



**METODE *GEOGRAPHICALLY WEIGHTED* UNTUK DATA
INDEKS PEMBANGUNAN MANUSIA DI PULAU JAWA**

*Diajukan untuk memenuhi sebagian persyaratan memperoleh gelar Sarjana pada
program studi Matematika*

SKRIPSI

Oleh :

**Indah Lestari
201810101121**

**KEMENTERIAN PENDIDIKAN, KEBUDAYAAN, RISET, DAN TEKNOLOGI
UNIVERSITAS JEMBER
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
JURUSAN MATEMATIKA
JEMBER
2024**

PERSEMBAHAN

Penulis mengucapkan rasa syukur atas karunia yang diberikan oleh Allah SWT sehingga bisa menyelesaikan skripsi ini dengan baik. Penulis mempersembahkan skripsi ini kepada :

1. Bapak Turikhan yang selalu memberikan semangat, dukungan dan do'a kepada penulis dalam menyelesaikan skripsi ini.
2. Alm. Ibu Mindariyati yang telah memberikan kasih sayang yang tak terhingga dan mendoakan dari surga kepada penulis agar bisa sampai di titik ini.
3. Kak Syarofi yang telah memberikan inspirasi serta dukungan baik secara fisik maupun mental.
4. Keluarga besar yang memberikan petuah, motivasi, semangat kepada penulis dalam menyelesaikan studi di perguruan tinggi ini.
5. Almamater Universitas Jember, SMA 1 Kudus, SMP 5 Kudus, dan SD 2 Bacin yang telah memberikan ilmu dan membimbing penulis dalam proses menuntut ilmu sehingga dapat mengamalkan ilmu ini dalam kehidupan.

MOTTO

“Tidak ada kesuksesan tanpa kerja keras. Tidak ada keberhasilan tanpa kebersamaan. Tidak ada kemudahan tanpa do’a.”

(Ridwan Kamil)

“Tidak ada jalan pintas menuju kesuksesan yang sejati.”

(John Wooden)

“Great things are not done by impulse, but by a series of small things brought together.”

(Vincent Van Gogh)

PERNYATAAN ORISINALITAS

Saya yang bertanda tangan di bawah ini :

Nama : Indah Lestari

NIM : 201810101121

Menyatakan dengan sesungguhnya bahwa skripsi yang berjudul : “Metode *Geographically Weighted* Untuk Data Indeks Pembangunan Manusia Di Pulau Jawa” adalah benar-benar hasil karya sendiri, kecuali jika dalam pengutipan substansi disebutkannya sumbernya, dan belum pernah diajukan pada institusi manapun, serta bukan karya jiplakan. Saya bertanggung jawab atas keabsahan dan kebenaran isinya sesuai dengan sikap ilmiah yang harus dijunjung tinggi.

Demikian pernyataan ini saya buat dengan sebenarnya, tanpa adanya tekanan dan paksaan dari pihak manapun serta bersedia mendapat sanksi akademik jika ternyata di kemudian hari pernyataan ini tidak benar.

Jember, 24 Juni 2024

Yang menyatakan,

Indah Lestari

NIM 201810101121

HALAMAN PERSSETUJUAN

Skripsi berjudul “Metode *Geographically Weighted* Untuk Data Indeks Pembangunan Manusia Di Pulau Jawa” telah diuji dan disahkan pada

Hari :

Tanggal :

Tempat : Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Jember

Tim Penguji

Ketua,

Anggota I,

Dr. Yuliani Setia Dewi, S.Si., M.Si.
NIP. 197407162000032001

Prof. Drs. I Made Tirta, M.Sc., Ph.D.
NIP. 195912201985031002

Anggota II,

Anggota III,

Dr. Mohamat Fatekurohman, S.Si., M.Si.
NIP. 196906061998031001

Ahmad Kamsyakawuni, S.Si., M.Kom.
NIP. 197211291998021001

ABSTRACT

The Human Development Index is an indicator used to measure the success of a country's development. According to the Central Statistical Agency (BPS), Java is an island that produces different HDI values in each province. This is due to the influence of spatial effects that can be overcome by Geographically Weighted Regression (GWR) method for linear data and Geographical Weighted Artificial Neural Network (GWANN) on nonlinear data. The aim to identify the factors influencing HDI and select best models among the GWR, GWRR, and GWANN methods. GWR is an extension of linear regression that incorporates a weighting function to account for spatial variability. However, multicollinearity detected in the GWR model can increase the variance, which can be mitigated using the GWRR method. The GWR, GWRR, and GWANN models conducted the selection of best models based on R^2 and RMSE values. On the GWR, GWRR, and the GWANN method obtained R^2 values in succession are 0.87, 0.93 and 0.54. The RMSE value of GWR < GWANN < GWR (1.35 < 1.83 < 2.74). Based on the R^2 and the RMSE valuation, the Adaptive Gaussian weighting concluded that GWRR is better at explaining the human development index in Java.

Keywords : Human Development Index, Geographically Weighted Regression, Geographically Weighted Ridge Regression, Geographically Weighted Artificial Neural Network.

RINGKASAN

Indeks pembangunan manusia merupakan indikator yang berfungsi untuk mengukur keberhasilan suatu negara dengan melihat tinggi rendahnya kualitas hidup. Menurut BPS tahun 2022, Pulau Jawa memiliki nilai IPM tertinggi dibanding dengan pulau lainnya. Pulau Jawa terbagi atas enam provinsi yaitu Provinsi Jawa Barat, Jawa Tengah, Jawa Timur, Banten, DIY, dan DKI Jakarta. Setiap provinsi di Pulau Jawa memiliki nilai IPM yang berbeda-beda. Hal ini dikarenakan terdapat hubungan spasial antar variabel yang mempengaruhi IPM yang menimbulkan adanya ketergantungan spasial. Metode yang digunakan untuk menganalisis adanya efek spasial adalah *Geographically Weighted Regression* (GWR) dan *Geographically Weighted Artificial Neural Network* (GWANN).

Tujuan dari penelitian ini adalah untuk mengetahui faktor apa saja yang berpengaruh terhadap IPM serta membandingkan metode GWR, GWRR, dan GWANN berdasarkan dari nilai R^2 dan RMSE. Faktor-faktor yang diduga mempengaruhi IPM dianalisis dengan GWR, GWANN, dan GWRR. Metode GWANN merupakan variasi dari *Artificial Neural Network* (ANN) yang menggabungkan ANN dengan pembobot spasial. Metode GWR merupakan pengembangan regresi linier yang ditambah dengan fungsi pembobot. Kasus IPM pada model GWR dideteksi adanya multikolinieritas yang menyebabkan besarnya variansi. Metode untuk mengatasi adanya multikolinieritas adalah *Geographically Weighted Ridge Regression* (GWRR). Metode GWRR memiliki cara kerja yang sama dengan GWR, namun hanya ditambahkan parameter *ridge* untuk mengatasi adanya multikolinieritas. Penentuan pembobot optimum pada model GWR, GWRR, dan GWANN menggunakan *Aike's Information Criteria* (AIC) terkecil. Nilai AIC pada *Adaptive Gaussian* sebesar 514,7019 dan *Adaptive Bisquare* sebesar 521,1609. Berdasarkan hasil AIC diperoleh pembobot optimum yaitu *Adaptive Gaussian*.

Metode GWANN digunakan *single hidden neuron* dengan *batch size* sebesar 11. *Optimizer* yang digunakan adalah momentum, nesterov, sgd, dan adam. *Neuron hidden* yang digunakan dimulai dari 10 sampai 300. Pada metode GWRR

diperoleh nilai parameter *ridge* optimum sebesar 0,0542. Nilai tersebut diperoleh berdasarkan *Generalized Cross Validation* (GCV) minimum. Model terbaik dapat dilihat berdasarkan nilai R^2 dan RMSE. Nilai R^2 dan RMSE yang semakin kecil menunjukkan suatu model memiliki tingkat keakuratan semakin baik. Nilai R^2 dari model GWR, GWRR, dan GWANN berturut-turut yaitu 0,87, 0,93, dan 0,54. Nilai RMSE dari GWRR < GWR < GWANN (1,35 < 1,83 < 2,74). Berdasarkan nilai diperoleh model GWR lebih baik dibanding metode lainnya. Pemilihan model terbaik dihasilkan 6 variabel signifikan dari 8 variabel yang berbeda-beda pada tiap lokasi yang disebabkan adanya pengaruh efek spasial. Oleh karena itu, dapat disimpulkan bahwa model GWRR dengan 6 variabel signifikan mampu menjelaskan indeks pembangunan manusia di Pulau Jawa.

PRAKATA

Puji dan syukur kepada Allah SWT yang telah memberikan rahmat dan karunia-Nya sehingga penulis dapat menyelesaikan tugas akhir dengan judul “Perbandingan *Geographically Weighted Ridge Regression (GWRR)* dan *Geographically Weighted Artificial Neural Network (GWANN)* Pada Indeks Pembangunan Manusia Di Pulau Jawa Tahun 2022”. Penyusunan tugas akhir ini untuk memenuhi syarat dalam menyelesaikan pendidikan Strata Satu (S1) pada Program Studi Matematika dan Ilmu Pengetahuan Alam Universitas Jember.

Penulis menyampaikan terima kasih yang sebesar-besarnya kepada seluruh pihak yang terlibat serta memberikan bantuan selama menempuh pendidikan Strata Satu (S1). Pihak-pihak tersebut diantaranya:

1. Yuliani Setia Dewi, S.Si., M.Si. selaku Dosen Pembimbing Utama dan Prof. Drs. I Made Tirta, M.Sc., Ph.D. selaku Dosen Pembimbing Anggota yang telah memberikan arahan dan meluangkan waktu, tenaga dan pikiran kepada penulis selama penyusunan skripsi ini.
2. Dr. Mohamat Fatekurohman, S.Si., M.Si. dan Ahmad Kamsyakawuni, S.Si., M.Kom. selaku Dosen Penguji yang telah memberikan masukan untuk memperbaiki dan menyempurnakan skripsi ini.
3. Seluruh dosen serta staff Program Studi Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Jember yang telah membantu penulis dalam menempuh pendidikan Strata Satu (S1).
4. Kedua orang tua, Bapak Turikhan yang tidak pernah berhenti untuk memberi dukungan dan do'a serta Almh. Ibu Mindariyati yang senantiasa mendoa'akan penulis dari surga dalam proses menempuh pendidikan Strata Satu (S1).
5. Mas Mohammad Syarofi, Mbak Sri Utami, Mbak Devi Fitriyanti yang tidak pernah berhenti dalam memberikan semangat dan dukungan dalam proses pengerjaan skripsi.
6. Keluarga besar penulis yang senantiasa memberikan masukan dan dukungan dalam menempuh pendidikan Strata Satu (S1).

7. Geameita, Sinta, Khafidha, Ifa, Lutfi, Nur yang telah menjadi sahabat terbaik dan menjadi tempat keluh kesah penulis serta senantiasa memberikan dukungan dalam menyelesaikan pendidikan.
8. Semua pihak yang terlibat dalam kehidupan penulis yang tidak dapat disebutkan satu per satu.
9. Diri saya sendiri, terimakasih karena terus berusaha dan tidak menyerah dalam kondisi apapun, apresiasi terhadap diri saya sendiri karena bertanggung jawab untuk menyelesaikan skripsi ini meskipun banyak rintangan yang dijalani.

Semoga Allah SWT membalas semua bentuk dukungan yang telah diberikan kepada penulis. Penulis menyadari masih bahwa skripsi ini masih jauh dari kesempurnaan. Oleh sebab itu, penulis menerima saran dan masukan dari seluruh pihak. Penulis berharap skripsi ini dapat bermanfaat bagi pihak yang memerlukannya.

Jember, 26 Juni 2024

Penulis

DAFTAR ISI

	Halaman
PERSEMBAHAN	ii
MOTTO	iii
PERNYATAAN ORISINALITAS	iv
HALAMAN PERSETUJUAN	v
ABSTRACT	vi
RINGKASAN	vii
PRAKATA	ix
DAFTAR ISI	xi
DAFTAR TABEL	xiii
DAFTAR GAMBAR	xiv
DAFTAR LAMPIRAN	xv
DAFTAR NOTASI	xvi
BAB 1. PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Tujuan Penelitian.....	4
1.4 Manfaat Penelitian.....	4
BAB 2. TINJAUAN TEORI	5
2.1 Indeks Pembangunan Manusia	5
2.2 Multikolinieritas	6
2.3 Uji Heterogenitas.....	6
2.4 Pembobot Spasial	7
2.5 <i>Geographically Weighted Regression</i>	8
2.5.1 Pengujian Signifikansi Parameter Model	9
2.6 Regresi <i>Ridge</i>	9
2.7 <i>Geographically Weighted Ridge Regression</i>	10
2.8 <i>Artificial Neural Network</i>	11
2.9 <i>Geographically Weighted Artificial Neural Network</i>	11
2.10 Pemilihan Model Terbaik.....	12

2.10.1	Koefisien Determinasi	12
2.10.2	<i>Root Mean Squared Error</i>	12
BAB 3.	METODE PENELITIAN	13
3.1	Populasi dan Sampel/Subyek Penelitian	13
3.2	Prosedur Penelitian	13
3.3	Pengumpulan Data Penelitian	15
BAB 4.	HASIL DAN PEMBAHASAN	17
4.1	Eksplorasi Data Penelitian	17
4.2	Uji Heterogenitas Spasial	20
4.3	Uji Multikolinieritas	21
4.4	Pemodelan dengan <i>Geographically Weighted Regression</i>	21
4.5	Parameter <i>Ridge</i>	25
4.6	Pemodelan <i>Geographically Weighted Ridge Regression</i>	26
4.7	Pemodelan <i>Geographically Weighted Artificial Neural Network</i>	28
4.8	Pemilihan Model Terbaik	30
4.9	Uji Signifikansi Parameter Model Berdasarkan Model Terbaik	31
BAB 5.	KESIMPULAN DAN SARAN	35
5.1	Kesimpulan	35
5.2	Saran	35
	DAFTAR PUSTAKA	36
	LAMPIRAN	38

DAFTAR TABEL

Tabel 2.1 Pembobotan Spasial	7
Tabel 3.1 Variabel Penelitian	15
Tabel 3.2 Struktur Data Penelitian	16
Tabel 4.1 Statistika Deskriptif	17
Tabel 4.2 Nilai VIF	21
Tabel 4.3 <i>Bandwidth</i>	22
Tabel 4.4 Pendugaan Parameter Model GWR	23
Tabel 4.5 Model GWR	23
Tabel 4.6 Multikolinieritas Model GWR	24
Tabel 4.7 Transformasi Variabel Dependen dan Variabel Independen	26
Tabel 4.8 Pendugaan Parameter Model GWRR	27
Tabel 4.9 Model GWRR	28
Tabel 4.10 Perbandingan Model GWR, GWRR, dan GWANN	31
Tabel 4.11 Variabel Signifikan Pada Model GWR	32

DAFTAR GAMBAR

Gambar 3.1 Skema Penelitian	13
Gambar 4.1 Pemetaan Indeks Pembangunan Manusia di Pulau Jawa	18
Gambar 4.2 Grafik <i>Hidden Neurons</i> Dengan RMSE	29
Gambar 4.3 Grafik <i>Hidden Neurons</i> Dengan Iterasi	30
Gambar 4.4 Grafik <i>Hidden Neurons</i> Dengan <i>Bandwidth</i>	30
Gambar 4.5 Pemetaan Variabel Signifikan	34

DAFTAR LAMPIRAN

Lampiran 1. Data IPM di Pulau Jawa	38
Lampiran 2. Statistika Deskriptif	38
Lampiran 3. Uji <i>Breusch-Pagan</i>	38
Lampiran 4. Uji Multikolinieritas	38
Lampiran 5. Jarak <i>Euclid</i>	38
Lampiran 6. Penskalaan Data Frame Spasial	38
Lampiran 7. Pemilihan <i>Bandwidth</i> Optimum Model GWR	38
Lampiran 8. Model GWR	38
Lampiran 9. Penduga Parameter Model GWR	38
Lampiran 10. <i>Output</i> Penduga Parameter Model GWR	38
Lampiran 11. Model GWR Pada Kabupaten Bogor Dan Sukabumi	38
Lampiran 12. Multikolinieritas Model GWR	38
Lampiran 13. Transformasi Data	38
Lampiran 14. <i>Output</i> Transformasi Data IPM	38
Lampiran 15. Parameter <i>Ridge</i>	38
Lampiran 16. <i>Output</i> Parameter <i>Ridge</i>	38
Lampiran 17. Pemilihan <i>Ridge</i> Optimum	38
Lampiran 18. Model GWRR	38
Lampiran 19. <i>Output</i> Penduga Parameter Model GWRR	38
Lampiran 20. Model GWRR Pada Kabupaten Bogor Dan Sukabumi	38
Lampiran 21. Pemodelan GWANN	38
Lampiran 22. <i>Training</i> Model	38
Lampiran 23. <i>Output Training</i> Model	38
Lampiran 24. Nilai RMSE dan R^2	38
Lampiran 25. Output t_{hitung} Berdasarkan Pemilihan Model Terbaik	38

DAFTAR NOTASI

Y_i^*	: transformasi variabel dependen
X_i^*	: transformasi variabel independen
$e_{i,\lambda}^2$: sisaan kuadrat ke- i untuk nilai λ tertentu
H_λ	: matriks $X(X^T X + \lambda I)^{-1} X^T$
d_{ij}	: jarak dari lokasi i ke j
u_i	: <i>longitude</i> lokasi ke- i
v_i	: <i>latitude</i> lokasi ke- i
y_i	: nilai pengamatan variabel dependen lokasi ke- i
x_{ik}	: nilai pengamatan variabel independen ke- k pada lokasi ke- i
β_k	: koefisien parameter lokal untuk masing-masing lokasi (u_i, v_i)
(u_i, v_i)	: koordinat <i>longitude</i> dan <i>latitude</i> pada lokasi ke- i
ε_i	: <i>error</i> pengamatan lokasi ke- i
$\beta_0(u_i, v_i)$: parameter model GWRR lokasi ke- i
X	: matriks variabel independen
Y	: vektor variabel dependen
$\hat{\beta}_R$: estimasi parameter <i>ridge</i>
I	: matriks identitas berorde $(n \times n)$
t_i	: nilai target
o_i	: <i>output</i> neuron i
v_i	: jarak yang ditentukan secara geografis antara pengamatan dan lokasi <i>output</i> neuron i
n	: jumlah nilai target/ <i>output</i> neuron
w_{jk}	: berat koneksi antara neuron j dan k
t_j	: nilai target dari neuron j
δ_k	: sinyal <i>error</i> untuk neuron k
ϕ'	: turunan dari fungsi aktivasi
v_j	: jarak <i>geographically weighted</i> antara pengamatan & lokasi <i>output</i> neuron j

BAB 1. PENDAHULUAN

1.1 Latar Belakang

Pembangunan merupakan alat untuk meningkatkan kesejahteraan dan kualitas hidup masyarakat. Indikator untuk menilai keberhasilan pembangunan suatu negara dalam mengukur tinggi rendahnya kualitas hidup adalah Indeks Pembangunan Manusia (IPM). Konsep IPM pertama kali dipublikasikan melalui laporan tahunan *Human Development Report (HDR)* yang diperkenalkan oleh *United Nations Development Programme (UNDP)* pada tahun 1990. IPM mengukur pencapaian pembangunan manusia yang bertumpu pada komponen dasar taraf hidup. IPM dibentuk melalui tiga pendekatan utama dalam kehidupan yaitu umur panjang dan hidup sehat, pengetahuan, serta kehidupan yang layak. Angka harapan hidup digunakan sebagai ukuran untuk menilai dimensi umur panjang dan hidup sehat. Rata-rata lama sekolah dan harapan lama sekolah digunakan untuk menilai dimensi pengetahuan. Pengeluaran per kapita digunakan untuk menilai dimensi hidup layak (Setiawan & Hakim, 2013).

Penelitian yang dilakukan oleh Ariwuni & Kartika (2019) tentang pengaruh PDRB dan pengeluaran pemerintah terhadap IPM dan tingkat kemiskinan di Kabupaten/Kota di Provinsi Bali. Hasil penelitian tersebut menunjukkan bahwa PDRB berpengaruh positif dan signifikan terhadap IPM. Pengaruh jumlah penduduk, pengangguran, dan kemiskinan terhadap IPM di Kabupaten Belu yang dilakukan oleh Kiha et al. (2021) diperoleh hasil bahwa setiap variabel independen memiliki korelasi yang kuat terhadap IPM di Kabupaten Belu. Penelitian lainnya dilakukan oleh Chalid & Yusuf (2014) mengenai pengaruh tingkat kemiskinan, tingkat pengangguran, upah minimum kabupaten/kota dan laju pertumbuhan ekonomi terhadap indeks pembangunan manusia di Provinsi Riau dengan hasil penelitiannya diperoleh upah minimum kabupaten/kota berpengaruh positif terhadap IPM sedangkan penduduk miskin berpengaruh negatif terhadap IPM. Hal ini menunjukkan semakin tinggi persentase penduduk miskin menyebabkan angka IPM semakin rendah sehingga menghambat pembangunan manusia.

Indeks pembangunan manusia nasional menunjukkan adanya kenaikan nilai IPM dari tahun 2020 sampai 2022. Peningkatan IPM nasional dipengaruhi oleh kondisi IPM tiap provinsi pada masing-masing pulau di Indonesia. Menurut Badan Pusat Statistik (2022), Pulau Jawa memiliki IPM tertinggi pada Provinsi DKI Jakarta tahun 2022 sebesar 81,65. Pulau Jawa terdiri atas 6 provinsi, namun hanya DKI Jakarta dan DI Yogyakarta yang memiliki range IPM diatas 80, sedangkan untuk Jawa Barat, Jawa Tengah, Jawa Timur dan Banten memiliki range IPM diatas 70. Hal ini menarik karena hanya ada 2 provinsi di Pulau Jawa yang memiliki IPM tergolong sangat tinggi. IPM tertinggi terletak pada Kota Salatiga sebesar 84,35 dan IPM terendah terdapat pada Kabupaten Sampang sebesar 63,39. Nilai IPM tersebut memiliki selisih yang cukup signifikan sebesar 20,96. Berdasarkan selisih nilai tersebut dapat dikatakan belum adanya pemerataan pembangunan pada seluruh wilayah. Selain itu, kondisi kesehatan dan pendidikan penduduk relatif rendah sehingga memberikan pengaruh yang signifikan dalam menentukan tingkat pembangunan manusia di wilayah tersebut. Hal ini menunjukkan ketidakmerataan kesehatan dan pendidikan disebabkan faktor geografis yang berpengaruh terhadap IPM di Pulau Jawa.

Pulau Jawa terdiri atas 86 kabupaten dan 33 kota yang memiliki karakteristik dan geografis yang beragam pada setiap wilayah. Pengaruh karakteristik dan geografis memperhitungkan adanya efek heterogenitas spasial. Salah satu metode dalam menganalisis keragaman spasial adalah *Geographically Weighted Artificial Neural Network* (GWANN). GWANN adalah variasi dari *Artificial Neural Network* (ANN) yang menggabungkan ANN dan pembobot spasial untuk mendeteksi hubungan nonlinier yang kompleks (Hagenauer & Helbich, 2022). Penelitian sebelumnya dilakukan oleh Hagenauer & Helbich (2022) dalam memprediksi harga rumah di Austria. Hasil penelitian tersebut diperoleh bahwa GWANN memberikan hasil kinerja yang lebih baik daripada GWR pada data yang memiliki varians spasial tinggi.

Metode lain yang digunakan untuk menangani heterogenitas spasial adalah *Geographically Weighted Regression* (GWR). Menurut Fotheringham et al. (2003) GWR merupakan pengembangan model regresi linier yang ditambahkan fungsi

pembobot untuk mengatasi keragaman spasial. Penambahan fungsi pembobot mengakibatkan peningkatan korelasi antar variabel pada tiap lokasi. Korelasi yang semakin tinggi diindikasikan terdapat multikolinieritas. Hal ini mengakibatkan penduga parameter model GWR mempunyai variansi besar sehingga tidak dapat menggunakan model GWR. Metode untuk mengatasi multikolinieritas adalah *Geographically Weighted Ridge Regression* (GWRR).

Model GWRR merupakan pengembangan dari model GWR yang menambahkan koefisien bias ridge optimum dalam proses pendugaan parameternya (Wheeler & Páez, 2009). Nilai *ridge* optimum diperoleh dari *Generalized Cross Validation* (GCV) yang mencapai nilai minimum. Penelitian sebelumnya dilakukan oleh Hastutik (2018) tentang model *Geographically Weighted Ridge Regression* pada data indeks pembangunan manusia di Provinsi Papua. Hasil penelitian tersebut diperoleh metode GWRR mampu mengatasi masalah multikolinieritas. Penelitian lain juga dilakukan oleh Qur'ani et al. (2023) tentang estimasi parameter model *Geographically Weighted Ridge Regression* pada *stunting* di Indonesia. Hasil penelitian tersebut diperoleh model GWRR mampu memberikan performanya untuk mengatasi masalah multikolinieritas lokal.

Penelitian ini dengan memperhitungkan efek heterogenitas spasial dalam data. Metode yang digunakan *Geographically Weighted Regression*, *Geographically Weighted Ridge Regression*, dan *Geographically Weighted Artificial Neural Network*. Pemilihan model terbaik didasarkan pada indikator RMSE dan R^2 .

1.2 Rumusan Masalah

Berdasarkan uraian latar belakang, maka diperoleh rumusan masalah sebagai berikut:

1. Bagaimana faktor yang mempengaruhi indeks pembangunan manusia di Pulau Jawa berdasarkan pemilihan model terbaik?
2. Bagaimana hasil perbandingan metode *Geographically Weighted Regression*, *Geographically Weighted Ridge Regression*, dan *Geographically Weighted Artificial Neural Network* pada model indeks pembangunan manusia di Pulau Jawa?

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah, tujuan yang ingin dicapai dalam penelitian ini sebagai berikut:

1. Menganalisis faktor-faktor yang mempengaruhi indeks pembangunan manusia di Pulau Jawa berdasarkan pemilihan model terbaik.
2. Membandingkan hasil dari metode *Geographically Weighted Regression*, *Geographically Weighted Ridge Regression* dan *Geographically Weighted Artificial Neural Network* pada indeks pembangunan manusia di Pulau Jawa.

1.4 Manfaat Penelitian

Penelitian ini memiliki manfaat untuk meningkatkan wawasan bidang statistika terkait penerapan model *Geographically Weighted Regression*, *Geographically Weighted Ridge Regression* dan *Geographically Weighted Artificial Neural Network* pada indeks pembangunan manusia di Pulau Jawa. Manfaat lainnya adalah memberikan informasi kepada pemerintah mengenai permasalahan IPM di Pulau Jawa. Gambaran dan keadaan IPM dapat diketahui melalui nilai IPM itu sendiri serta faktor-faktor yang mempengaruhi IPM sehingga mencapai pemerataan pembangunan manusia di Pulau Jawa.

BAB 2. TINJAUAN TEORI

2.1 Indeks Pembangunan Manusia

Menurut Badan Pusat Statistik (2022) Indeks Pembangunan Manusia adalah ukuran perbandingan tiga bidang kehidupan yaitu usia hidup (*longevity*), pengetahuan (*knowledge*), dan standar hidup layak (*decent living*). Komponen IPM terdiri dari angka harapan hidup, harapan lama sekolah, rata-rata lama sekolah, dan pengeluaran per kapita. Kategori IPM terdiri dari rendah (63,4 – 71,4), sedang (71,5 – 77,9), tinggi (77,9 – 87,7). Rumusan untuk perhitungan IPM yaitu:

$$IPM = \left(\sqrt[3]{I_{kesehatan} + I_{pendidikan} + I_{pengeluaran}} \times 100 \right) \quad (2.1)$$

Faktor yang mempengaruhi indeks pembangunan manusia adalah faktor ekonomi dan kependudukan. Faktor ekonomi terdiri dari produk nasional domestik bruto dan upah minimum kabupaten/kota, penduduk miskin, dan indeks kedalaman kemiskinan (Ariwuni & Kartika, 2019). Berikut untuk setiap indeks dalam faktor ekonomi:

- a. PDRB merupakan jumlah nilai bruto dari perekonomian suatu wilayah. Produk nasional domestik bruto digunakan untuk mengukur pertumbuhan ekonomi dan tidak dipengaruhi oleh fluktuasi harga.
- b. Upah minimum kabupaten/kota merupakan penerimaan bulanan terendah yang diterima karyawan yang didasarkan atas perundang-undangan. Upah minimum ditetapkan berdasarkan kebutuhan hidup layak dan inflasi.
- c. Penduduk miskin adalah penduduk yang tidak mampu mendapatkan sumber daya untuk memenuhi kebutuhan dasar. Penduduk ini hidup di bawah tingkat pendapatan riil minimum.
- d. Indeks kedalaman kemiskinan adalah ukuran rata-rata kesenjangan pengeluaran penduduk miskin. Nilai indeks kedalaman kemiskinan yang semakin tinggi menyebabkan rata-rata pengeluaran penduduk semakin jauh dari garis kemiskinan.

Menurut Prayogo & Hasmarini (2022) faktor kependudukan terdiri dari kepadatan penduduk, laju pertumbuhan penduduk, jumlah penduduk, dan jumlah rumah tangga. Berikut penjelasan masing-masing faktor:

- e. Kepadatan penduduk merupakan kondisi pertumbuhan penduduk yang memberikan dampak terhadap kualitas hidup.
- f. Jumlah penduduk merupakan jumlah orang yang berdomisili di suatu wilayah. Laju pertumbuhan penduduk memiliki hubungan yang linier terhadap jumlah penduduk. Jumlah penduduk yang semakin meningkat harus diimbangi dengan peningkatan kesejahteraan.
- g. Laju pertumbuhan penduduk merupakan angka bertambahnya populasi penduduk yang diakibatkan banyaknya jumlah kelahiran. Pertumbuhan penduduk menyebabkan tingginya produksi makanan yang dapat mempengaruhi sumber daya manusia.
- h. Jumlah rumah tangga merupakan sejumlah orang yang mendiami pada suatu bangunan.

2.2 Multikolinieritas

Menurut James et al (2013) multikolinieritas adalah pengujian yang dilakukan untuk mengetahui kondisi ada atau tidaknya korelasi atau hubungan linier antar variabel independen pada model regresi. Uji multikolinieritas dapat diidentifikasi dengan melihat nilai *Variance Inflation Factors* (VIF). Nilai VIF lebih dari 10 menunjukkan adanya multikolinieritas sehingga diestimasi bahwa koefisien regresi buruk (Shrestha, 2020). Formula yang digunakan adalah:

$$VIF_j = \frac{1}{1-R_j^2} \quad (2.2)$$

R_j^2 : koefisien determinasi antar variabel independen dengan rumus

$$R_j^2 = 1 - \frac{JKG}{JKT}$$

JKG : Jumlah Kuadrat Galat

JKT : Jumlah Kuadrat Total

2.3 Uji Heterogenitas

Uji heterogenitas spasial digunakan untuk mengidentifikasi keragaman antar lokasi sehingga dihasilkan parameter regresi yang berbeda-beda pada setiap lokasi. Uji *Breusch-Pagan* (*BP-test*) merupakan salah satu cara dalam melihat adanya

heterogenitas spasial dalam model regresi (Andriani, 2017). Berikut ini adalah hipotesis pengujian heterogenitas spasial:

$$H_0: \sigma_1^2 = \sigma_2^2 = \dots = \sigma_n^2 = \sigma^2 \text{ (tidak terdapat heterogenitas spasial)}$$

$$H_1: \{\exists i, \sigma_i^2 \neq \sigma^2\}, i = 1, 2, \dots, n \text{ (terdapat heterogenitas spasial)}$$

Statistik uji yang digunakan dalam efek spasial adalah:

$$BP = \left(\frac{1}{2}\right) \mathbf{f}^T \mathbf{Z} (\mathbf{Z}^T \mathbf{Z})^{-1} \mathbf{Z}^T \mathbf{f} \quad (2.3)$$

dengan elemen vektor \mathbf{f}

$$f_i = \frac{e_i^2}{\sigma^2} - 1$$

\mathbf{f} : vektor (f_1, f_2, \dots, f_n) berukuran $n \times 1$

σ^2 : varians dari e_i dengan $\sigma^2 = \sum_{i=1}^n e_i^2$

e_i^2 : kuadrat sisa pengamatan ke- i

\mathbf{Z} : matriks berukuran $n \times (p + 1)$ yang berisi vektor normal

Pengambilan keputusan pada *BP test* tolak H_0 jika $BP \geq \chi_{(a,k)}^2$ atau $p\text{-value} \leq a$ terdapat heterogenitas spasial.

2.4 Pembobot Spasial

Pembobot spasial digunakan untuk menganalisis model pada data lokasi pengamatan dengan mempertimbangkan pengaruh spasial. Pembobot memiliki peran penting karena mampu menentukan letak data pengamatan satu dengan data pengamatan yang lain (Caraka & Yasin 2017). Fungsi kernel yang digunakan sebagai pembobot spasial yaitu *Adaptive Gaussian Kernel* dan *Adaptive Bisquare Kernel* (Fan et al., 2018). *Adaptive Kernel* menghasilkan *bandwidth* yang berbeda pada setiap lokasi pengamatan. Jenis fungsi pembobot yang dapat digunakan yaitu:

Tabel 2.1 Pembobotan Spasial

	Kernel Gaussian	Kernel Bisquare	
<i>Adaptive</i>	$w_{ij} = \exp\left[-\frac{1}{2} \left(\frac{d_{ij}}{b_i}\right)^2\right]$	$w_{ij} = \begin{cases} \left[1 - \left(\frac{d_{ij}}{b_i}\right)^2\right]^2 & \text{jika } d_{ij} \leq b_i \\ 0 & \text{jika } d_{ij} > b_i \end{cases}$	

Persamaan jarak *Euclid* yaitu:

$$d_{ij} = \sqrt{(u_i - u_j)^2 + (v_i - v_j)^2} \quad (2.4)$$

d_{ij} : jarak dari lokasi i ke j

u_i : *longitude* lokasi ke- i

v_i : *latitude* lokasi ke- i

Bandwidth digunakan untuk mengatur besar kecilnya variansi dan bias. Cara untuk menentukan *bandwidth* yaitu *Cross Validation* (CV) (Fotheringham et al., 2003). Nilai *bandwidth* optimum diperoleh dari CV yang minimum. Bentuk persamaan CV adalah:

$$CV = \sum_{i=1}^n (y_i - \hat{y}_{\neq i}(b))^2 \quad (2.5)$$

$\hat{y}_{\neq i}(b)$: nilai penaksir y_i di lokasi u_i, v_i dihilangkan dari proses estimasi

n : banyaknya pengamatan

y_i : pengamatan ke- i

Pembobot digunakan untuk memberikan bobot berbeda terhadap titik lokasi pengamatan berdasarkan jarak geografis. Pembobot optimum diperoleh dari AIC (*Akaike Information Criterion*) minimum (Brewer et al., 2016). Rumus AIC yaitu:

$$AIC = 2n \log(\hat{\sigma}) + n \log(2\pi) + n + tr(S) \quad (2.6)$$

$\hat{\sigma}$: estimasi residual simpangan baku

$tr(S)$: *trace matrix* S

2.5 Geographically Weighted Regression

Menurut Fotheringham et al., (2003) *Geographically Weighted Regression* merupakan pengembangan dari model regresi yang ditambahkan dengan pembobot spasial. Model GWR dihasilkan parameter lokal pada setiap lokasi pengamatan. Persamaan model GWR yaitu:

$$y_i = \beta_0(u_i, v_i) + \sum_{k=1}^p \beta_k(u_i, v_i) x_{ik} + \varepsilon_i \quad (2.7)$$

$\beta_0(u_i, v_i)$: parameter model GWR lokasi ke- i

x_{ik} : nilai pengamatan variabel independen ke- k pada lokasi ke- i

Penduga koefisien parameter model GWR diperoleh dengan metode *Weighted Least Square* (WLS) dari persamaan (2.6) yang diturunkan terhadap $\beta^T(u_i, v_i)$. Penduga parameter model GWR untuk setiap lokasi adalah:

$$\beta(u_i, v_i) = (\mathbf{X}^T \mathbf{W}(u_i, v_i) \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W}(u_i, v_i) \mathbf{y} \quad (2.8)$$

\mathbf{y} : vektor variabel dependen berorde $(n \times 1)$

\mathbf{X} : matriks variabel independen $(n \times (p + 1))$

$\mathbf{W}(u_i, v_i)$: matriks pembobot untuk setiap lokasi

2.5.1 Pengujian Signifikansi Parameter Model

Pengujian signifikansi parameter digunakan untuk mendeteksi adanya pengaruh signifikan variabel independen terhadap variabel dependen (Caraka & Yasin, 2017). Hipotesis pengujian parameter model sebagai berikut:

$H_0: \beta_k(u_i, v_i) = 0$ (parameter signifikan)

$H_1: \beta_k(u_i, v_i) \neq 0$ (parameter tidak signifikan)

Uji statistik:

$$t_{hitung} = \frac{\hat{\beta}_k(u_i, v_i)}{SE[\hat{\beta}_k(u_i, v_i)]} \quad (2.9)$$

Daerah penolakan H_0 terjadi untuk $\alpha = 5\%$, $|t_{hitung}| > t_{(\frac{\alpha}{2}, df)}$.

2.6 Regresi Ridge

Model regresi *ridge* digunakan untuk mengatasi multikolinieritas. Pendugaan parameter model regresi *ridge* dilakukan dengan menambahkan fungsi kendala pada kuadrat terkecil dengan meminimumkan jumlah kuadrat galat (Ishwaran & Rao, 2014). Penduga koefisien regresi *ridge* dapat ditulis dengan persamaan berikut:

$$\hat{\beta}_R = \arg \min \left\{ \sum_{i=1}^n (y_i - \beta_0 - \sum_{k=1}^p x_{ij} \beta_k)^2 + \lambda \sum_{k=1}^p \beta_k^2 \right\} \quad (2.10)$$

dengan syarat pembatas $\sum_{k=1}^p \beta_k^2 \leq \rho$, dugaan parameter regresi *ridge* dengan menurunkan jumlah kuadrat galat terhadap $\hat{\beta}$, maka diperoleh:

$$\hat{\beta}_R = (\mathbf{X}^T \mathbf{X} + \lambda \mathbf{I})^{-1} \mathbf{X}^T \mathbf{Y} \quad (2.11)$$

\mathbf{Y} : vektor variabel dependen berorde $(n \times 1)$

\mathbf{X} : matriks variabel independen $(n \times (p + 1))$

Regresi *ridge* dilakukan transformasi *centering* dan *scaling* pada variabel dependen dan independen untuk menuju kedalam proses GWRR. Transformasi bertujuan untuk menstandarisasi variabel yang kemudian dapat memperkecil variansi (Veronica et al., 2016). Rumus transformasi yaitu:

$$Y_i^* = \frac{Y_i - \bar{Y}}{\sqrt{n-1}S_y}, X_{ik}^* = \frac{X_{ik} - \bar{X}}{\sqrt{n-1}S_{x_{ik}}} \quad (2.12)$$

Y_i^* : hasil transformasi variabel dependen

X_{ik}^* : hasil transformasi variabel independen

$S_{x_{ik}}$: standar deviasi untuk variabel dependen

Nilai λ yang optimal diperoleh dengan menggunakan *Generalized Cross Validation* (GCV). Penduga koefisien optimum didapatkan dari nilai λ yang menghasilkan nilai GCV minimum. Nilai GCV dapat dirumuskan yaitu:

$$GCV = \frac{\sum_{i=1}^n e_{i,\lambda}^2}{\{n - [1 + \text{tr}(\mathbf{H}_\lambda)]\}^2} \quad (2.13)$$

$e_{i,\lambda}^2$: sisaan kuadrat ke- i untuk nilai λ tertentu

2.7 Geographically Weighted Ridge Regression

Geographically Weighted Ridge Regression merupakan salah satu metode yang digunakan pada data spasial dalam mengatasi masalah multikolinieritas (Wheeler & Páez, 2009). GWRR pengembangan dari metode regresi *ridge*. Perbedaan antara regresi *ridge* dengan GWRR terletak pada pembobot yang ditambahkan pada setiap lokasi pengamatan. Model GWRR secara umum yaitu:

$$y_i = \beta_0(u_i, v_i) + \sum_{k=1}^p x_{ik} \beta_k(u_i, v_i) x_{ik} + \lambda \sum_{k=1}^p \beta_k^2(u_i, v_i) \quad (2.14)$$

Pendugaan parameter model GWRR diperoleh dengan menurunkan jumlah kuadrat galat terhadap $\hat{\beta}(u_i, v_i)$. Penduga parameter model GWRR untuk setiap lokasi yaitu:

$$\hat{\beta}(u_i, v_i) = (\mathbf{X}^{*T} \mathbf{W}(u_i, v_i) \mathbf{X}^* + \lambda \mathbf{I})^{-1} \mathbf{X}^{*T} \mathbf{W}(u_i, v_i) \mathbf{Y}^* \quad (2.15)$$

$\mathbf{W}(u_i, v_i)$: matriks pembobot spasial berdimensi $(n \times n)$

\mathbf{I} : matriks identitas berorde $(p \times p)$

Pembentukan \mathbf{X}^* ke \mathbf{X} dapat dilakukan berdasarkan nilai parameter penduga $\hat{\beta}(u_i, v_i, \lambda)$. Pembentukan \mathbf{X}^* ke \mathbf{X} yaitu :

$$\beta_i = \left(\frac{S_y}{S_{xik}} \right) \beta^*, k = 1, 2, \dots, p \quad (2.16)$$

S_y : standar deviasi variabel dependen

S_{xik} : standar deviasi variabel independen

2.8 Artificial Neural Network

Artificial Neural Network atau jaringan syaraf tiruan adalah sistem kecerdasan buatan dimana strukturnya mirip dengan jaringan syaraf biologis (Lesnussa et al., 2018). Komponen *Artificial Neural Network* yaitu:

1. *Input layer* merupakan lapisan yang memiliki beberapa neuron untuk menerima sinyal dari luar yang kemudian diteruskan ke neuron lainnya.
2. *Hidden layer* merupakan lapisan yang terdiri dari unit-unit tersembunyi sebagai tempat pemrosesan data yang terletak antara *input* dan *output layer*.
3. *Output layer* merupakan lapisan yang terdiri dari unit-unit *output* sebagai *output* hasil keluaran proses.

Menurut Zhang & Zhang (2018) arsitektur *Artificial Neural Network* diklasifikasikan berdasarkan jumlah *hidden layer* sebagai berikut:

1. *Single layer* merupakan jaringan yang terdiri dari satu *layer input* dan satu *layer output*.
2. *Multilayer* merupakan jaringan yang memiliki 3 *layer* yaitu *input layer*, *hidden layer* dan *output layer*.

2.9 Geographically Weighted Artificial Neural Network

Geographically Weighted Artificially Neural Network merupakan variasi dari *Artificial Neural Network* (ANN) yang menggunakan bobot koneksi untuk mengukur pembobot secara geografis dari ANN diestimasi dengan memanfaatkan fungsi *error geographically weighted*, lalu bobot dapat diinterpretasikan sebagai model GWR. Fungsi *error geographically weighted* pada regresi didefinisikan yaitu:

$$E = \frac{1}{2} \sum_{i=1}^n v_i (t_i - o_i)^2 \quad (2.17)$$

Persamaan untuk menghitung sinyal *error* dari *backpropagation* dirumuskan yaitu:

$$\delta_b = \begin{cases} \phi'(net_j)v_j(o_j - t_j) & \text{jika } j \text{ adalah output neuron} \\ \phi'(net_j)\sum_k \delta_k w_{jk} & \text{sebaliknya} \end{cases} \quad (2.18)$$

δ_k : sinyal error untuk neuron b

(Hagenauer & Helbich, 2022).

2.10 Pemilihan Model Terbaik

Model terbaik merupakan model yang dapat mengetahui interaksi antara variabel independen menggunakan variabel dependen dari kriteria tertentu. Kriteria dalam memilih model terbaik adalah (R^2) dan RMSE. Berikut ini penjelasan kriteria yang digunakan:

2.10.1 Koefisien Determinasi

Menurut Bawono (2018) R^2 menunjukkan varians pada variabel dependen yang diprediksi pada variabel independen. Koefisien determinasi bernilai antara 0 dan 1. Nilai koefisien determinasi yang baik dalam menjalankan suatu model adalah mendekati 1. R^2 dapat dituliskan yaitu:

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2.19)$$

y_i : nilai observasi

\hat{y}_i : nilai prediksi ke- i

2.10.2 Root Mean Squared Error

RMSE adalah hasil akar kuadrat *Mean Square Error*. RMSE merupakan suatu kriteria pengukuran untuk mencari perbedaan antara nilai-nilai prediksi pada model. Nilai RMSE yang semakin kecil menunjukkan tingkat keakuratan yang tinggi dalam pengukurannya (Hodson, 2022). Formula RMSE dirumuskan sebagai:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (2.20)$$

Y_i : data awal

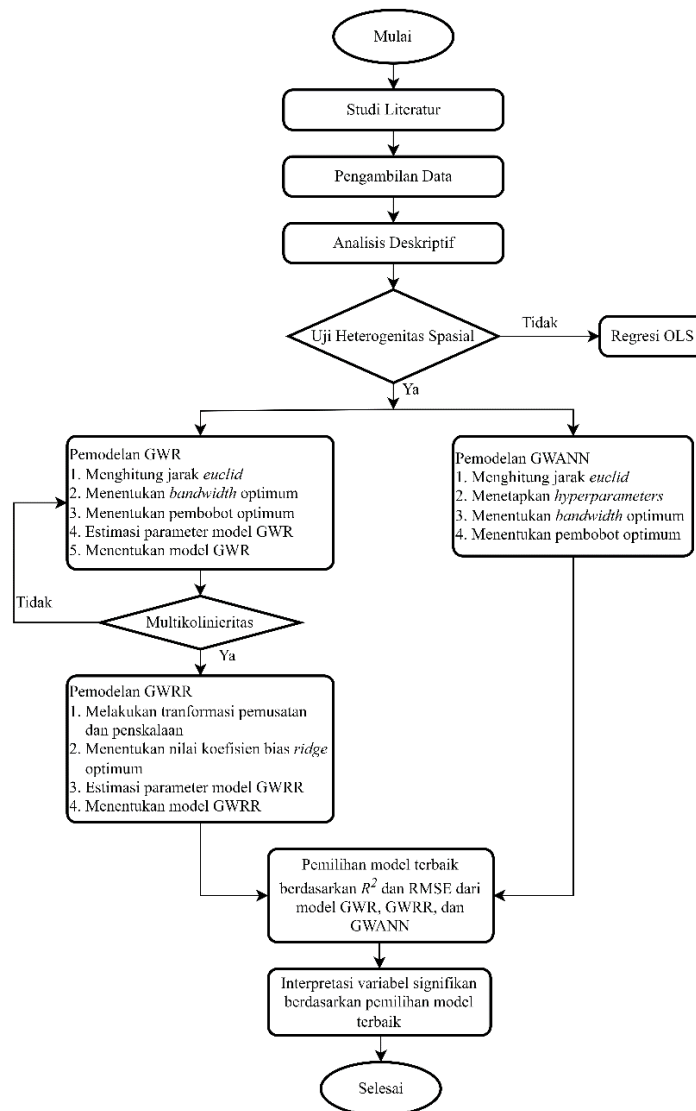
\hat{Y}_i : data akhir (hasil estimasi)

BAB 3. METODE PENELITIAN

3.1 Populasi dan Sampel/Subyek Penelitian

Populasi dan sampel pada penelitian ini yaitu Indeks Pembangunan Manusia (IPM) di Jawa tahun 2022. Data IPM diperoleh melalui laman *website* Badan Pusat Statistik (BPS) dari Provinsi Jawa Barat, Jawa Tengah, Jawa Timur, DKI Jakarta, DI Yogyakarta, dan Banten. Data koordinat *longitude* dan *latitude* diperoleh dari *google maps* pada masing-masing lokasi pengamatan.

3.2 Prosedur Penelitian



Gambar 3.1 Skema Penelitian

Adapun langkah-langkah yang dilakukan dalam penelitian ini sebagai berikut:

1. Melakukan study literatur dengan mencari sumber referensi dari jurnal, buku dan skripsi yang terkait dengan GWR, GWRR, dan GWANN.
2. Mengambil data dari BPS Provinsi Jawa Barat, Jawa Tengah, Jawa Timur, DKI Jakarta, DI Yogyakarta dan Banten berupa excel untuk kemudian diolah menggunakan *software* R-Studio.
3. Melakukan analisis deskriptif untuk mendeskripsikan data indeks pembangunan manusia berdasarkan variabel dependen dan variabel independen sehingga diperoleh nilai rata-rata, nilai maksimum, nilai minimum dan varians.
4. Melakukan uji heterogenitas dengan menggunakan uji *Breusch-Pagan*.
5. Melakukan pemodelan GWR dengan langkah-langkah sebagai berikut:
 - a. Melakukan perhitungan jarak *Euclid*.
 - b. Memilih *bandwidth* optimum.
 - c. Memilih pembobot optimum.
 - d. Melakukan penduga parameter model GWR.
 - e. Menentukan model GWR berdasarkan analisis hasil penduga parameter.
6. Melakukan pendeteksian multikolinieritas antar variabel independen dengan menggunakan nilai VIF.
7. Melakukan pemodelan GWRR dengan langkah-langkah sebagai berikut:
 - a. Melakukan tranformasi pemusatan dan penskalaan.
 - b. Menentukan nilai parameter *ridge* optimum.
 - c. Melakukan estimasi parameter model GWRR.
 - d. Menentukan model GWRR.
8. Melakukan pemodelan GWANN dengan langkah-langkah sebagai berikut:
 - a. Menghitung jarak *euclidean* berdasarkan lokasi geografis.
 - b. Penetapan *hyperparameters*.
 - c. Melakukan pelatihan model untuk mendapatkan nilai *bandwidth* yang optimum.
 - d. Menentukan pembobot optimum.
9. Membandingkan model GWR, GWRR, dan GWANN dengan R^2 dan RMSE.

10. Interpretasi variabel signifikan berdasarkan pemilihan model terbaik.
11. Menarik kesimpulan.

3.3 Pengumpulan Data Penelitian

Data penelitian yang digunakan merupakan data sekunder dari Badan Pusat Statistik (BPS) Provinsi Jawa Barat, Jawa Tengah, Jawa Timur, DKI Jakarta, DI Yogyakarta dan Banten pada tahun 2022. Unit pengamatan yang digunakan sebanyak 119 daerah yang terdiri atas 86 kabupaten dan 33 kota.

Penelitian ini menggunakan dua jenis variabel yaitu variabel dependen dan variabel independen. Variabel dependen adalah variabel yang dipengaruhi oleh variabel independen. Variabel dependen (Y) pada penelitian ini adalah indeks pembangunan manusia (IPM) tahun 2022. Variabel independen (X) adalah variabel yang dapat memberikan pengaruh terhadap variabel dependen. Pada penelitian ini terdapat 8 variabel independen. Berikut variabel yang digunakan pada penelitian ini:

Tabel 3.1 Variabel Penelitian

Variabel	Keterangan	Skala
Y	Indeks Pembangunan Manusia (IPM)	Rasio
X_1	Produk Nasional Domestik Bruto (PDRB)	Rasio
X_2	Penduduk Miskin	Rasio
X_3	Kepadatan Penduduk	Rasio
X_4	Laju Pertumbuhan Penduduk	Rasio
X_5	Upah Minimum Kabupaten/Kota	Rasio
X_6	Jumlah Penduduk	Rasio
X_7	Indeks Kedalaman Kemiskinan	Rasio
X_8	Jumlah Rumah Tangga	Rasio

Aspek geografis pada penelitian ini diimplementasikan menggunakan nama *latitude* dan *longitude*. *Latitude* adalah garis lintang yang membentang secara horizontal. *Longitude* adalah garis bujur yang membentang secara vertikal. Struktur data yang digunakan pada penelitian ini ditampilkan dalam tabel berikut:

Tabel 3.2 Struktur Data Penelitian

Lokasi	Y	X_1	...	X_8	lon	lat
Bogor	Y_1	$X_{1,1}$...	$X_{8,1}$	u_1	v_1
Sukabumi	Y_2	$X_{1,2}$...	$X_{8,2}$	u_2	v_2
⋮	⋮	⋮	⋮	⋮	⋮	⋮
Kota						
Tangerang Selatan	Y_{119}	$X_{1,119}$...	$X_{8,119}$	u_{119}	v_{119}

BAB 4. HASIL DAN PEMBAHASAN

4.1 Eksplorasi Data Penelitian

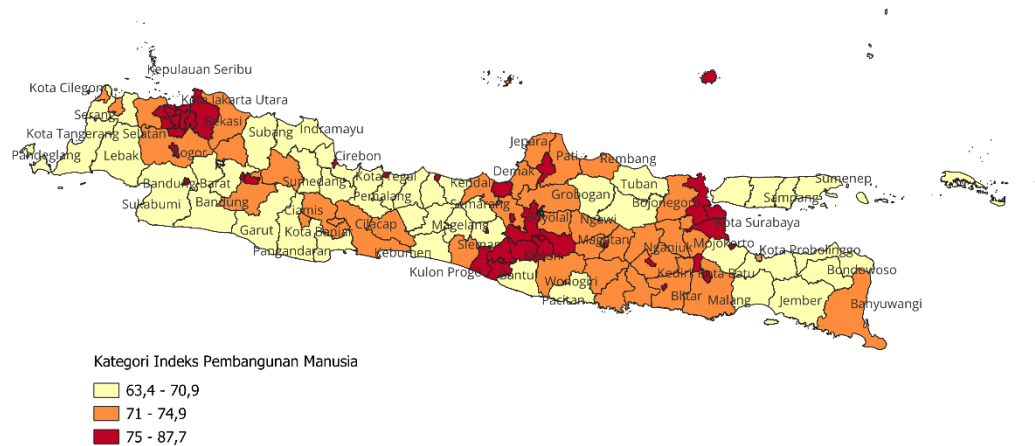
Eksplorasi data dilakukan untuk memperoleh informasi terkait variabel yang digunakan dalam penelitian. Data yang dianalisis dalam penelitian adalah data Indeks Pembangunan Manusia (IPM) di Pulau Jawa tahun 2022. Eksplorasi data mampu menunjukkan statistika deskriptif terhadap masing-masing variabel. Statistika deskriptif dari data terdiri atas nilai minimum, maksimum, variansi dan rata-rata. Statistika deskriptif untuk data IPM di Pulau Jawa dapat ditampilkan pada Tabel 4.1.

Tabel 4.1 Statistika deskriptif

Variabel	Minimum	Maksimum	Variansi	Rata-rata
Y	63,39	87,69	28,23	73,71
X_1	1803	482088	8281078426	5.6358
X_2	2,50	21,61	14,52	9,59
X_3	383	22708	19886094	3318,40
X_4	0,07	2,36	0,21	0,96
X_5	1819835	4816921	937861789835	2675760
X_6	28925	5566838	747151675231	1300005
X_7	0,32	3,72	0,45	1,42
X_8	6683	1381734	50026392976	343907

Berdasarkan Tabel 4.1, indeks pembangunan manusia (Y) di Pulau Jawa tahun 2022 memiliki rata-rata sebesar 73,71. Nilai IPM tersebut tergolong dalam kategori sedang. Wilayah dengan nilai IPM tertinggi terletak pada Kota Yogyakarta sebesar 87,69, sedangkan Kabupaten Sampang sebesar 63,39 merupakan wilayah dengan nilai IPM terendah. Variansi pada X_1 , X_3 , X_5 , X_6 , X_8 memiliki nilai yang sangat tinggi. Hal ini menunjukkan data tersebar jauh dari rata-rata dan memiliki variasi data yang besar. Nilai variansi yang tinggi disebabkan adanya *outlier* atau nilai ekstrem dalam data sehingga penyebaran datanya lebih besar daripada yang sebenarnya. *Outlier* ini menyebabkan distribusi data menjadi *skewed* (condong).

Variabel X_1 , X_3 , X_5 , X_6 , X_8 menunjukkan *positive skewness* yang artinya kemiringan dari grafik dari kiri ke kanan atau ekor dari grafik condong ke kanan dan sebaran datanya berkumpul di nilai yang maksimum.



Gambar 4.1 Pemetaan Indeks Pembangunan Manusia di Pulau Jawa

Pemetaan kasus IPM di Pulau Jawa dapat dilihat pada Gambar 4.1. Pemetaan ini dilakukan menggunakan aplikasi QGIS. Nilai IPM dikelompokkan menjadi tiga kategori yaitu rendah, sedang, dan tinggi. IPM tinggi di Pulau Jawa ditandai dengan daerah yang memiliki warna lebih pekat. Kategori IPM tinggi terdapat pada Kota Surabaya, Kota Bandung, Kota Semarang lainnya. IPM rendah ditandai dengan daerah yang memiliki warna paling terang. Tuban, Blora, Tegal dan lainnya tergolong dalam kategori IPM rendah. IPM sedang ditandai dengan daerah yang memiliki warna orange muda. Kategori IPM sedang terdapat pada Karawang, Demak, Kediri dan lainnya. Penyebaran nilai IPM yang beragam disebabkan oleh perbedaan jumlah penduduk, kepadatan penduduk, laju pertumbuhan penduduk, penduduk miskin serta indeks kedalaman kemiskinan yang berbeda pada setiap wilayah. PDRB dan upah minimum kabupaten/kota menunjang ekonomi pada setiap wilayah juga dapat menyebabkan keberagaman nilai IPM.

PDRB merupakan nilai pasar semua barang dan jasa yang diproduksi dalam kurun waktu tertentu. Nilai PDRB beragam pada setiap wilayah. Hal ini disebabkan

tingginya arus jual beli, fasilitas perdagangan serta kondisi sosial, dan kesejahteraan masyarakat yang berbeda-beda pada setiap wilayah. Hubungan PDRB terhadap IPM berbanding lurus. Nilai PDRB pada suatu wilayah tinggi maka pembangunan manusia di suatu wilayah juga tinggi. PDRB tertinggi berada pada Kota Jakarta Pusat sebesar 482.088. Kota Cirebon memiliki PDRB terendah sebesar 1803.

Upah minimum kabupaten/kota (UMK) merupakan penerimaan bulanan terendah yang ditetapkan berdasarkan perjanjian kerja antara pengusaha dan karyawan. Hubungan UMK terhadap IPM berlaku linier, jika UMK semakin tinggi menyebabkan tingginya nilai IPM. UMK tertinggi terletak pada Kota Bekasi sebesar 4.816.921 sedangkan paling rendah sebesar 1.819.835 pada Kota Banjarnegara.

Jumlah penduduk merupakan total penduduk yang menempati suatu wilayah. Rata-rata jumlah penduduk di Pulau Jawa sebesar 1.300.005 jiwa. Penduduk dengan jumlah tertinggi terletak pada Kota Bogor sebesar 5.566.838 jiwa. Kepulauan Seribu memiliki jumlah penduduk terendah sebesar 28.925 jiwa.

Laju pertumbuhan penduduk merupakan laju bertambahnya angka populasi penduduk pada suatu wilayah. Laju pertumbuhan penduduk memiliki hubungan linier dengan kepadatan penduduk. Laju pertumbuhan penduduk tertinggi terletak pada Kepulauan Seribu sedangkan paling rendah terletak pada Kota Magelang dan Kota Surakarta.

Indeks kedalaman kemiskinan merupakan rata-rata dari pengeluaran penduduk miskin. Hubungan indeks kedalaman kemiskinan berbanding terbalik terhadap IPM. Apabila indeks kedalaman kemiskinan tinggi pada suatu wilayah maka nilai IPM di wilayah tersebut semakin rendah. Wilayah yang memiliki indeks kedalaman kemiskinan tertinggi berada pada Kota Kediri sebesar 3,72. Kota Tangerang Selatan memiliki indeks kedalaman kemiskinan terendah sebesar 0,32.

Kepadatan penduduk merupakan kondisi pertumbuhan penduduk pada suatu wilayah. Kepadatan penduduk memberikan efek terhadap kualitas hidup. Kota Jakarta Pusat memiliki kepadatan penduduk tertinggi di Pulau Jawa sebesar 22708 jiwa/km. Kepadatan penduduk terendah berada pada Kabupaten Pangandaran sebesar 383 jiwa/km.

Penduduk miskin merupakan penduduk yang tidak mampu memenuhi kebutuhan hidup sehari-hari. Jumlah penduduk miskin yang tinggi mengindikasikan sumber daya manusia di suatu daerah tersebut rendah. Hal ini menyebabkan rendahnya nilai IPM. Persentase penduduk miskin tertinggi berada pada Kabupaten Sampang sebesar 21,61. Kota Tangerang Selatan memiliki persentase penduduk miskin terendah sebesar 2,5.

Jumlah rumah tangga merupakan banyaknya orang yang mendiami seluruh bangunan fisik, tinggal bersama, dan makan dalam satu dapur. Jumlah rumah tangga tertinggi berada pada Kabupaten Bogor sebesar 1.381.734 rumah tangga. Kepulauan Seribu memiliki jumlah rumah tangga terendah sebesar 6.683 rumah tangga.

4.2 Uji Heterogenitas Spasial

Indeks pembangunan manusia memiliki nilai beragam yang disebabkan adanya pengaruh heterogenitas spasial. Heterogenitas terjadi jika sebaran variabel pada seluruh rentang tidak sama dengan nilai variabel lainnya. Heterogenitas spasial dapat diidentifikasi menggunakan uji *Breusch-Pagan*. Hipotesis mengenai uji *Breusch-Pagan* yaitu:

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

$H_1: \{\exists i, \sigma_i^2 \neq \sigma^2\}, i = 1, 2, \dots, n$ (terdapat heterogenitas spasial)

Daerah penolakan H_0 terjadi jika $BP > \chi_{(\alpha, k)}^2$ atau $p - value < 0,05$. Taraf signifikansi yang digunakan adalah 0,05. Pada Lampiran 3 dihasilkan nilai BP sebesar 15,519, nilai $p - value$ sebesar 0,0498 dan $\chi_{(0,05;8)}^2$ sebesar 15,510. Hal ini menunjukkan bahwa terjadi penolakan H_0 dimana $p - value < 0,05$ sebesar 0,0498 < 0,05 atau dengan melihat dari nilai $BP > \chi_{(0,05;8)}^2$ sebesar 15,519 > 15,510, sehingga dapat disimpulkan bahwa residual bersifat heterogen dan terdapat pengaruh heterogenitas spasial pada setiap lokasi pengamatan.

4.3 Uji Multikolinieritas

Multikolinieritas terjadi ketika terdapat korelasi antar masing-masing variabel independen dalam model regresi. Uji multikolinieritas dapat diidentifikasi menggunakan *Variance Inflation Factor* (VIF). Multikolinieritas ditunjukkan dengan nilai VIF lebih besar dari 10. Nilai VIF ditampilkan pada Tabel 4.2 yang merujuk pada Lampiran 4 yaitu:

Tabel 4.2 Nilai VIF

Variabel	VIF
X_1	2,995
X_2	8,063
X_3	2,291
X_4	1,481
X_5	2,820
X_6	81,968
X_7	6,719
X_8	81,672

Berdasarkan Tabel 4.2 bahwa pada variabel X_1 , X_2 , X_3 , X_4 , X_5 , dan X_7 memiliki nilai $VIF < 10$ sehingga pada variabel tersebut tidak menunjukkan adanya multikolinieritas. Variabel X_6 dan X_8 terdapat multikolinieritas yang ditunjukkan dengan nilai $VIF > 10$ yaitu 81,968, dan 81,672. Hal ini dapat disimpulkan bahwa terdapat multikolinieritas pada variabel jumlah penduduk (X_6) dan jumlah rumah tangga (X_8) dengan nilai $VIF > 10$.

4.4 Pemodelan *Geographically Weighted Regression*

Heterogenitas spasial menunjukkan adanya keragaman spasial antar lokasi pengamatan. Data indeks pembangunan manusia menunjukkan adanya keragaman spasial yang dapat dilihat dengan uji *Breusch-Pagan*. Metode *Geographically Weighted Regression* berfungsi untuk mengatasi keragaman spasial. Pemodelan GWR dimulai dengan menghitung jarak *Euclid* yang tertera pada persamaan (2.4) dan pada Lampiran 5. Langkah selanjutnya adalah memilih *bandwidth* dan pembobot optimum. *Bandwidth* optimum diperoleh dari metode *Cross Validation*

(CV) yang dapat ditunjukkan pada persamaan (2.5). Nilai *bandwidth* tersebut kemudian digunakan dalam matriks pembobot ketika melakukan proses estimasi parameter. Fungsi kernel digunakan untuk menentukan besarnya pembobot dalam pemodelan GWR berupa *Adaptive Gaussian* dan *Adaptive Bisquare* (Salsavira et al., 2021). Pemilihan pembobot optimum diperoleh dari nilai *Akaike Information Criterion* (AIC) pada persamaan (2.6). Nilai *bandwidth* optimum dari dua fungsi kernel yaitu:

Tabel 4.3 *Bandwidth*

Fungsi Kernel	<i>Bandwidth</i>	AIC
<i>Adaptive Gaussian</i>	21	514,7019
<i>Adaptive Bisquare</i>	58	521,1609

Berdasarkan Tabel 4.3 digunakan *adaptive quantile* untuk menganalisis data dari distribusi data yang berubah seiring waktu dan menangkap hubungan antar variabel pada berbagai *quantile* terhadap lokasi pengamatan. Fungsi kernel *adaptive* menghasilkan nilai *bandwidth*. Pemilihan *bandwidth* optimum berdasarkan CV minimum yang merujuk pada Lampiran 7. Dua fungsi kernel *adaptive* yang berbeda akan dipilih dalam menentukan pembobot. Pembobot optimum dilihat dari nilai AIC terkecil. Pada Tabel 4.3 diperoleh nilai AIC terkecil yaitu 514,7019 yang terdapat pada kernel *Adaptive Gaussian*. Oleh karena itu, pembobot yang digunakan dalam proses mengestimasi parameter model GWR adalah *Adaptive Gaussian* dengan nilai *bandwidth* sebesar 21. Pendugaan parameter dilakukan setelah pemilihan pembobot optimum. Pendugaan parameter model GWR merupakan suatu langkah untuk memberikan bobot pada setiap lokasi pengamatan yang terdapat dalam data penelitian. Bentuk pendugaan parameter model GWR tertera dalam persamaan (2.8). Pendugaan parameter terdiri dari nilai minimum dan maksimum. Nilai pendugaan parameter ditampilkan pada Tabel 4.4 atau Lampiran 10.

Tabel 4.4 Pendugaan Parameter Model GWR

Variabel	Minimum	Maksimum
<i>Intercept</i>	66,648521	83,583473
X_1	-0,000008	0,000044
X_2	-1,216729	-0,512668
X_3	0,000513	0,000812
X_4	-1,515880	4,057185
X_5	-0,000003	0,000002
X_6	-0,000019	0,000014
X_7	0,228954	4,365372
X_8	-0,000055	0,000071

Pada Tabel 4.4 diperoleh informasi bahwa terdapat korelasi positif antara variabel kepadatan penduduk (X_3) dan indeks kedalaman kemiskinan (X_7) terhadap indeks pembangunan manusia. Hal tersebut menunjukkan bahwa jika variabel X_1, X_3 tinggi, maka indeks pembangunan manusia juga akan semakin tinggi. Variabel penduduk miskin (X_2) memiliki hubungan negatif terhadap IPM, sehingga jika X_2 semakin tinggi maka nilai IPM akan semakin rendah. Variabel Produk Domestik Regional Bruto (X_1), laju pertumbuhan penduduk (X_4), upah minimum kabupaten/kota (X_5), jumlah penduduk (X_6), dan jumlah rumah tangga (X_8) memiliki nilai penduga parameter minimum bernilai negatif dan maksimum bernilai positif. Nilai tersebut menunjukkan adanya korelasi positif pada beberapa kabupaten/kota sementara sebagian lainnya berkorelasi negatif.

Model GWR dapat dilihat sesuai persamaan (2.7) yang berbeda-beda pada setiap kabupaten/kota di Pulau Jawa. Interpretasi model GWR ditampilkan pada Tabel 4.5 atau Lampiran 11.

Tabel 4.5 Model GWR

Kabupaten/Kota	Model GWR
Bogor	$\hat{y}_1 = 69,6021360 - 0,0000070x_1 - 1,0414345x_2$ $+ 0,0005686x_3 - 1,1987444x_4 + 0,0000020x_5$ $- 0,0000054x_6 + 3,5103163x_7 + 0,0000202x_8$

Sukabumi	$\hat{y}_2 = 70,4978510 - 0,0000066x_1 - 1,1420632x_2$ $+ 0,0005989x_3 - 1,1043491x_4 + 0,0000017x_5$ $- 0,0000052x_6 + 4,3653723x_7 + 0,0000191x_8$
----------	--

Berdasarkan Tabel 4.5 menunjukkan bahwa variabel kepadatan penduduk (X_3), upah minimum kabupaten/kota (X_5), indeks kedalaman kemiskinan (X_7), dan jumlah rumah tangga (X_8) memiliki korelasi positif terhadap indeks pembangunan manusia di Kabupaten Bogor dan Sukabumi. Variabel Produk Domestik Regional Bruto (PDRB) (X_1), penduduk miskin (X_2), laju pertumbuhan penduduk (X_4), dan jumlah penduduk (X_6) memiliki hubungan negatif terhadap indeks pembangunan manusia di Kabupaten Bogor dan Sukabumi. Kabupaten Bogor pada nilai $\hat{\beta}_5$ memiliki arti jika upah minimum kabupaten/kota satu juta rupiah maka akan berkorelasi terhadap kenaikan indeks pembangunan manusia sebesar 1,7%. Nilai $\hat{\beta}_2$ pada Kabupaten Bogor memiliki arti jika persentase penduduk miskin naik sebesar 1% maka akan berkorelasi terhadap penurunan indeks pembangunan manusia sebesar 1,04%.

Langkah selanjutnya setelah diketahui model GWR pada setiap kabupaten/kota di Pulau Jawa adalah menguji asumsi multikolinieritas pada model GWR. Multikolinieritas mengindikasikan adanya korelasi linier antar masing-masing variabel independen dalam suatu model. Tabel 4.1 menunjukkan adanya multikolinieritas pada model regresi linier sehingga menyebabkan model GWR juga memenuhi asumsi multikolinieritas. Hasil pengujian asumsi multikolinieritas pada 119 model menunjukkan terdapat multikolinieritas pada keseluruhan model GWR. Pengujian multikolinieritas model GWR disajikan pada Lampiran 12 atau pada Tabel 4.6 yaitu:

Tabel 4.6 Multikolinieritas Model GWR

Kab/Kota	Variabel	VIF
Bogor	X_1	2,7247
	X_2	9,9530
	X_3	4,6978
	X_4	2,9100

	X_5	2,0455
	X_6	197,9617
	X_7	7,9650
	X_8	200,1600
Sukabumi	X_1	2,7361
	X_2	10,5654
	X_3	4,5850
	X_4	2,8158
	X_5	2,3663
	X_6	182,7492
	X_7	8,2151
	X_8	184,5897

Berdasarkan Tabel 4.6, nilai VIF > 10 menunjukkan adanya multikolinieritas. Kabupaten Bogor terdapat adanya multikolinieritas pada variabel X_6 dan X_8 sedangkan X_1 , X_2 , X_3 , X_4 , X_5 , dan X_7 tidak terdapat multikolinieritas. Variabel X_2 , X_6 dan X_8 menunjukkan adanya multikolinieritas pada Kabupaten Sukabumi. Multikolinieritas pada model GWR disebabkan karena adanya penambahan fungsi pembobot yang mengakibatkan besarnya variansi penduga parameter model.

4.5 Parameter Ridge

Ridge digunakan untuk mengatasi multikolinieritas pada suatu model GWR. Multikolinieritas dapat diatasi dengan menambahkan parameter *ridge* pada suatu model seperti pada persamaan (2.10). Nilai parameter *ridge* kemudian akan digunakan dalam pendugaan parameter model GWRR. Langkah pertama untuk menentukan nilai parameter *ridge* dengan melakukan transformasi pada seluruh variabel independen dan dependen. Transformasi ini digunakan untuk memperkecil variansi. Bentuk transformasi dapat dilihat pada persamaan (2.12). Hasil transformasi ditampilkan pada Tabel 4.7 atau pada Lampiran 14.

Tabel 4.7 Transformasi Variabel Dependen dan Variabel Independen

Variabel	Bogor	Sukabumi
Y^*	-0,043	-0,104
X_1^*	0,112	-0,006
X_2^*	-0,447	-0,054
X_3^*	-0,029	-0,054
X_4^*	0,096	0,142
X_5^*	0,145	0,042
X_6^*	0,452	0,159
X_7^*	0,008	-0,067
X_8^*	0,425	0,425

Tabel 4.7 menunjukkan hasil transformasi variabel pada Kabupaten Bogor dan Sukabumi. Transformasi variabel juga dilakukan pada 117 kabupaten/kota lainnya. Langkah selanjutnya adalah menentukan nilai parameter *ridge*. Pemilihan nilai *ridge* optimum didasarkan dari nilai GCV minimum. Nilai parameter *ridge* dan GCV disajikan pada Lampiran 16. Nilai GCV minimum diperoleh sebesar 0,0841 dengan nilai *ridge* optimum sebesar 0,542. Oleh karena itu, nilai *ridge* optimum yang digunakan untuk pendugaan parameter model GWRR yaitu 0,542.

4.6 Pemodelan *Geographically Weighted Ridge Regression*

Model GWRR digunakan untuk menangani multikolinieritas pada GWR dengan cara menambahkan parameter *ridge* pada matriks dugaan parameternya (Wheeler, 2007). Nilai parameter *ridge* diperoleh dari nilai parameter *ridge* optimum. Pembobot yang digunakan adalah *Adaptive Gaussian* yang merupakan pembobot optimum pada model GWR. Model GWRR menggunakan variabel hasil transformasi disajikan pada Lampiran 14. Pendugaan parameter untuk 119 kabupaten/kota dapat dilihat pada Lampiran 19. Tabel 4.8 disajikan nilai minimum dan maksimum pendugaan parameter model GWRR dengan menggunakan variabel hasil transformasi.

Tabel 4.8 Pendugaan Parameter Model GWRR

Parameter Model GWRR	Minimum	Maksimum
X_1	-0,00979	0,93115
X_2	-0,97746	-0,06036
X_3	0,04378	0,08550
X_4	-0,83469	0,99271
X_5	-0,05423	0,93224
X_6	-0,49921	0,47754
X_7	-0,73878	0,93207
X_8	-0,24632	0,01215

Pada Tabel 4.8 dapat dilihat kisaran nilai minimum dan maksimum dari pendugaan parameter. Nilai tersebut merepresentasikan rentang nilai duga untuk variabel hasil transformasi. Variabel kepadatan penduduk (X_3) memiliki nilai penduga parameter minimum dan maksimum bernilai positif yang mengindikasikan variabel tersebut memiliki korelasi positif terhadap indeks pembangunan manusia. Variabel penduduk miskin (X_2) memiliki nilai penduga parameter minimum dan maksimum bernilai negatif. Hal ini menunjukkan bahwa X_2 memiliki korelasi negatif terhadap indeks pembangunan manusia. Variabel Produk Domestik Regional Bruto (PDRB) (X_1), laju pertumbuhan penduduk (X_4), upah minimum kabupaten/kota (X_5), jumlah penduduk (X_6), indeks kedalaman kemiskinan (X_7), dan jumlah rumah tangga (X_8) memiliki nilai penduga parameter minimum bernilai negatif dan maksimum bernilai positif. Nilai tersebut menunjukkan adanya korelasi positif pada beberapa kabupaten/kota sementara sebagian lainnya berkorelasi negatif.

Pendugaan parameter GWRR yang telah diperoleh akan dikembalikan ke dalam bentuk awal sebelum dilakukannya transformasi. Pembentukan dari variabel hasil transformasi ke variabel sebelum transformasi tertera pada persamaan (2.16). dari Model GWRR terbentuk berdasarkan nilai pendugaan parameter yang telah dikembalikan dari hasil transformasi. Model GWRR tertera pada persamaan (2.14) yang diperoleh model yang berbeda-beda pada masing-masing kabupaten/kota di

Pulau Jawa. Model GWRR dapat dilihat pada Lampiran 20. Model GWRR pada Kabupaten Bogor dan Sukabumi adalah:

Tabel 4.9 Model GWRR

Kabupaten/Kota	Model GWRR
Bogor	$\hat{y}_1 = 71,454688 - 0,000006x_1 - 1,150870x_2 +$ $0,000523x_3 - 1,357752x_4 + 0,000001x_5 -$ $0,000004x_6 + 3,395379x_7 + 0,000016x_8$
Sukabumi	$\hat{y}_2 = 70,515651 - 0,000006x_1 - 1,313030x_2 +$ $0,000610x_3 - 0,994387x_4 + 0,000001x_5 -$ $0,000003x_6 + 5,031327x_7 + 0,000013x_8$

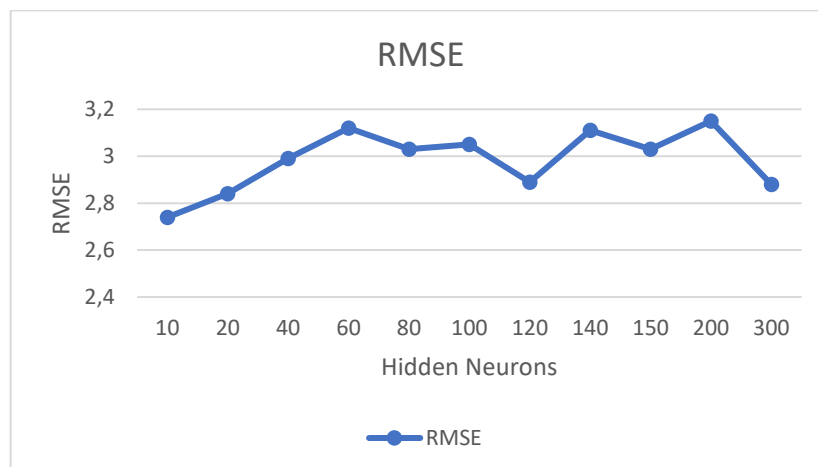
Berdasarkan Tabel 4.9 menunjukkan bahwa kepadatan penduduk (X_3) dan upah minimum kabupaten/kota (X_5) memiliki korelasi positif terhadap indeks pembangunan manusia di Kabupaten Bogor dan Sukabumi. Variabel Produk Domestik Regional Bruto (PDRB) (X_1), penduduk miskin (X_2), laju pertumbuhan penduduk (X_4), jumlah penduduk (X_6), indeks kedalaman kemiskinan (X_7), dan jumlah rumah tangga (X_8) memiliki korelasi negatif terhadap indeks pembangunan manusia di Kabupaten Bogor dan Sukabumi. Interpretasi model GWRR pada Kabupaten Bogor pada nilai $\hat{\beta}_5$ memiliki arti jika variabel upah minimum kabupaten/kota meningkat satu juta rupiah maka akan berkorelasi terhadap kenaikan indeks pembangunan manusia sebesar 1%. X_3 dan X_5 memiliki pengaruh positif terhadap kenaikan nilai indeks pembangunan manusia pada seluruh kabupaten/kota di Pulau Jawa. Nilai $\hat{\beta}_2$ pada Kabupaten Sukabumi menunjukkan jika variabel penduduk miskin menurun 1% maka akan berkorelasi terhadap penurunan indeks pembangunan manusia sebesar 1,3%. X_1 , X_2 , X_4 , X_6 , X_7 , X_8 memiliki pengaruh negatif terhadap penurunan indeks pembangunan manusia pada seluruh kabupaten/kota di Pulau Jawa.

4.7 Pemodelan *Geographically Weighted Artificial Neural Network*

Geographically Weighted Artificial Neural Network merupakan pengembangan dari *Artificial Neural Network* yang ditambahkan dengan pembobot

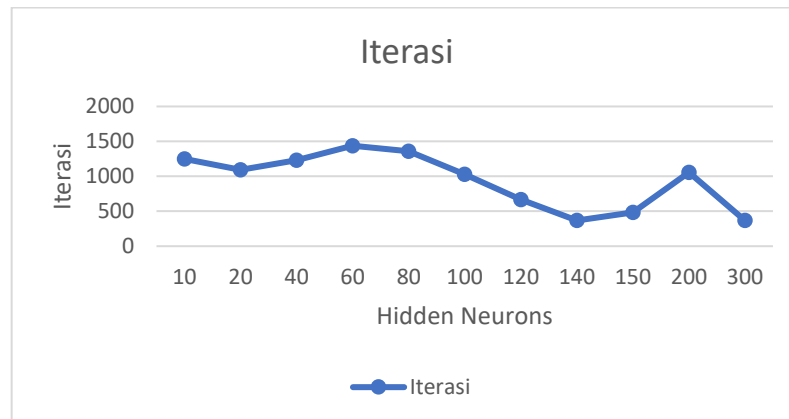
spasial. Pembobot yang digunakan dalam pembelajaran model GWANN pada IPM di Pulau Jawa yaitu *Adaptive Gaussian* dan *Adaptive Bisquare*. Fungsi aktivasi yang digunakan yaitu fungsi *hyperbolic tangent*. Nilai bandwidth yang sesuai dapat dicari dengan menggunakan pendekatan *golden section*. Jenis arsitektur yang digunakan pada GWANN adalah *single hidden layer* dengan beberapa *hidden neurons*. Pembelajaran model dilakukan dengan *hidden neurons* dari 10 sampai 300. *Learning rate* yang digunakan pada GWANN sebesar 0,01. *Optimizer* dalam model terdiri atas nesterov, adam, SGD, dan momentum. *Batch size* yang digunakan dalam penelitian yaitu 11, 32, 64, dan 128.

Pemilihan model terbaik GWANN didasarkan pada nilai RMSE terkecil. Berdasarkan Lampiran 23 diperoleh satu model terbaik yaitu model dengan menggunakan fungsi kernel *adaptive gaussian*, *optimizer* nesterov, dan *batch size* sebesar 10.



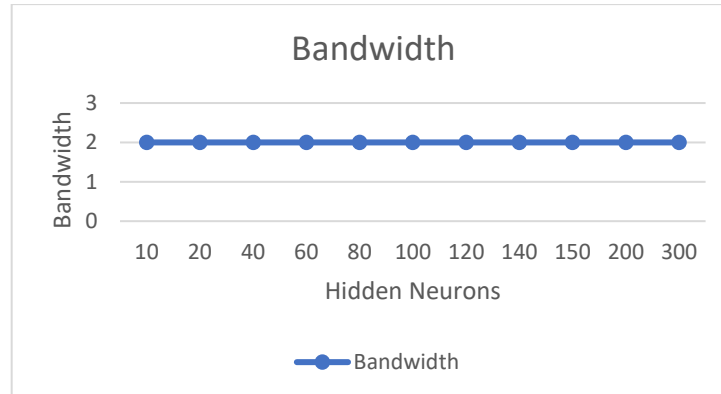
Gambar 4.2 Grafik *Hidden Neurons* Dengan RMSE

Berdasarkan Gambar 4.2 *hidden neurons* yang digunakan pada model *Adaptive Gaussian* dimulai dari 10 sampai 300 dengan *8-fold cross validation*. Nilai RMSE terkecil sebesar 2,7 diperoleh saat diberikan *hidden neurons* sebesar 10. Nilai RMSE tertinggi diperoleh pada penggunaan *hidden neurons* sebesar 200 yaitu 3,15. Penggunaan *hidden neurons* mulai dari 10 hingga 60 menghasilkan kenaikan pada nilai RMSE.



Gambar 4.3 Grafik *Hidden Neurons* Dengan Iterasi

Berdasarkan Gambar 4.3, iterasi mengalami peningkatan pada saat diberikan *hidden neurons* sebesar 140 hingga 200. Iterasi mengalami penurunan signifikan pada saat diberikan *hidden neurons* sebesar 140 dari 1438 iterasi menjadi 368 iterasi. Pada saat penggunaan *hidden neurons* sebesar 60, iterasi mengalami kenaikan signifikan dari 1094 iterasi menjadi 1438 iterasi.



Gambar 4.4 Grafik *Hidden Neurons* Dengan *Bandwidth*

Berdasarkan Gambar 4.4 ditampilkan hubungan antara *hidden neurons* dengan *bandwidth*. Grafik *hidden neurons* dari 10 sampai 300 terhadap *bandwidth* adalah konstan. Nilai *bandwidth* sama pada seluruh *hidden neurons* yaitu 2.

4.8 Pemilihan Model Terbaik

Pemilihan model terbaik antara GWR, GWRR, dan GWANN dilakukan untuk mengetahui metode mana yang paling efektif dalam menjelaskan masalah yang

dikaji dalam penelitian ini. Kriteria pemilihan model terbaik ditentukan berdasarkan nilai RMSE dan nilai R^2 . Perbandingan ketiga model diperoleh hasil sebagai berikut:

Tabel 4.10 Perbandingan Model GWR, GWRR, dan GWANN

Kriteria	GWR	GWRR	GWANN
RMSE	1,83	1,35	2,74
R^2	0,87	0,93	0,54
Waktu (detik)	3,23	5,82	6,15

Berdasarkan Tabel 4.10 ketiga metode tersebut menggunakan fungsi kernel *Adaptive Gaussian*. Kriteria penentuan model terbaik dilihat dari nilai RMSE yang terkecil, selain itu dilihat dari R^2 dimana semakin mendekati 1, semakin baik keakuratan pengukurannya. Pada metode GWRR mampu mengatasi multikolinieritas dan diperoleh nilai R^2 sebesar 0,93 serta nilai RMSE terkecil sebesar 1,35 dibanding kedua metode lainnya. Pada metode GWR diperoleh nilai RMSE sebesar 1,83, dimana nilai tersebut masih lebih besar dibanding GWRR. Selain itu, jika dilihat dari nilai R^2 pada metode GWR memiliki nilai yang tidak berbeda jauh dari GWRR. Pada metode GWANN dengan *hyperparameter* terpilih menghasilkan waktu yang paling lama dibanding dengan kedua metode lainnya serta memiliki nilai RMSE terbesar sebesar 2,74 dan nilai R^2 paling jauh dari angka 1. Berdasarkan hasil perbandingan yang diperoleh metode GWRR menunjukkan hasil yang lebih baik dibanding dengan GWR dan GWANN.

4.9 Uji Signifikansi Parameter Model Berdasarkan Model Terbaik

Berdasarkan pemilihan model terbaik diperoleh metode GWRR yang paling baik dalam kasus IPM di Pulau Jawa tahun 2022. Langkah selanjutnya setelah ditentukan model terbaik adalah melakukan pengujian signifikansi parameter model pada metode GWRR. Uji signifikansi parameter model digunakan untuk mengetahui signifikansi parameter-parameter yang diperoleh dari masing-masing lokasi pengamatan. Pengujian ini dilakukan untuk mengetahui pengaruh signifikan variabel independen terhadap variabel dependen. Uji signifikansi parameter yaitu:

$H_0: \beta_k(u_i, v_i) = 0$ (parameter tidak signifikan)

$H_1: \beta_k(u_i, v_i) \neq 0, k = 1, 2, \dots, p$ (parameter signifikan)

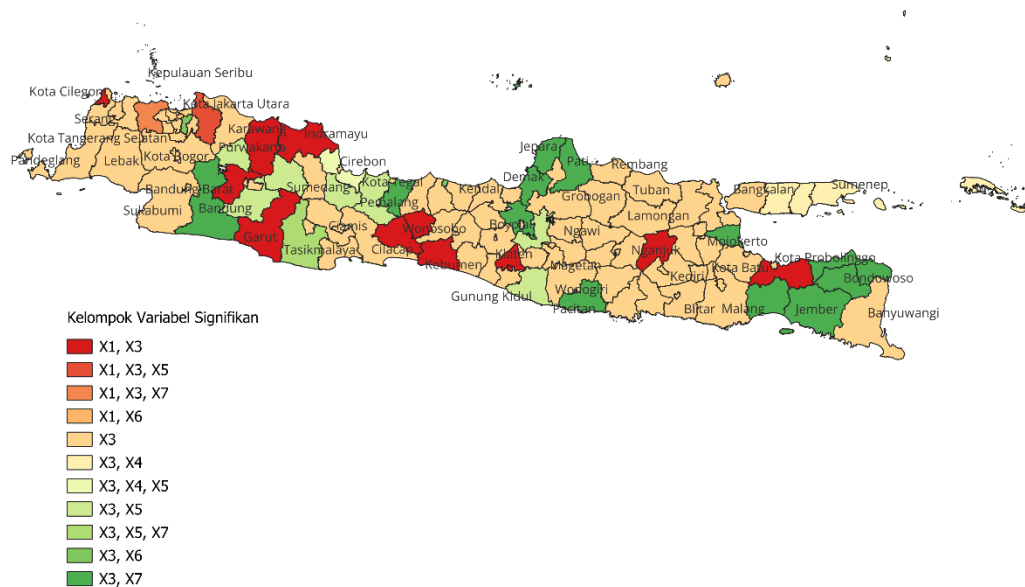
Hasil pengujian signifikansi parameter model GWRR disajikan pada Lampiran 25. H_0 ditolak apabila $|t_{hitung}| > t_{(\frac{\alpha}{2}, df)}$. Hal ini menunjukkan bahwa minimal terdapat satu variabel independen yang berpengaruh signifikan terhadap variabel dependen. Berdasarkan Lampiran 8, didapatkan bahwa nilai derajat kebebasan (df) sebesar 78,77487 dan α sebesar 0,05. Nilai $t_{(\frac{\alpha}{2}, df)}$ dengan taraf signifikansi 0,05 diperoleh $t_{(0,025;101,5214)}$ sebesar 1,990539. Pengelompokan variabel signifikan disajikan pada Tabel 4.11.

Tabel 4.11 Variabel Signifikan Pada Model GWRR

Kabupaten/Kota	Variabel
Kota Cilegon, Kota Yogyakarta, Sleman, Bandung Barat, Garut, Indramayu, Subang, Banyumas, Kebumen, Purbalingga, Nganjuk, Probolinggo	X_1, X_3
Bekasi	X_1, X_3, X_5
Tangerang	X_1, X_3, X_7
Kota Jakarta Pusat	X_1, X_6
Kota Serang, Kota Tangerang, Kota Tangerang Selatan, Lebak, Pandeglang, Serang, Bantul, Kulon Progo, Kepulauan Riau, Kota Jakarta Barat, Kota Jakarta Selatan, Kota Jakarta Utara, Bogor, Ciamis, Karawang, Kota Bandung, Kota Banjar, Kota Bekasi, Kota Bogor, Kota Cimahi, Kota Cirebon, Kota Depok, Kota Sukabumi, Kota Tasikmalaya, Majalengka, Pangandaran, Sukabumi, Banjarnegara, Batang, Blora, Cilacap, Grobogan, Karanganyar, Kendal, Klaten, Kota Magelang, Kota Salatiga, Kota Semarang, Kota Surakarta, Kota Tegal, Kudus, Magelang, Pekalongan, Pemalang, Purworejo, Rembang, Sragen, Sukoharjo, Temanggung, Wonogiri, Wonosobo, Bangkalan, Banyuwangi, Blitar, Bojonegoro, Gresik, Jombang, Kediri, Kota Batu, Kota Batu, Kota Blitar, Kota Kediri, Kota Madiun, Kota Malang, Kota Mojokerto, Kota Pasuruan, Kota Probolinggo, Kota Surabaya, Lamongan, Madiun, Magetan, Malang,	X_3

Mojokerto, Ngawi, Pasuruan, Ponorogo, Trenggalek, Tuban, Tulungagung	
Sumenep, Sampang, Pamekasan	X_3, X_4
Cirebon	X_3, X_4, X_5
Gunung Kidul, Bandung, Kuningan, Purwakarta, Sumedang, Boyolali, Brebes	X_3, X_5
Tasikmalaya	X_3, X_5, X_7
Kota Jakarta Timur, Kota Pekalongan	X_3, X_6
Lumajang, Pacitan, Situbondo, Sidoarjo, Jember, Bondowoso, Tegal, Semarang, Pati, Jepara, Demak, Cianjur	X_3, X_7

Berdasarkan Tabel 4.11, kepadatan penduduk (X_3) memiliki pengaruh signifikan terhadap IPM pada seluruh lokasi di Pulau Jawa. Produk Domestik Regional Bruto (RDRB) (X_1), laju pertumbuhan penduduk (X_4), upah minimum kabupaten/kota (X_5), jumlah penduduk (X_6) dan indeks kedalaman kemiskinan (X_7) berpengaruh pada sebagian lokasi di Pulau Jawa. Penduduk miskin (X_2) dan jumlah rumah tangga (X_8) tidak memiliki pengaruh signifikan terhadap IPM pada seluruh lokasi. Pada Tabel 4.9 terdapat 11 pengelompokan variabel signifikan. Kelompok pertama yaitu X_1, X_3 yang memiliki pengaruh pada 12 lokasi. Kelompok kedua terdiri dari X_1, X_3, X_5 yang hanya memiliki pengaruh pada 1 lokasi. Kelompok ketiga yaitu X_1, X_3, X_7 berpengaruh terhadap IPM hanya 1 lokasi. Kelompok keempat adalah X_1, X_6 hanya berpengaruh pada 1 lokasi. Kelompok kelima adalah X_3 berpengaruh pada 78 lokasi. Kelompok keenam yaitu X_3, X_4 berpengaruh pada 3 lokasi. Kelompok ketujuh yaitu X_3, X_4, X_5 berpengaruh hanya 1 lokasi. Kelompok kedelapan yaitu X_3, X_5 memiliki pengaruh pada 7 lokasi. Kelompok kesembilan terdiri dari X_3, X_5, X_7 hanya berpengaruh pada 1 lokasi. Kelompok kesepuluh yaitu X_3, X_6 berpengaruh pada 2 lokasi. Kelompok kesebelas yaitu X_3, X_7 memiliki pengaruh terhadap IPM pada 12 lokasi.



Gambar 4.5 Pemetaan Variabel Signifikan

Berdasarkan Gambar 4.5, hampir di seluruh wilayah di Pulau Jawa dipengaruhi oleh X_3 . Pada bagian timur Pulau Jawa beberapa daerah dipengaruhi X_3 dan X_7 . Daerah Jawa Barat (Subang, Indramayu, dan beberapa daerah lain) dipengaruhi oleh X_1 dan X_3 . Daerah Jawa Tengah (Brebes dan Boyolali) dipengaruhi oleh X_3 dan X_5 . Pada wilayah DIY sebagian daerah dipengaruhi oleh X_1 dan X_3 . Berdasarkan hal tersebut dapat diketahui bahwa keterkaitan antar wilayah satu sama lain dipengaruhi oleh dekat atau jauhnya letak geografis suatu wilayah.

Model GWRR pada setiap kabupaten dan kota di Pulau Jawa berbeda-beda sesuai pada persamaan (2.14). Interpretasi model GWRR dapat dilihat pada Tabel 4.9 atau Lampiran 20. Berdasarkan pemilihan model terbaik diperoleh model GWRR mampu menjelaskan dengan baik dalam kasus IPM di Pulau Jawa tahun 2022.

BAB 5. KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil analisis data indeks pembangunan manusia di Pulau Jawa dengan metode GWR, GWRR, dan GWANN dapat diambil kesimpulan sebagai berikut:

1. Hasil yang diperoleh dari model GWR, GWRR, dan GWANN menunjukkan adanya ketergantungan spasial yang memengaruhi nilai indeks pembangunan manusia. Faktor yang memengaruhi indeks pembangunan manusia terdiri atas faktor kependudukan (kepadatan penduduk, laju pertumbuhan penduduk, dan jumlah penduduk) dan faktor ekonomi (Produk Nasional Domestik Bruto, upah minimum kabupaten/kota, indeks kedalaman kemiskinan). Pemetaan wilayah berdasarkan variabel signifikan terbagi menjadi 11 kelompok dimana kepadatan penduduk mempengaruhi indeks pembangunan manusia pada hampir seluruh lokasi di Pulau Jawa.
2. Kriteria pemilihan model terbaik terdiri dari R^2 dan RMSE. Hasil R^2 dari GWR, GWRR, dan GWANN berturut-turut yaitu 0,87, 0,93, dan 0,54. Nilai RMSE dari GWRR < GWR < GWANN (1,35 < 1,83 < 2,74). Berdasarkan hasil pemilihan model terbaik diperoleh model GWRR dengan pembobot optimum *Adaptive Gaussian* yang mampu menjelaskan dengan baik pada data indeks pembangunan manusia.

5.2 Saran

Berdasarkan penelitian yang telah dilakukan, diharapkan peneliti selanjutnya untuk menambah faktor-faktor lain yang diduga mempengaruhi indeks pembangunan manusia, sehingga variabel signifikan dapat lebih bervariasi. Peneliti selanjutnya diharapkan dapat menggunakan metode selain GWRR dalam mengatasi multikolinieritas yaitu *Geographically Weighted Lasso* (GWL) atau *Locally Compasanted Ridge Geographically Weighted Regression* (LCR-GWR).

DAFTAR PUSTAKA

- Andriani, S. (2017). Uji Park Dan Uji Breusch Pagan Godfrey Dalam Pendeteksian Heteroskedastisitas Pada Analisis Regresi. *Al-Jabar: Jurnal Pendidikan Matematika*, 8(1), 63–72.
- Ariwuni, M., & Kartika, I. (2019). Pengaruh PDRB Dan Pengeluaran Pemerintah Terhadap IPM Dan Tingkat Kemiskinan Di Kabupaten/Kota Provinsi Bali. *E-Jurnal Ekonomi Pembangunan*, 8(12), 2807–3114.
- Badan Pusat Statistik. (2022). *Indeks Pembangunan Manusia 2022*. BPS Indonesia.
- Bawono, A. (2018). *EKONOMETRIKA TERAPAN Untuk Ekonomi dan Bisnis Islam Aplikasi dengan Eviews*. LP2M Press.
- Brewer, M. J., Butler, A., & Cooksley, S. L. (2016). The relative performance of AIC, AICC and BIC in the presence of unobserved heterogeneity. *Methods in Ecology and Evolution*, 7(6), 679–692.
- Caraka, R. E., & Yasin, H. (2017). *Geographically weighted regression (GWR) sebuah pendekatan regresi geografis*. Mobius, Graha Ilmu.
- Chalid, N., & Yusuf, Y. (2014). Pengaruh tingkat kemiskinan, tingkat pengangguran, upah minimum kabupaten/kota dan laju pertumbuhan ekonomi terhadap indeks pembangunan manusia di Provinsi Riau. *Jurnal Ekonomi*, 22(2), 1–12.
- Fan, G.-F., Peng, L.-L., & Hong, W.-C. (2018). Short term load forecasting based on phase space reconstruction algorithm and bi-square kernel regression model. *Applied Energy*, 224, 13–33.
- Fotheringham, A. S., Brunsdon, C., & Charlton, M. (2003). *Geographically weighted regression: the analysis of spatially varying relationships*. John Wiley & Sons.
- Hagenauer, J., & Helbich, M. (2022). A geographically weighted artificial neural network. *International Journal of Geographical Information Science*, 36(2), 215–235.
- Hastutik, R. D. (2018). *Model Geographically Weighted Ridge Regression (Gwrr) Pada Data Indeks Pembangunan Manusia (Ipm) Di Provinsi Papua*.
- Hodson, T. O. (2022). Root-mean-square error (RMSE) or mean absolute error (MAE): When to use them or not. *Geoscientific Model Development*, 15(14), 5481–5487.
- Ishwaran, H., & Rao, J. S. (2014). Geometry and properties of generalized ridge regression in high dimensions. *Contemp. Math*, 622, 81–93.

- Kiha, E. K., Seran, S., & Lau, H. T. (2021). Pengaruh jumlah penduduk, pengangguran, dan kemiskinan terhadap indeks pembangunan manusia (ipm) di kabupaten belu. *Jurnal Ekonomi, Sosial & Humaniora*, 2(07), 60–84.
- Lesnussa, Y. A., Mustamu, C. G., Lembang, F. K., & Talakua, M. W. (2018). Application of backpropagation neural networks in predicting rainfall data in Ambon city. *International Journal of Artificial Intelligence Research*, 2(2), 41–50.
- Prayogo, I., & Hasmarini, M. I. (2022). Analisis Pengaruh IPM, Upah Minimum, PDRB dan Jumlah Penduduk Terhadap Penyerapan Tenaga Kerja Di Yogyakarta Tahun 2018-2021. *SEIKO: Journal of Management & Business*, 5(2), 77–85.
- Qur'ani, A. Y., Octavanny, M. A. D., & Widiastuti, R. S. (2023). Estimasi Parameter Model Geographically Weighted Ridge Regression pada Indikator Pengukuran Penanganan Stunting di Indonesia. *OKTAL: Jurnal Ilmu Komputer Dan Sains*, 2(08), 2245–2253.
- Salsavira, S., Afifah, J., Mahendra, F. T., & Dzakiyah, L. (2021). Spatial Analysis of Prevalence of Early Marriage and HDI in Indonesia. *Jurnal Matematika, Statistika Dan Komputasi*, 18(1), 31–41.
- Setiawan, M. B., & Hakim, A. (2013). Indeks pembangunan manusia Indonesia. *Jurnal Economia*, 9(1), 18–26.
- Shrestha, N. (2020). Detecting multicollinearity in regression analysis. *American Journal of Applied Mathematics and Statistics*, 8(2), 39–42.
- Veronica, D., Yasin, H., & Widiharih, T. (2016). Pemodelan pendapatan asli daerah (pad) di kabupaten dan kota di jawa tengah menggunakan geographically weighted ridge regression. *Jurnal Gaussian*, 5(3), 383–393.
- Wasilaine, T. L., Talakua, M. W., & Lesnussa, Y. A. (2014). Model Regresi Ridge Untuk Mengatasi Model Regresi Linier Berganda Yang Mengandung Multikolinieritas. *BAREKENG: Jurnal Ilmu Matematika Dan Terapan*, 8(1), 31–37.
- Wheeler, D. C. (2007). Diagnostic tools and a remedial method for collinearity in geographically weighted regression. *Environment and Planning A*, 39(10), 2464–2481.
- Wheeler, D. C., & Páez, A. (2009). Geographically weighted regression. In *Handbook of applied spatial analysis: Software tools, methods and applications* (pp. 461–486). Springer.
- Zhang, Z., & Zhang, Z. (2018). Artificial neural network. *Multivariate Time Series Analysis in Climate and Environmental Research*, 1–35.

LAMPIRAN

- Lampiran 1. [Data IPM di Pulau Jawa](#)
- Lampiran 2. [Statistika Deskriptif](#)
- Lampiran 3. [Uji *Breusch-Pagan*](#)
- Lampiran 4. [Uji Multikolinieritas](#)
- Lampiran 5. [Jarak *Euclid*](#)
- Lampiran 6. [Penskalaan Data Frame Spasial](#)
- Lampiran 7. [Pemilihan *Bandwidth* Optimum Model GWR](#)
- Lampiran 8. [Model GWR](#)
- Lampiran 9. [Penduga Parameter Model GWR](#)
- Lampiran 10. [*Output* Penduga Parameter Model GWR](#)
- Lampiran 11. [Model GWR Pada Kabupaten Bogor dan Sukabumi](#)
- Lampiran 12. [Multikolinieritas Model GWR](#)
- Lampiran 13. [Transformasi Data](#)
- Lampiran 14. [*Output* Transformasi Data IPM](#)
- Lampiran 15. [Parameter *Ridge*](#)
- Lampiran 16. [*Output* Parameter *Ridge*](#)
- Lampiran 17. [Pemilihan *Ridge* Optimum](#)
- Lampiran 18. [Model GWRR](#)
- Lampiran 19. [*Output* Penduga Parameter Model GWRR](#)
- Lampiran 20. [Model GWRR Pada Kabupaten Bogor dan Sukabumi](#)
- Lampiran 21. [Pemodelan GWANN](#)
- Lampiran 22. [*Training* Model](#)
- Lampiran 23. [*Output Training* Model](#)
- Lampiran 24. [Nilai RMSE dan \$R^2\$](#)
- Lampiran 25. [*Output* \$t_{hitung}\$ Berdasarkan Pemilihan Model Terbaik](#)

