5. Pemerintah diharapkan mampu mengkondisikan angkatan kerja yang mengalami peningkatan signifikan di saat bonus demografi di Indonesia saat ini dengan memberikan tambahan lapangan pekerjaan dan sarana pengembangan *Skill*. Selain angkatan kerja, faktor yang signifikan juga keluhan kesehatan menjadi tantangan lapisan masyarakat untuk mengembalikan perekonomian agar kembali berjaya, dengan terus memberikan inovasi produk dan pemasaran di sosial media.

DAFTAR PUSTAKA

- AIF (Faujik). "Mengenal Arti dan Penyebab Resesi". Tersedia : <http://dpmptsp.jatimprov.go.id/wp-content/uploads/2020/09/Mengenal-Arti-dan-Penyebab-Resesi.pdf> . Diakses 7 Juni 2021.
- Anonim. "Pengertian Pengangguran Terbuka, Setengah Menganggur dan Terselubung". Tersedia : <https://www.gurugeografi.id/2018/03/pengertian-pengangguran-terbuka.html> . Diakses 8 Juni 2021.
- Bekti, Rokhana Dwi. 2012. *Autokorelasi Spasial untuk Identifikasi Pola Hubungan Kemiskinan di Jawa Timur*. ComTech. Vol.3, No.1. 217-227.
- Badan Pusat Statistik.2020. "Tenaga Kerja". Tersedia: <https://www.bps.go.id/subject/6/tenaga-kerja.html>. Diakses 26 Mei 2020.
- Badan Pusat Statistik. 2021. *Statistik Indonesia 2021*. Jakarta:BPS.
- Caraka, Rezy Eko dkk. 2017. *Geographically Weighted Regression(GWR) Sebuah Pendekatan Regresi Geografis. Edisi Pertama. Cet.Ke-1. Yogyakarta : Mobius*.
- Evana, Lisa dkk. 2008. *Pengembangan Model Prediksi Madden Julian Oscillation (MJO) Berbasis pada Hasil Analisis Data Real Time Multivariate MJO*. J.Agromet 22 (2):144-159.
- Brundson C., Fotheringham, A.S., dan Charlton, M. E. 2002. *Geographically Weighted Regression: The Analysis of Spatially Varying Relationship*. England : John Wiley and Sons Ltd.
- Latitudelongitude.org. "Indonesia Latitude and Longitude". Tersedia : <https://latitudelongitude.org/id/> . Diakses 8 Juni 2021.
- Ira, Farida. 2016. *Model Geographically Weighted Regression (GWR) dengan Pembobot Kernel Bi-Square*. Repository.upi.edu. 15-24.
- Kurniyanti, Umi Latifah. 2019. *Pemodelan Tindak Pidana di Jawa Timur dengan menggunakan Geographically Weighted Regression (GWR)*. Skripsi. Diterbitkan. Fakultas Sains dan Teknologi. Universitas Islam Negeri Maulana Malik Ibrahim : Malang.
- Lutfiani, Nurul.dkk. 2019. *Pemodelan Geographically Weighted Regression dengan Fungsi Pembobot Kernel Gaussian dan Bi-Square*. Unnes Journal of Mathematics. 8(1). 82-91.

- Maulani, Atiya. 2013. *Aplikasi model Geographically Weighted Regression untuk menentukan faktor-faktor yang mempengaruhi kasus gizi buruk anak balita di Jawa Barat*. Eurematika. Vol.4 . No.1. 46-63.
- Nadya, Meila.dkk. 2017. *Analisis Geographically Weighted Regression pada Kasus Pneumonia Balita di Jawa Barat*. Jurnal Statistika dan Aplikasinya. Vol.1, No.1. 23-32.
- Putri, Rizqa Leony. ” 10 Negara dengan Penduduk Terpadat , Indonesia nomer Berapa?” . Tersedia: <https://economy.okezone.com/read/2019/11/23/470/2133563/10-negara-dengan-penduduk-terpadat-indonesia-nomor-berapa>. Diakses 1 April 2021.
- Putri, Zarmeila. 2018. *Pemodelan Indeks Pembangunan Manusia menggunakan Geographically Weighted Regression*. Skripsi. Diterbitkan. Fakultas Matematika dan Ilmu Pengetahuan Alam. Universitas Islam Indonesia : Yogyakarta.
- Richie.”Regresi Spasial (GWR)” . Tersedia :<https://www.mobilestatistik.com/regresi-spasial-gwr/>. Diakses 6 November 2020.
- Richie. ”Bandwidth Optimum pada Regresi Spasial” . Tersedia: <https://www.mobilestatistik.com/bandwidth-optimum-pada-regresi-spasial/>. Diakses 7 November 2020.
- Schaar, R.M.A vander. dkk. ”Pengangguran di Indonesia” . Tersedia: <https://www.indonesia-investments.com/id/keuangan/angka-ekonomi-makro/pengangguran/item255>. Diakses 9 Desember 2020.
- Sinaga, Kristina Pestaria. 2015. *Pemodelan Data Kemiskinan di Provinsi Sumatera Utara dengan Geographically Weighted Regression*. Repositori.usu.ac.id. 883-894.
- Soleh, Agus M., dan Aunuddin. 2013. *Lasso:Solusi Alternatif dari Seleksi Peubah dan Penyusutan Koefisien Model Regresi Linier*. Indonesian Journal of Statistics. Vol.18, No.1. 21-27.
- Suharjo, Bambang. 2008. *Analisis Regresi Terapan dengan SPSS*. Edisi Pertama. Yogyakarta: Graha Ilmu.
- Utami, Tiani Wahyu. dkk. 2016.*Pemodelan Regresi Berganda dan Geographically Weighted Regression pada Tingkat Pengangguran Terbuka di Jawa Tengah*. Media Statistika. 9(2).133-147.
- Walpole, R. E., Raymond H Myers. 1995. *Ilmu Peluang dan Statistika untuk Insinyur dan Ilmuwan*. Edisi ke-4. Bandung: Penerbit ITB.

- Widayaka, Pratama Ganang. dkk. 2016. *Pemodelan Mixed Geographically Weighted Regression untuk Pemodelan Pertumbuhan Ekonomi menurut Kabupaten/ Kota di Jawa Tengah*. Jurnal Gaussian. Vol.5, No.4. 727-736.
- Wuryandari, Triastuti. dkk. 2014. *Identifikasi Autokorelasi Spasial pada Jumlah Pengangguran di Jawa Tengah Menggunakan Indeks Moran*. Media Statistika. Vol.7, No.1 . 1-10.

LAMPIRAN

1. Data Penelitian

No	Provinsi	X1	X2	X3	TPT	Lon	Lat
1	Aceh	65.1	57.92	15.43	6.59	4.695135	96.7494
2	Sumatera Utara	68.67	42.36	9.14	6.91	2.115355	99.5451
3	Sumatera Barat	69.01	57.25	6.56	6.88	-0.73994	100.8
4	Riau	65.24	42.52	7.04	6.32	0.293347	101.7068
5	Jambi	67.79	38.4	7.97	5.31	-1.48518	102.4381
6	Sumatera Selatan	68.65	38.64	12.98	5.51	-3.31944	103.9144
7	Bengkulu	71.73	44.14	15.3	4.07	-3.57785	102.3464
8	Lampung	70.16	43.95	12.76	4.67	-4.55858	105.4068
9	Kepulauan Bangka Belitung	66.89	46.43	4.89	5.25	-2.74105	106.4406
10	Kepulauan Riau	66.28	43.9	6.13	10.34	3.945651	108.1429
11	DKI Jakarta	63.81	49.96	4.69	10.95	-6.21154	106.8452
12	Jawa Barat	64.53	47.61	8.43	10.46	-7.09091	107.6689
13	Jawa Tengah	69.53	49.09	11.84	6.48	-7.15098	110.1403
14	DI Yogyakarta	71.12	50.18	12.8	4.57	-7.87538	110.4262
15	Jawa Timur	70.33	46	11.46	5.84	-7.53606	112.2384
16	Banten	64.48	42.3	6.63	10.64	-6.40582	106.064
17	Bali	74.32	61.32	4.45	5.63	-8.40952	115.1889
18	Nusa Tenggara Barat	70.45	43.86	14.23	4.22	-8.65293	117.3616
19	Nusa Tenggara Timur	73.11	50.8	21.21	4.28	-8.65738	121.0794
20	Kalimantan Barat	68.83	37.5	7.24	5.81	-0.27878	111.4753
21	Kalimantan Tengah	68.4	31.48	5.26	4.58	-1.68149	113.3824
22	Kalimantan Selatan	69.33	32.52	4.83	4.74	-3.09264	115.2838
23	Kalimantan Timur	65.5	46.22	6.64	6.87	1.64063	116.4194
24	Kalimantan Utara	66.51	43.06	7.41	4.97	2.75	116
25	Sulawesi Utara	63.42	49.46	7.78	7.37	0.624693	123.975
26	Sulawesi Tengah	69.44	36.42	13.06	3.77	-1.43003	121.4456
27	Sulawesi Selatan	63.4	41.02	8.99	6.31	-3.6688	119.9741
28	Sulawesi Tenggara	69.83	33.41	11.69	4.58	-4.14491	122.1746
29	Gorontalo	66.46	48.57	15.59	4.28	0.699937	122.4467
30	Sulawesi Barat	70.19	41.48	11.5	3.32	-2.84414	119.2321
31	Maluku	65.07	40.43	17.99	7.57	-3.23846	130.1453
32	Maluku Utara	64.28	44.93	6.97	5.15	1.570999	127.8088
33	Papua Barat	69.55	46.24	21.7	6.8	-1.33612	133.1747
34	Papua	72.16	49.92	26.8	4.28	-4.26993	138.0804

Gambar 5.1: Data Penelitian

2. Hasil Pemodelan GWR Terbaik

No	Provinsi	Model GWR
1	Aceh	$\hat{y} = 22.74388 - 0.2484283 X_1 + 0.04317026 X_2 - 0.16025001 X_3$
2	Sumatera Utara	$\hat{y} = 22.73267 - 0.2534034 X_1 + 0.04601183 X_2 - 0.14579995 X_3$
3	Sumatera Barat	$\hat{y} = 31.38618 - 0.3936257 X_1 + 0.05539786 X_2 - 0.10049762 X_3$
4	Riau	$\hat{y} = 26.29688 - 0.3176964 X_1 + 0.05429061 X_2 - 0.10837662 X_3$
5	Jambi	$\hat{y} = 51.81006 - 0.7804129 X_1 + 0.13522826 X_2 + 0.15376694 X_3$
6	Sumatera Selatan	$\hat{y} = 78.04460 - 1.2484397 X_1 + 0.20602924 X_2 + 0.41725232 X_3$
7	Bengkulu	$\hat{y} = 71.81507 - 1.1395849 X_1 + 0.19470670 X_2 + 0.35290602 X_3$
8	Lampung	$\hat{y} = 89.24538 - 1.3981035 X_1 + 0.17214502 X_2 + 0.46889757 X_3$
9	Kepulauan Bangka Belitung	$\hat{y} = 89.43737 - 1.3703735 X_1 + 0.13009045 X_2 + 0.44123459 X_3$
10	Kepulauan Riau	$\hat{y} = 58.25502 - 0.8139051 X_1 + 0.09698972 X_2 - 0.04763309 X_3$
11	DKI Jakarta	$\hat{y} = 87.30420 - 1.3357518 X_1 + 0.13494970 X_2 + 0.42269128 X_3$
12	Jawa Barat	$\hat{y} = 81.84833 - 1.2341937 X_1 + 0.12191480 X_2 + 0.34981671 X_3$
13	Jawa Tengah	$\hat{y} = 54.36831 - 0.7761690 X_1 + 0.13566691 X_2 - 0.06219566 X_3$
14	DI Yogyakarta	$\hat{y} = 53.02686 - 0.7526600 X_1 + 0.13566691 X_2 - 0.09747241 X_3$
15	Jawa Timur	$\hat{y} = 52.11825 - 0.7502448 X_1 + 0.15763620 X_2 - 0.11657477 X_3$
16	Banten	$\hat{y} = 88.73208 - 1.3659938 X_1 + 0.14424832 X_2 + 0.43858775 X_3$
17	Bali	$\hat{y} = 30.77764 - 0.4317816 X_1 + 0.12013226 X_2 - 0.06923491 X_3$
18	Nusa Tenggara Barat	$\hat{y} = 19.41945 - 0.2514782 X_1 + 0.08542788 X_2 - 0.06087760 X_3$
19	Nusa Tenggara Timur	$\hat{y} = 17.09164 - 0.2130726 X_1 + 0.07336279 X_2 - 0.05610348 X_3$
20	Kalimantan Barat	$\hat{y} = 33.93901 - 0.4648884 X_1 + 0.07513934 X_2 + 0.08940894 X_3$
21	Kalimantan Tengah	$\hat{y} = 15.31967 - 0.2427081 X_1 + 0.08809714 X_2 - 0.07751250 X_3$
22	Kalimantan Selatan	$\hat{y} = 22.23257 - 0.2844167 X_1 + 0.09090521 X_2 - 0.16606547 X_3$
23	Kalimantan Timur	$\hat{y} = 24.21718 - 0.2950676 X_1 + 0.06622593 X_2 - 0.21343800 X_3$
24	Kalimantan Utara	$\hat{y} = 19.85785 - 0.2427081 X_1 + 0.10027643 X_2 - 0.26692622 X_3$
25	Sulawesi Utara	$\hat{y} = 39.84583 - 0.4993217 X_1 - 0.4993217 X_2 + 0.03351404 X_3$
26	Sulawesi Tengah	$\hat{y} = 25.31618 - 0.2972933 X_1 + 0.02734510 X_2 - 0.13663053 X_3$
27	Sulawesi Selatan	$\hat{y} = 19.16758 - 0.2322670 X_1 + 0.06253639 X_2 - 0.09834028 X_3$
28	Sulawesi Tenggara	$\hat{y} = 21.28843 - 0.2616911 X_1 + 0.04692364 X_2 - 0.04920628 X_3$
29	Gorontalo	$\hat{y} = 33.92663 - 0.4109002 X_1 - 0.01410400 X_2 - 0.07178596 X_3$
30	Sulawesi Barat	$\hat{y} = 21.39798 - 0.2582015 X_1 + 0.05435806 X_2 - 0.11777837 X_3$
31	Maluku	$\hat{y} = 39.03120 - 0.5170755 X_1 - 0.03183004 X_2 + 0.19027366 X_3$
32	Maluku Utara	$\hat{y} = 38.26376 - 0.5137835 X_1 - 0.01848780 X_2 + 0.18424484 X_3$
33	Papua Barat	$\hat{y} = 41.36783 - 0.5456754 X_1 - 0.04301365 X_2 + 0.19410545 X_3$
34	Papua	$\hat{y} = 41.42779 - 0.5403669 X_1 - 0.04934939 X_2 + 0.18600791 X_3$

Gambar 5.2: Hasil Model GWR dengan Adaptive Bi-Square

Lampiran 3.Syntax Penelitian

```

install.packages("lmtest")
library(lmtest)
datasps <- read.table(file.choose(), header = TRUE)
View(datasps)
model <- lm(TPT X1+X2+X3,data =datasps)
summary(model)
AIC(model)
bptest(model,studentize = FALSE)
install.packages("spgwr")
library(spgwr)
LON <- datasps$Lon
LAT <- datasps$Lat
# Mencaribandwidth optimal (adaptive bandwidth) adaptif gauss
b <- gwr.sel(TPT X1+X2+X3, coords=cbind(LON,LAT),
data=datasps, adapt=TRUE,gweight=gwr.Gauss)
# Estimasi Parameter
gwr1 <- gwr(TPT X1+X2+X3, coords=cbind(LON,LAT),
data=datasps, adapt=b,hatmatrix=TRUE,gweight=gwr.Gauss)
# Membaca Output
gwr1
names(gwr1)
names(gwr1$SDF)

# Menampilkan nilai koefisien beta
gwr1$SDF$(Intercept)"
gwr1$SDF$X1
gwr1$SDF$X2
gwr1$SDF$X3

# Uji Kecocokan Model
BFC02.gwr.test(gwr1)

# Uji Pengaruh Geografis terhadap setiap prediktor
LMZ.F3GWR.test(gwr1)

```

```

# Melihat nilai bandwidth
gwr1$bandwidth

# Mencari nilai t hitung
T.boadaptifgauss<-gwr1$SDF$(Intercept)/gwr1 $SDF$(Intercept)_se"
T.b1adaptifgauss<-gwr1$SDF$X1/gwr1$SDF $X1_se
T.b2adaptifgauss<-gwr1$SDF$X2/gwr1$SDF$X2_se
T.b3adaptifgauss<-gwr1$SDF$X3/gwr1$SDF$X3_se
T.boadaptifgauss
T.b1adaptifgauss
T.b2adaptifgauss
T.b3adaptifgauss

#Mencari bandwidth optimal (fixed bandwidth)
h <- gwr.sel(TPT X1+X2+X3, coords=cbind(LON,LAT),
data=datasps, adapt=FALSE,gweight=gwr.Gauss)
#Estimasi Parameter fixed bandwidth
gwr2 <- gwr(TPT X1+X2+X3, coords=cbind(LON,LAT),
bandwidth=h, data=datasps,hatmatrix=TRUE,gweight=gwr.Gauss)

#Melihat nilai bandwidth
gwr2$bandwidth

#Membaca Output
gwr2
names(gwr2)
names(gwr2$SDF)

gwr2$SDF$(Intercept)"
gwr2$SDF$X1
gwr2$SDF$X2
gwr2$SDF$X3
#Uji Kecocokan Model
BFC02.gwr.test(gwr2)

#Uji Pengaruh Geografis terhadap setiap prediktor

```

```
LMZ.F3GWR.test(gwr2)
```

```

#Mencari nilai t hitung
T.bofixedgauss< -gwr2$SDF$"(Intercept)"/gwr2$SDF$"(Intercept)_se"
T.b1fixedgauss< -gwr2$SDF$X1/gwr2$SDF$X1_se
T.b2fixedgauss< -gwr2$SDF$X2/gwr2$SDF$X2_se
T.b3fixedgauss< -gwr2$SDF$X3/gwr2$SDF$X3_se
T.bofixedgauss
T.b1fixedgauss
T.b2fixedgauss
T.b3fixedgauss

# Mencari bandwidth optimal (adaptive bandwidth) e < - gwr.sel(TPT X1+X2+X3,
coords=cbind(LON,LAT),
data=datasps, adapt=TRUE,gweight=gwr.bisquare)

# Estimasi Parameter
gwr3 < - gwr(TPT X1+X2+X3, coords=cbind(LON,LAT),
data=datasps, adapt=e,hatmatrix=TRUE,gweight=gwr.bisquare)
gwr3$bandwidth
# Membaca Output
gwr3
names(gwr3)
names(gwr3$SDF)
gwr3$SDF$"(Intercept)"
gwr3$SDF$X1
gwr3$SDF$X2
gwr3$SDF$X3
# Uji Kecocokan Model BFC02.gwr.test(gwr3)
#Uji Pengaruh Geografis terhadap setiap prediktor
LMZ.F3GWR.test(gwr3)

#Mencari nilai t hitung
T.boadaptifbisquare < -gwr3$SDF$"(Intercept)"/gwr3$SDF$"(Intercept)_se"
T.b1adaptifbisquare< -gwr3$SDF$X1/gwr3$SDF$X1_se
T.b2adaptifbisquare< -gwr3$SDF$X2/gwr3$SDF$X2_se

```



```

T.b3adaptifbisquare< -gwr3$SDF$X3/gwr3$SDF$X3_se
T.boadaptifbisquare
T.b1adaptifbisquare
T.b2adaptifbisquare
T.b3adaptifbisquare

#Mencari bandwidth optimal (fixed bandwidth)
f <- gwr.sel(TPT X1+X2+X3, coords=cbind(LON,LAT),
data=datasps, adapt=FALSE,gweight=gwr.bisquare)

#Estimasi Parameter fixed bandwidth
gwr4 <- gwr(TPT X1+X2+X3, coords=cbind(LON,LAT),
bandwidth=f, data=datasps,hatmatrix=TRUE,gweight=gwr.bisquare)
gwr4$bandwidth

# Membaca Output
gwr4
names(gwr4)
names(gwr4$SDF)

gwr4$SDF$"(Intercept)"
gwr4$SDF$X1
gwr4$SDF$X2
gwr4$SDF$X3

#Uji Kecocokan Model
BFC02.gwr.test(gwr4)

#Uji Pengaruh Geografis terhadap setiap prediktor
LMZ.F3GWR.test(gwr4)

#Mencari nilai t hitung
T.bofixedbisquare< -gwr4$SDF$"(Intercept)"/gwr4$SDF$"(Intercept)_se"
T.b1fixedbisquare< -gwr4$SDF$X1/gwr4$SDF$X1_se
T.b2fixedbisquare< -gwr4$SDF$X2/gwr4$SDF$X2_se
T.b3fixedbisquare< -gwr4$SDF$X3/gwr4$SDF$X3_se

```

T.bofixedbisquare

T.b1fixedbisquare

T.b2fixedbisquare

T.b3fixedbisquare

Lampiran 4. Uji Regresi

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.
		B	Std. Error	Beta		
1	(Constant)	14.591	3.238		4.507	.000
	X1	-.213	.048	-.669	-4.428	.000
	X2	.021	.019	.152	1.087	.286
	X3	.009	.026	.050	.329	.744

a. Dependent Variable: abs_res

Gambar 5.3: Uji Heterokedastisitas

		Unstandardized Residual
N		34
Normal Parameters ^{a,b}	Mean	.0000000
	Std. Deviation	1.47631010
Most Extreme Differences	Absolute	.112
	Positive	.112
	Negative	-.068
Test Statistic		.112
Asymp. Sig. (2-tailed)		.200 ^{c,d}

a. Test distribution is Normal.

b. Calculated from data.

c. Lilliefors Significance Correction.

d. This is a lower bound of the true significance.

Gambar 5.4: Uji Normalitas

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
		B	Std. Error	Beta			Tolerance	VIF
1	(Constant)	29.760	6.810		4.370	.000		
	X1	-.395	.101	-.573	-3.912	.000	.837	1.194
	X2	.085	.040	.288	2.121	.042	.977	1.024
	X3	-.058	.055	-.156	-1.062	.297	.828	1.208

a. Dependent Variable: Y

Gambar 5.5: Uji Multikolinearitas

Model Summary ^a					
Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	.679 ^a	.461	.407	1.54837	1.684

a. Predictors: (Constant), X3, X2, X1
b. Dependent Variable: Y

Gambar 5.6: Uji Autokorelasi

ANOVA ^a						
Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	61.522	3	20.507	8.554	.000 ^b
	Residual	71.923	30	2.397		
	Total	133.445	33			

a. Dependent Variable: Y
b. Predictors: (Constant), X3, X2, X1

Gambar 5.7: Uji F

```
> summary(model)

Call:
lm(formula = TPT ~ X1 + X2 + X3, data = datasps)

Residuals:
    Min       1Q   Median       3Q      Max
-2.6219 -0.8766 -0.1523  0.5943  3.3981

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) 29.75998     6.80980   4.370 0.000137 ***
X1          -0.39542     0.10109  -3.912 0.000487 ***
X2           0.08535     0.04024   2.121 0.042304 *
X3          -0.05812     0.05472  -1.062 0.296661
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 1.548 on 30 degrees of freedom
Multiple R-squared:  0.461,    Adjusted R-squared:  0.4071
F-statistic: 8.554 on 3 and 30 DF,  p-value: 0.0002962
```

Gambar 5.8: Uji T

Lampiran 5. Uji GWR

```
> bptest(model, studentize = FALSE)

Breusch-Pagan test

data:  model
BP = 10.506, df = 3, p-value = 0.01472
```

1. Fixed Gaussian

```
> gwr2
Call:
gwr(formula = TPT ~ X1 + X2 + X3, data = datasps, coords = cbind(LON,
  LAT), bandwidth = h, gweight = gwr.Gauss, hatmatrix = TRUE)
Kernel function: gwr.Gauss
Fixed bandwidth: 5.334214
Summary of GWR coefficient estimates at data points:
      Min.  1st Qu.  Median  3rd Qu.  Max.  Global
X.Intercept. 19.782895 23.684178 36.186340 47.316689 56.425761 29.7600
X1           -0.823326 -0.679279 -0.473132 -0.294959 -0.210060 -0.3954
X2           -0.149969  0.056341  0.090014  0.117921  0.149627  0.0853
X3           -0.193790 -0.104936 -0.055773  0.024691  0.200615 -0.0581
Number of data points: 34
Effective number of parameters (residual: 2traces - traces'S): 15.71018
Effective degrees of freedom (residual: 2traces - traces'S): 18.28982
Sigma (residual: 2traces - traces'S): 1.208421
Effective number of parameters (model: traces): 12.93553
Effective degrees of freedom (model: traces): 21.06447
Sigma (model: traces): 1.126024
Sigma (ML): 0.8863054
AICC (GWR p. 61, eq 2.33; p. 96, eq. 4.21): 137.9865
AIC (GWR p. 96, eq. 4.22): 101.2162
Residual sum of squares: 26.70827
Quasi-global R2: 0.7998555
```

```
> h <- gwr.sel(TPT~X1+X2+X3,
+             coords=cbind(LON,LAT),
+             data=datasps, adapt=FALSE,gweight=gwr.Gauss)
Bandwidth: 16.61727 CV score: 80.94552
Bandwidth: 26.86046 CV score: 84.37371
Bandwidth: 10.28663 CV score: 78.11145
Bandwidth: 6.374075 CV score: 65.83319
Bandwidth: 3.955985 CV score: 74.19984
Bandwidth: 6.824891 CV score: 69.1418
Bandwidth: 5.624624 CV score: 60.87585
Bandwidth: 4.987261 CV score: 61.29405
Bandwidth: 5.368517 CV score: 60.2624
Bandwidth: 5.346932 CV score: 60.25424
Bandwidth: 5.331725 CV score: 60.25298
Bandwidth: 5.334165 CV score: 60.25293
Bandwidth: 5.334214 CV score: 60.25293
Bandwidth: 5.334254 CV score: 60.25293
Bandwidth: 5.334214 CV score: 60.25293
```

```
> gwr2$bandwidth
[1] 5.334214
```

```

> gwr2$SDF$(Intercept)"
[1] 20.17445 27.72288 37.63589 37.26598 45.31786 54.34496 52.26651 56.36048 53.17513 42.12750
[11] 54.78055 53.21730 48.11302 47.98297 43.52813 56.42576 35.12977 27.62183 20.64143 36.90710
[21] 31.75457 27.30297 21.09205 21.00834 25.76865 20.59827 19.78289 20.44676 22.98935 19.95833
[31] 35.46559 33.64155 40.65712 39.61906
> gwr2$SDF$X1
[1] -0.2100598 -0.3240410 -0.4836175 -0.4770579 -0.6137896 -0.7738699 -0.7349762 -0.8158559
[9] -0.7608080 -0.5686117 -0.7976142 -0.7750969 -0.6976175 -0.6962822 -0.6282675 -0.8233263
[17] -0.4988895 -0.3806822 -0.2690300 -0.5138608 -0.4377603 -0.3695354 -0.2642937 -0.2625210
[25] -0.3267107 -0.2555428 -0.2489674 -0.2589432 -0.2852646 -0.2507155 -0.4692062 -0.4466814
[33] -0.5320489 -0.4287606
> gwr2$SDF$X2
[1] 0.042273424 0.045925847 0.056677323 0.056229161 0.072005000 0.098997058 0.089513315
[8] 0.116923908 0.109381857 0.090514586 0.132989749 0.140114129 0.146936090 0.149626536
[15] 0.147270667 0.131119871 0.132626010 0.111641602 0.083003869 0.118334880 0.118252742
[22] 0.109415814 0.090946585 0.094566214 0.028241854 0.059414717 0.075494563 0.063485619
[29] 0.043098865 0.078028447 -0.015547407 -0.004208946 -0.047323818 -0.149969003
> gwr2$SDF$X3
[1] -0.152883116 -0.157001334 -0.105146003 -0.110563093 -0.045366262 0.039013940 0.017811671
[8] 0.055575108 0.027625432 -0.116055301 0.026983833 0.001183124 -0.052434585 -0.059111715
[15] -0.079801663 0.045543828 -0.085853350 -0.078914492 -0.052306953 -0.104304739 -0.124519846
[22] -0.121421653 -0.173851935 -0.193789598 0.016884467 -0.062955932 -0.081800776 -0.036199380
[29] -0.041561344 -0.097577575 0.173058414 0.150849521 0.200615169 0.129488248

```

Gambar 5.9: Estimasi Parameter Fixed Gaussian

```
> BFC02.gwr.test(gwr2)
```

Brunsdon, Fotheringham & Charlton (2002, pp. 91-2) ANOVA

data: gwr2

F = 2.6929, df1 = 30.00, df2 = 18.29, p-value = 0.01477

alternative hypothesis: greater

sample estimates:

SS OLS residuals	SS GWR residuals
71.92322	26.70827

2. Adaptive Gaussian

```

> T.bofixedgauss
[1] 1.415751 2.179438 3.384614 3.362688 4.518420 6.111118 5.456550 6.998938 6.934240 4.908583
[11] 7.320262 7.268356 6.969365 6.915568 6.633335 7.292580 5.648257 4.327302 3.098272 6.119713
[21] 5.315684 4.518847 3.239615 3.162962 3.520096 3.166598 3.093683 3.200969 3.289949 3.128549
[31] 3.046347 3.108628 2.705143 2.367960
> T.b1fixedgauss
[1] -1.038464 -1.796659 -3.077746 -3.052898 -4.325211 -5.933891 -5.306489 -6.650797 -6.558078
[10] -4.557054 -6.833712 -6.759752 -6.474993 -6.430073 -6.160441 -6.831217 -5.211352 -3.903137
[19] -2.645466 -5.450681 -4.742520 -3.997168 -2.704333 -2.642619 -3.091541 -2.631492 -2.580450
[28] -2.691622 -2.797481 -2.605436 -2.903412 -3.021693 -2.592059 -1.664093
> T.b2fixedgauss
[1] 0.70278922 0.81998129 1.07765578 1.09053418 1.47662909 2.23153801 1.85697315 2.84409508
[9] 2.80634208 2.21088527 3.32969600 3.52055406 3.81975575 3.85869333 3.85045459 3.17630633
[17] 3.50155647 2.91669743 1.98296055 3.17378776 3.20084039 2.99271178 2.31461314 2.31177403
[25] 0.54609652 1.42406553 1.96918167 1.51702716 0.91411688 2.07458692 -0.21851185 -0.06041008
[33] -0.55964556 -1.28208567
> T.b3fixedgauss
[1] -1.30528726 -1.47170533 -1.04262094 -1.11681751 -0.46714955 0.40621465 0.17864886 0.60781007
[9] 0.31318111 -1.34507082 0.31970960 0.01455037 -0.69581399 -0.78283132 -1.10755095 0.51916975
[17] -1.22571804 -1.12111998 -0.75268563 -1.51613233 -1.89099958 -1.87732471 -2.35341173 -2.50361456
[25] 0.25394310 -1.03459865 -1.34902939 -0.63557946 -0.61903074 -1.57623574 2.00855990 1.83624528
[33] 1.97542900 0.96978924
.....

> gwr1
Call:
gwr(formula = TPT ~ X1 + X2 + X3, data = datasps, coords = cbind(LON,
LAT), gweight = gwr.Gauss, adapt = b, hatmatrix = TRUE)
kernel function: gwr.Gauss
Adaptive quantile: 0.1470557 (about 4 of 34 data points)
Summary of GWR coefficient estimates at data points:
      Min.   1st Qu.   Median   3rd Qu.    Max.   Global
x.Intercept. 19.320341 24.946674 31.284880 48.835399 82.539618 29.7600
X1           -1.268195 -0.704660 -0.396746 -0.310176 -0.239325 -0.3954
X2            0.023952  0.059950  0.091884  0.126316  0.152472  0.0853
X3           -0.174613 -0.105399 -0.055882  0.063315  0.369537 -0.0581
Number of data points: 34
Effective number of parameters (residual: 2traces - traces's): 15.87138
Effective degrees of freedom (residual: 2traces - traces's): 18.12862
Sigma (residual: 2traces - traces's): 1.208064
Effective number of parameters (model: traces): 12.83297
Effective degrees of freedom (model: traces): 21.16703
Sigma (model: traces): 1.118002
Sigma (ML): 0.8821308
AICc (GWR p. 61, eq 2.33; p. 96, eq. 4.21): 137.0356
AIC (GWR p. 96, eq. 4.22): 100.7926
Residual sum of squares: 26.45726
Quasi-global R2: 0.8017365

```

3. Fixed Bi-Square

```

> b <- gwr.sel(TPT~X1+X2+X3,
+             coords=cbind(LON,LAT),
+             data=datasps, adapt=TRUE,gweight=gwr.Gauss)
Adaptive q: 0.381966 CV score: 69.04261
Adaptive q: 0.618034 CV score: 77.68153
Adaptive q: 0.236068 CV score: 61.99404
Adaptive q: 0.145898 CV score: 60.4912
Adaptive q: 0.1288168 CV score: 60.66486
Adaptive q: 0.1576752 CV score: 61.01367
Adaptive q: 0.1400477 CV score: 60.49915
Adaptive q: 0.1438389 CV score: 60.49441
Adaptive q: 0.1503965 CV score: 60.66064
Adaptive q: 0.1476163 CV score: 60.51721
Adaptive q: 0.1451115 CV score: 60.49265
Adaptive q: 0.1465544 CV score: 60.4897
Adaptive q: 0.14696 CV score: 60.48863
Adaptive q: 0.1472107 CV score: 60.49621
Adaptive q: 0.146805 CV score: 60.48905
Adaptive q: 0.1470557 CV score: 60.48836
Adaptive q: 0.1471149 CV score: 60.49125
Adaptive q: 0.147015 CV score: 60.48848
Adaptive q: 0.1470557 CV score: 60.48836

> gwr1$bandwidth
[1] 9.988252 6.344878 4.043831 4.233828 4.194738 3.761074 3.923596 3.213616 4.178787
[10] 7.876452 3.493989 3.395482 4.143716 4.603011 5.243503 3.761189 5.317710 5.935831
[19] 6.099676 5.444859 5.964059 4.867584 5.303611 6.460644 5.868622 3.258734 5.019925
[28] 4.852461 5.019938 4.784723 8.022043 7.035231 10.919335 15.906137

> gwr1$SDF$(Intercept)
[1] 35.05545 32.96942 29.81007 30.68597 44.86281 68.63523 61.22873 82.53962 63.59759 35.26422
[11] 71.66661 65.56531 51.77801 50.15960 43.79199 71.67651 35.14371 28.45292 22.18185 36.74699
[21] 31.88379 26.50897 21.04499 22.99913 23.90447 26.00644 19.38765 20.41262 23.93277 19.32034
[31] 26.10399 26.45054 24.81978 25.32735

> gwr1$SDF$X1
[1] -0.4362984 -0.4007584 -0.3770632 -0.3853487 -0.6268991 -1.0479838 -0.9214171 -1.2681951
[9] -0.9302641 -0.4684374 -1.0666241 -0.9618775 -0.7519027 -0.7287340 -0.6324370 -1.0731317
[17] -0.4991388 -0.3927335 -0.2931635 -0.5112570 -0.4386147 -0.3575793 -0.2635205 -0.2939346
[25] -0.3037606 -0.3058975 -0.2421148 -0.2566349 -0.2956418 -0.2393246 -0.3404276 -0.3436598
[33] -0.3230113 -0.3357661

> gwr1$SDF$X2
[1] 0.05601929 0.04637997 0.06378398 0.05987988 0.08808370 0.14842115 0.13631123 0.14829096
[9] 0.10907151 0.09290330 0.12632881 0.12627594 0.14973263 0.15247160 0.14797013 0.13358294
[17] 0.13269089 0.11306312 0.08730566 0.11819271 0.11679180 0.10808124 0.09086383 0.09451368
[25] 0.03820222 0.02395158 0.07359899 0.06015992 0.03789701 0.07453994 0.03428160 0.02487831
[33] 0.04891895 0.07137261

> gwr1$SDF$X3
[1] -0.167337512 -0.157618430 -0.093974499 -0.103969938 0.009928010 0.253832965 0.180222413
[8] 0.369536670 0.144831598 -0.140429031 0.205416864 0.113588272 -0.047155081 -0.059385689
[15] -0.079754122 0.212818313 -0.085770698 -0.082297680 -0.052377640 -0.105875786 -0.123478430
[22] -0.122161663 -0.174612970 -0.160657514 0.014387566 -0.133276167 -0.084588818 -0.038891932
[29] -0.048258194 -0.103647736 0.071563941 0.084078759 0.038568705 0.003189048

```

Gambar 5.10: Estimasi Parameter Adaptive Gaussian

4. Adaptive Bi-Square


```
> BFC02.gwr.test(gwr1)
```

```
Brunsdon, Fotheringham & Charlton (2002, pp. 91-2) ANOVA
```

```
data: gwr1
F = 2.7185, df1 = 30.000, df2 = 18.129, p-value = 0.01435
alternative hypothesis: greater
sample estimates:
SS OLS residuals SS GWR residuals
      71.92322      26.45726
```

```
> T.boadaptifgauss
```

```
[1] 4.172081 2.929151 2.337141 2.437159 3.887939 5.653830 5.086119 6.079029 6.561011 5.945602
[11] 6.562146 6.609213 6.951933 6.929188 6.684149 6.670110 5.686044 4.729414 3.610315 6.178323
[21] 5.545132 4.274095 3.243261 3.919610 3.566607 2.039408 2.965750 3.096207 3.234644 2.885976
[31] 3.768338 3.605505 3.905491 4.442047
```

```
> T.b1adaptifgauss
```

```
[1] -3.562447 -2.502254 -2.072660 -2.158031 -3.733901 -5.406565 -4.842189 -5.799275 -6.299081
[10] -5.385820 -6.199719 -6.092297 -6.477616 -6.448162 -6.209163 -6.266313 -5.246025 -4.294988
[19] -3.152228 -5.505947 -4.958582 -3.753586 -2.706801 -3.306834 -3.072588 -1.783012 -2.456240
[28] -2.594620 -2.781575 -2.374943 -3.314972 -3.222873 -3.410907 -3.922100
```

```
> T.b2adaptifgauss
```

```
[1] 1.3260672 0.8968202 1.1028584 1.0658819 1.5628779 2.4188620 2.1497727 2.1774167 2.4400675
[10] 2.8333408 1.9807032 1.9051347 3.5996332 3.7585910 3.8744990 2.1679593 3.5249896 3.0748470
[19] 2.2354699 3.2237754 3.3093148 2.9019574 2.3200455 2.6404295 0.8161349 0.3216658 1.9046512
[28] 1.3817772 0.7595225 1.9505450 0.7383449 0.4940659 1.1884771 2.0089170
```

```
> T.b3adaptifgauss
```

```
[1] -1.95688292 -1.57199598 -0.84899808 -0.98434840 0.08641927 1.72112745 1.24354488 2.24143024
[9] 1.28822580 -2.22690496 1.55517800 0.91180258 -0.53737105 -0.71915225 -1.10457138 1.63403200
[17] -1.23192295 -1.23661513 -0.83762066 -1.56604888 -1.98318808 -1.83304205 -2.36735073 -2.52094183
[25] 0.24138260 -1.11905679 -1.36937184 -0.65847529 -0.66870926 -1.60354651 1.33290182 1.41716782
[33] 0.79678588 0.07172425
```

```
> gwr4
```

```
Call:
```

```
gwr(formula = TPT ~ X1 + X2 + X3, data = datasps, coords = cbind(LON,
LAT), bandwidth = f, gweight = gwr.bisquare, hatmatrix = TRUE)
```

```
kernel function: gwr.bisquare
```

```
Fixed bandwidth: 16.38876
```

```
Summary of GWR coefficient estimates at data points:
```

	Min.	1st Qu.	Median	3rd Qu.	Max.	Global
x.Intercept.	19.690109	23.108188	36.229741	44.619517	50.309221	29.7600
X1	-0.725232	-0.637549	-0.489966	-0.281012	-0.061339	-0.3954
X2	-0.325141	0.050765	0.086031	0.116483	0.145159	0.0853
X3	-0.184303	-0.110573	-0.054546	-0.019692	0.199935	-0.0581

```
Number of data points: 34
```

```
Effective number of parameters (residual: 2traces - traces's): 12.57939
```

```
Effective degrees of freedom (residual: 2traces - traces's): 21.42061
```

```
Sigma (residual: 2traces - traces's): 1.254948
```

```
Effective number of parameters (model: traces): 10.76097
```

```
Effective degrees of freedom (model: traces): 23.23903
```

```
Sigma (model: traces): 1.204849
```

```
Sigma (ML): 0.9960983
```

```
AICc (GWR p. 61, eq 2.33; p. 96, eq. 4.21): 133.8765
```

```
AIC (GWR p. 96, eq. 4.22): 106.9829
```

```
Residual sum of squares: 33.7352
```

```
Quasi-global R2: 0.7471976
```

```

> f <- gwr.sel(TPT~X1+X2+X3,
+             coords=cbind(LON,LAT),
+             data=datasps, adapt=FALSE,gweight=gwr.bisquare)
Bandwidth: 16.61727 CV score: 63.11979
Bandwidth: 26.86046 CV score: 86.95106
Bandwidth: 10.28663 CV score: NA
Bandwidth: 20.52982 CV score: 81.26439
Bandwidth: 14.19918 CV score: NA
Bandwidth: 18.11173 CV score: 70.88111
Bandwidth: 15.69364 CV score: 64.43049
Bandwidth: 16.41492 CV score: 62.85486
Bandwidth: 16.34303 CV score: 62.86467
Bandwidth: 16.39192 CV score: 62.85062
Bandwidth: 16.38936 CV score: 62.85055
Bandwidth: 16.38867 CV score: 62.85055
Bandwidth: 16.38876 CV score: 62.85055
Bandwidth: 16.3888 CV score: 62.85055
Bandwidth: 16.38872 CV score: 62.85055
Bandwidth: 16.38876 CV score: 62.85055

> gwr4$bandwidth
[1] 16.38876

> gwr4$SDF$(Intercept)"
[1] 23.09545 36.47083 43.69592 43.37163 46.36424 48.58137 48.77452 49.09895 46.67646 40.41822
[11] 49.20784 48.73368 44.53327 44.64826 40.55361 50.30922 34.61293 29.24935 21.35558 35.98865
[21] 32.38704 29.05611 22.50256 22.14466 23.14641 19.69011 21.00280 19.78753 20.99902 21.55619
[31] 37.29283 35.69468 42.26567 24.16819
> gwr4$SDF$X1
[1] -0.25320799 -0.44592346 -0.56453283 -0.56164197 -0.61772598 -0.67031391 -0.66315183 -0.69442375
[9] -0.65590971 -0.54600789 -0.71057268 -0.70767906 -0.64415697 -0.64702617 -0.58205022 -0.72523213
[17] -0.48863867 -0.40382980 -0.27926352 -0.49886442 -0.44487746 -0.39445338 -0.28621657 -0.27927753
[25] -0.29520802 -0.24726737 -0.26996120 -0.25210785 -0.26338239 -0.27739810 -0.49129417 -0.46790865
[33] -0.55762902 -0.06133917
> gwr4$SDF$X2
[1] 0.04285854 0.03848069 0.04895582 0.05160320 0.06436213 0.08913954 0.07518438 0.11174031
[9] 0.10958477 0.08865936 0.13298866 0.14043015 0.14277277 0.14515905 0.14003729 0.12946040
[17] 0.13003454 0.11538491 0.08308691 0.11841312 0.11684895 0.11156897 0.09435268 0.09586117
[25] 0.03946135 0.06314580 0.07974826 0.06550108 0.05048620 0.08340268 -0.02556053 -0.01747474
[33] -0.04681508 -0.32514115
> gwr4$SDF$X3
[1] -0.161301314 -0.160103791 -0.113730266 -0.113884978 -0.081263389 -0.045143678 -0.054089773
[8] -0.026823767 -0.044670274 -0.101100042 -0.016613989 -0.020858666 -0.054067343 -0.055001632
[15] -0.078404604 -0.009527091 -0.095784682 -0.093886723 -0.050607112 -0.117592124 -0.128525126
[22] -0.126211245 -0.163269894 -0.184303240 0.031044618 -0.033587189 -0.067302037 -0.019302683
[29] -0.009553094 -0.084334799 0.172118194 0.147969586 0.199935203 0.045509815

```

Gambar 5.11: Estimasi Parameter Fixed Gaussian

```
> #Uji Kecocokan Model
> BFC02.gwr.test(gwr4)
```

Brunsdon, Fotheringham & Charlton (2002, pp. 91-2) ANOVA

```
data: gwr4
F = 2.132, df1 = 30.000, df2 = 21.421, p-value = 0.03643
alternative hypothesis: greater
sample estimates:
SS OLS residuals SS GWR residuals
      71.92322      33.73520
```

```
> T.bofixedbisphere
```

```
[1] 1.551298 2.883841 3.855209 3.856876 4.721117 6.006199 5.376231 6.617740 6.549889 4.814688
[11] 6.749630 6.705620 6.455379 6.425024 6.099223 6.760121 5.357730 4.623909 3.278184 5.802774
[21] 5.275890 4.731749 3.525940 3.393837 3.283551 3.062008 3.352321 3.073247 3.140416 3.461303
[31] 3.233379 3.120250 2.729190 0.789157
```

```
> T.b1fixedbisphere
```

```
[1] -1.19987827 -2.48422851 -3.52115106 -3.54060520 -4.43260001 -5.68541222 -5.09718757 -6.18870267
[9] -6.09531347 -4.51954692 -6.22131530 -6.16613422 -5.94168842 -5.93050327 -5.63474260 -6.25810454
[17] -4.94877528 -4.21593986 -2.83722360 -5.19437210 -4.72436158 -4.22983548 -2.96730387 -2.83743512
[25] -2.83770514 -2.54492067 -2.85393714 -2.58765492 -2.63665219 -2.95035154 -3.03898232 -2.99087671
[33] -2.61273774 -0.09240332
```

```
> T.b2fixedbisphere
```

```
[1] 0.6856243 0.6676850 0.9217835 0.9945005 1.3643918 2.1659068 1.6635996 2.8546650
[9] 2.8695536 2.1224688 3.3571657 3.5247072 3.6898268 3.7222521 3.6468945 3.2382867
[17] 3.3722417 2.9807608 2.0218945 3.2332081 3.1838945 2.9880584 2.4352355 2.4357406
[25] 0.8362024 1.5401334 2.0290467 1.5872194 1.1550391 2.1454178 -0.3388552 -0.2365667
[33] -0.5311628 -1.0788428
```

```
> T.b3fixedbisphere
```

```
[1] -1.3622314 -1.4552000 -1.0727263 -1.0878298 -0.8343984 -0.5174193 -0.5776922 -0.3170804
[9] -0.5418357 -1.1533960 -0.1989650 -0.2565392 -0.7363507 -0.7502293 -1.1152828 -0.1112034
[17] -1.3557295 -1.3425344 -0.7629536 -1.6979905 -1.9352679 -1.9173624 -2.3288776 -2.4815964
[25] 0.5109575 -0.5713008 -1.1076883 -0.3310379 -0.1581981 -1.3690899 1.8706907 1.7466054
[33] 1.8466340 0.1833020
```

```
> gwr3
```

```
call:
```

```
gwr(formula = TPT ~ X1 + X2 + X3, data = datasps, coords = cbind(LON,
LAT), gweight = gwr.bisphere, adapt = e, hatmatrix = TRUE)
```

```
kernel function: gwr.bisphere
```

```
Adaptive quantile: 0.3861647 (about 13 of 34 data points)
```

```
summary of GWR coefficient estimates at data points:
```

	Min.	1st Qu.	Median	3rd Qu.	Max.	global
X.Intercept.	15.319670	22.735470	36.101383	54.032949	89.437373	29.7600
X1	-1.398103	-0.779352	-0.482105	-0.267373	-0.188436	-0.3954
X2	-0.049349	0.046240	0.080284	0.133735	0.206029	0.0853
X3	-0.266926	-0.106407	-0.058491	0.189207	0.468898	-0.0581

```
Number of data points: 34
```

```
Effective number of parameters (residual: 2traces - traces's): 20.30852
```

```
Effective degrees of freedom (residual: 2traces - traces's): 13.69148
```

```
Sigma (residual: 2traces - traces's): 1.026213
```

```
Effective number of parameters (model: traces): 17.29388
```

```
Effective degrees of freedom (model: traces): 16.70612
```

```
Sigma (model: traces): 0.9290193
```

```
Sigma (ML): 0.6512129
```

```
AICc (GWR p. 61, eq 4.23; p. 96, eq. 4.21): 151.9109
```

```
AIC (GWR p. 96, eq. 4.22): 84.61524
```

```
Residual sum of squares: 14.41866
```

```
quasi-global R2: 0.8919505
```

```

> e <- gwr.sel(TPT~X1+X2+X3,
+             coords=cbind(LON,LAT),
+             data=datasps, adapt=TRUE,gweight=gwr.bisquare)
Adaptive q: 0.381966 CV score: 63.65776
Adaptive q: 0.618034 CV score: 77.94949
Adaptive q: 0.236068 CV score: 118.4956
Adaptive q: 0.4735057 CV score: 72.66527
Adaptive q: 0.3262379 CV score: 67.69249
Adaptive q: 0.3853145 CV score: 63.53922
Adaptive q: 0.411905 CV score: 68.7748
Adaptive q: 0.3954712 CV score: 64.38095
Adaptive q: 0.3856614 CV score: 63.53515
Adaptive q: 0.3864026 CV score: 63.53345
Adaptive q: 0.3898665 CV score: 63.66417
Adaptive q: 0.3861647 CV score: 63.53293
Adaptive q: 0.386124 CV score: 63.53294
Adaptive q: 0.3862054 CV score: 63.53295
Adaptive q: 0.3861647 CV score: 63.53293
" - - - - - "

> gwr3$bandwidth
[1] 16.293265 12.511038 10.768642 9.974908 9.174969 8.182653 9.524602 7.585269 6.915817
[10] 10.054103 8.171285 7.962968 7.531184 8.103421 8.451123 8.243996 8.990986 10.249038
[19] 10.728548 8.152063 7.879073 7.108609 10.152591 11.045593 10.912412 8.948839 8.713460
[28] 9.146999 10.681317 8.202625 14.926829 13.527395 17.695944 22.871353

> gwr3$SDF$(Intercept)"
[1] 22.74388 22.73267 31.38618 26.29688 51.81006 78.04460 71.81507 89.24538 89.43737 58.25502
[11] 87.30420 81.84833 54.36831 53.02686 52.11825 88.73208 30.77764 19.41945 17.09164 33.93901
[21] 15.31967 22.23257 24.21718 19.85785 39.84583 25.31618 19.16758 21.28843 33.92663 21.39798
[31] 39.03120 38.26376 41.36783 41.42779

> gwr3$SDF$X1
[1] -0.2484283 -0.2534034 -0.3936257 -0.3176964 -0.7804129 -1.2484397 -1.1395849 -1.3981035
[9] -1.3703735 -0.8139051 -1.3357518 -1.2341937 -0.7761690 -0.7526600 -0.7502448 -1.3659938
[17] -0.4317816 -0.2514782 -0.2130726 -0.4648884 -0.1884361 -0.2844167 -0.2950676 -0.2427081
[25] -0.4993217 -0.2972933 -0.2322670 -0.2616911 -0.4109002 -0.2582015 -0.5170755 -0.5137835
[33] -0.5456754 -0.5403669

> gwr3$SDF$X2
[1] 0.04317026 0.04601183 0.05539786 0.05429061 0.13522826 0.20602924 0.19470670 0.17214502
[9] 0.13009045 0.09698972 0.13494970 0.12191480 0.13566691 0.13793493 0.15763620 0.14424832
[17] 0.12013226 0.08542788 0.07336279 0.07513934 0.08809714 0.09090521 0.06622593 0.10027643
[25] -0.04051986 0.02734510 0.06253639 0.04692364 -0.01410400 0.05435806 -0.03183004 -0.01848780
[33] -0.04301365 -0.04934939

> gwr3$SDF$X3
[1] -0.16025001 -0.14579995 -0.10049762 -0.10837662 0.15376694 0.41725232 0.35290602 0.46889757
[9] 0.44123459 -0.04763309 0.42269128 0.34981671 -0.06219566 -0.09747241 -0.11657477 0.43858775
[17] -0.06923491 -0.06087760 -0.05610348 0.08940894 -0.07751250 -0.16606547 -0.21343800 -0.26692622
[25] 0.03351404 -0.13663053 -0.09834028 -0.04920628 -0.07178596 -0.11777837 0.19027366 0.18424484
[33] 0.19410545 0.18600791

```

Gambar 5.12: Estimasi Parameter Adaptive Gaussian

```
> BFC02.gwr.test(gwr3)
```

```
Brunsdon, Fotheringham & Charlton (2002, pp. 91-2) ANOVA
```

```
data: gwr3
```

```
F = 4.9882, df1 = 30.000, df2 = 13.691, p-value = 0.001468
```

```
alternative hypothesis: greater
```

```
sample estimates:
```

```
SS OLS residuals SS GWR residuals
      71.92322      14.41866
```

```
> T.boadaptifbisphere
```

```
[1] 1.973157 1.993373 3.020438 2.372705 4.293573 6.606012 6.165175 7.027373 6.434062 3.158714
[11] 6.569381 6.267529 8.072899 8.041008 7.920839 6.668739 4.138138 2.340502 2.196970 1.197052
[21] 1.628592 2.887019 1.603750 1.306285 3.685605 1.884634 2.767434 2.667005 2.830180 2.688004
[31] 3.968628 3.385790 3.802979 3.940753
```

```
> T.b1adaptifbisphere
```

```
[1] -1.520891 -1.568863 -2.662021 -2.007292 -3.873886 -6.094508 -5.643083 -6.597738 -6.381468
[10] -2.920966 -6.116736 -5.445454 -6.903783 -6.889504 -7.359066 -6.180820 -3.613224 -1.902630
[19] -1.691104 -1.207939 -1.313890 -2.376245 -1.531695 -1.252383 -3.582356 -1.670182 -2.257930
[28] -2.305927 -2.654164 -2.254481 -3.747680 -3.393312 -3.630233 -3.725722
```

```
> T.b2adaptifbisphere
```

```
[1] 0.8943005 0.9595868 1.1623385 1.1254986 2.1517081 3.0775407 2.9403106 2.4867801
[9] 1.8587121 1.8733766 1.6574363 1.2483566 2.6361459 2.8321685 4.1754783 1.7922188
[17] 2.7625455 2.0441116 1.6010538 0.7046930 1.8304154 2.1827279 0.7953858 1.2076861
[25] -0.5854583 0.3657525 1.6639981 0.9048214 -0.2011092 1.3561199 -0.5168966 -0.2690884
[33] -0.6603277 -0.7618402
```

```
> T.b3adaptifbisphere
```

```
[1] -1.7507518 -1.6189402 -1.1199738 -1.2054466 1.0453078 2.5734644 2.1923097 2.8832483
[9] 2.7779633 -0.3475625 2.4177103 1.8239371 -0.6226359 -0.9983248 -1.3332384 2.4998854
[17] -1.0446866 -0.9386780 -0.7920329 0.3310226 -0.6371490 -1.5532468 -1.9512195 -2.4862216
[25] 0.4085302 -1.1616791 -1.5964556 -0.6245528 -0.7643015 -1.6596950 2.4522822 2.3662852
[33] 2.4426854 2.3851916
```

DAFTAR RIWAYAT HIDUP

Penulis bernama lengkap Mila Rizki Ramadayani yang lahir di Jakarta pada tanggal 11 Desember 1999 dari pasangan Bapak Imhar dan Ibu Siti Aisyah. Penulis anak kedua dari empat bersaudara.

Penulis menyelesaikan pendidikan Sekolah Dasar di SD Negeri Jakasetia VI Bekasi Selatan pada 2011 dan melanjutkan pendidikan di SMP Negeri 7 Bekasi hingga 2014. Pada tahun 2017 penulis lulus dari SMA Negeri 6 Bekasi. Berkeinginan melanjutkan pendidikan hingga jenjang perkuliahan, penulis mengikuti seleksi Penmaba UNJ dan diterima di Universitas Negeri Jakarta dengan Program Studi S1 Matematika.

Selama masa perkuliahan penulis aktif dalam organisasi kemahasiswaan. Bergabung di BEM Matematika sebagai Staff Rohis periode 2018/2019 dan menjadi Staff Diklit periode 2019/2020. Kemudian melanjutkan BEM Fakultas Matematika dan Ilmu Pengetahuan Alam sebagai Biro Entrepreneur pada 2020/2021.