PERBANDINGAN MODEL *GEOGRAPHICALLY WEIGHTED PANEL REGRESSION* DENGAN PEMBOBOT *ADAPTIVE GAUSSIAN* DAN *ADAPTIVE BISQUARE* UNTUK INDEKS PEMBANGUNAN MANUSIA DI JAWA TENGAH

Skripsi
disusun sebagai salah satu syarat
untuk memperoleh gelar Sarjana Sains
Program Studi Matematika

oleh

Erlinda Permata Fitri

4111415027

JURUSAN MATEMATIKA

FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM

UNIVERSITAS NEGERI SEMARANG

2019

HALAMAN PENGESAHAN

Skripsi berjudul

Perbandingan Model *Geographically Weighted Panel Regression* dengan Pembobot *Adaptive Gaussian* dan *Adaptive Bisquare* untuk Indeks Pembangunan Manusia di Jawa Tengah

disusun oleh

Erlinda Permata Fitri

4111415027

telah dipertahankan di hadapan sidang Panitia Ujian Skripsi FMIPA Universitas Negeri Semarang pada tanggal 12 Agustus 2019 dan disahkan oleh Panitia Ujian.

Panitia:

KEMENTERIAN RISET, TEKNOLOGI DAN PENDIDIKAN TINGGI UNIVERSITAS NEGERI SEMARANG UNNES

Ketua

Dr. Sugianto, M.Si.
NIP. 196102191993031001

Sekretaris

Drs. Arief Agoestanto, M.Si.
NIP. 196807221993031005

Ketua Penguji

Dr. Scolastika Mariani, M.Si.
NIP. 196502101991022001

Anggota Penguji/
Penguji II

Dra. Sunarmi, M.Si.
NIP. 195506241988032001

Anggota Penguji/
Pembimbing I

Drs. Sugiman, M.Si
NIP 196401111989011001

ii

PERNYATAAN

Dengan ini, saya

Nama : Erlinda Permata Fitri

NIM : 4111415027

Program studi : Matematika

Menyatakan bahwa skripsi berjudul "Perbandingan Model *Geographically Weighted Panel Regression* dengan Pembobot *Adaptive Gaussian* dan *Adaptive Bisquare* untuk Indeks Pembangunan Manusia di Jawa Tengah" ini benar-benar karya sendiri bukan jiplakan dari karya orang lain. Dan pendapat atau temuan orang atau pihak lain yang terdapat dalam skripsi ini telah dikutip berdasarkan kode etik ilmiah.

Semarang, Agustus 2019

METERAI TEMPEL

8935DAFF81638

6000

ENAM RIBU RUPIAH

Erlinda Permata Fitri

NIM 4111415027

MOTTO DAN PERSEMBAHAN

MOTTO

1. Maka sesungguhnya bersama kesulitan ada kemudahan, Sesungguhnya bersama kesulitan ada kemudahan. (Q.S Al-Insyirah: 5-6).
2. “Allah tidak membebani seseorang itu melainkan sesuai dengan kesanggupannya.” (QS. Al-Baqarah ; 286)

PERSEMBAHAN

Untuk kedua orangtua, keluarga, kerabat, dan sahabat yang telah mendoakan dan memberikan dukungan. Serta untuk almamater, Universitas Negeri Semarang.

PRAKATA

Puji syukur kehadirat Allah SWT atas segala limpahan rahmat-Nya sehingga penulis dapat menyelesaikan skripsi yang berjudul “Perbandingan *Model Geographically Weighted Panel Regression* dengan Pembobot *Adaptive Gaussian* dan *Adaptive Bisquare* untuk Indeks Pembangunan Manusia di Jawa Tengah”. Skripsi ini disusun sebagai salah satu syarat meraih gelar Sarjana Sains pada Program Studi Matematika, Universitas Negeri Semarang. Shalawat serta salam senantiasa tercurahkan kepada junjungan kita Nabi Muhammad SAW, yang kita nantikan safa’atnya di hari kiamat nanti.

Penulis menyadari bahwa dalam penyusunan skripsi ini tidak terlepas dari bantuan dan bimbingan dari berbagai pihak. Untuk itu, penulis ingin menyampaikan terima kasih kepada:

1. Prof. Dr. Fathur Rokhman, M.Hum., Rektor Universitas Negeri Semarang.
2. Dr. Sugianto, M.Si., Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Semarang.
3. Drs. Arief Agoestanto, M.Si., Ketua Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Semarang.
4. Drs. Sugiman, M.Si., Dosen Pembimbing yang telah memberikan bimbingan, arahan, dan saran kepada penulis dalam menyusun skripsi ini.
5. Dr. Scolastika Mariani, M.Si., dan Dra. Sunarmi, M.Si., Dosen Penguji yang telah memberikan bimbingan, arahan, dan saran kepada penulis dalam menyusun skripsi ini.

6. Bapak dan Ibu dosen Jurusan Matematika, yang telah memberikan bimbingan dan ilmu kepada penulis selama menempuh pendidikan.
7. Teman-teman mahasiswa Program Studi Matematika UNNES angkatan 2015, yang selalu berbagi rasa dalam suka duka, dan atas segala bantuan dan kerja samanya dalam menempuh studi.
8. Semua pihak yang turut membantu dalam menyusun skripsi ini yang tidak dapat disebutkan namanya satu persatu.

Semoga skripsi ini dapat memberikan manfaat bagi penulis dan para pembaca. Terima kasih.

Semarang, Agustus 2019

Penulis

ABSTRAK

Fitri, Erlinda Permata. 2019. Perbandingan Model *Geographically Weighted Panel Regression* dengan Pembobot *Adaptive Gaussian* dan *Adaptive Bisquare* untuk Indeks Pembangunan Manusia di Jawa Tengah. Skripsi, Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Semarang. Pembimbing Drs. Sugiman, M.Si.

Kata Kunci : Regresi Data Panel, *Fixed Effect Model*, *Geographically Weighted Panel Regression*, *Adaptive Gaussian*, *Adaptive Bisquare*

Regresi data panel yaitu suatu metode regresi yang dapat digunakan untuk memodelkan data *cross section* dan data *time series*. Menggunakan data panel akan memberikan hasil yang lebih baik dibanding hanya melakukan pengamatan dalam satu waktu tertentu saja. Tetapi ada faktor lain yang juga perlu diperhatikan yaitu mengenai pengaruh efek spasial seperti heterogenitas spasial. Untuk mengatasi adanya heterogenitas spasial pada data bertipe panel dapat menggunakan metode statistik yang merupakan gabungan antara model *Geographically Weighted Regression* (GWR) dengan model regresi data panel yaitu *Geographically Weighted Panel Regression*. Tujuan dari penelitian ini adalah membentuk model GWPR dengan pembobot *adaptive gaussian* dan *adaptive bisquare*, serta membandingkan model GWPR terbaik dengan pembobot *adaptive gaussian* dan *adaptive bisquare*. Data yang digunakan adalah Indeks Pembangunan Manusia di Jawa Tengah tahun 2015-2017.

Variabel independen yang digunakan dalam penelitian ini yaitu Umur Harapan Hidup, Harapan Lama Sekolah, Rata-rata Lama Sekolah, dan Pengeluaran perkapita. Langkah analisis yang dilakukan yaitu melakukan pengujian model estimasi regresi data panel. Dalam penelitian ini model estimasi regresi data panel yang terbaik yaitu *Fixed Effect Model*. Selanjutnya dilakukan pengujian menggunakan model *Fixed Effect* GWPR dengan pembobot *adaptive gaussian* dan *adaptive bisquare*.

Berdasarkan hasil penelitian diperoleh model *Fixed Effect* GWPR dengan pembobot *Adaptive Gaussian* di Kabupaten Brebes $\hat{y}_{29t} = 0{,}615648\,\mathrm{X}_{29\mathrm{t}1} + 0{,}176231\,\mathrm{X}_{29\mathrm{t}2} + 1{,}517739\,\mathrm{X}_{29\mathrm{t}3} + 0{,}001099\,\mathrm{X}_{29\mathrm{t}4}$ dan model *Fixed Effect* GWPR dengan pembobot *Adaptive Bisquare* di Kabupaten Brebes $\hat{y}_{29t} = 0{,}620885\,\mathrm{X}_{29\mathrm{t}1} + 0{,}122763\,\mathrm{X}_{29\mathrm{t}2} + 1{,}426407\,\mathrm{X}_{29\mathrm{t}3} + 0{,}001198\,\mathrm{X}_{29\mathrm{t}4}$. Pemilihan model terbaik dapat diketahui berdasarkan nilai koefisien determinasi dan nilai AIC. Model *Fixed Effect* GWPR dengan pembobot *Adaptive Bisquare* merupakan model yang terbaik karena memiliki nilai koefisien determinasi terbesar yaitu $0{,}9954$ dan nilai AIC terkecil sebesar $65{,}61756$. Untuk penelitian selanjutnya dapat dikembangkan model *Random Effect* GWPR atau dengan menggunakan pembobot lain.

DAFTAR ISI

DAFTAR TABEL

DAFTAR GAMBAR

DAFTAR LAMPIRAN

BAB 1

PENDAHULUAN

1.1 Latar Belakang Masalah

Regresi linear adalah salah satu metode statistik yang mempelajari hubungan atara variabel respon dengan satu atau lebih variabel prediktor. Variabel respon dikenal sebagai variabel yang dipengaruhi, variabel dependen, variabel terikat, atau variabel Y. Sedangkan variabel prediktor mempunyai istilah lain seperti variabel penjelas, variabel eksplanatorik, variabel independen, variabel bebas, atau variabel X.

Istilah regresi diperkenalkan oleh Francis Galton. Analisis regresi berkenaan dengan studi ketergantungan satu variabel, variabel tak bebas, pada satu atau lebih variabel lain, variabel yang menjelaskan, dengan maksud menaksir dan atau meramalkan nilai rata-rata hitung (mean) atau rata-rata (populasi) variabel tak bebas, dipandang dari segi nilai yang diketahui atau tetap (dalam pengambilan sampel berulang) variabel yang menjelaskan (Gujarati, 1978).

Dalam suatu penelitian, tidak cukup hanya melakukan pengamatan terhadap unit amatan dalam satu waktu tertentu saja, tetapi perlu juga mengamati unit tersebut pada berbagai periode waktu (Rahayu, 2017). Oleh karena itu, berkembanglah suatu metode regresi yang melibatkan unit *cross section* dan unit *time series*. Data silang (*cross section*) terdiri dari beberapa atau banyak objek, sering disebut responden dengan beberapa jenis data dalam suatu periode waktu tertentu. Sedangkan data runtun waktu (*time series*) biasanya meliputi satu objek tetapi meliputi beberapa periode. Metode regresi yang dapat digunakan untuk memodelkan data *cross section* dan data *time series* disebut metode regresi data panel. Regresi data panel akan memberikan hasil lebih baik dibanding regresi yang hanya menggunakan data *cross section* atau data *time series* saja. Menurut Baltagi (2005) terdapat beberapa keuntungan menggunakan data panel, diantaranya (1) mengendalikan heterogenitas individu, (2) data panel memberikan data yang lebih informatif, lebih variatif, kolinearitas antar variabel lebih sedikit, derajat kebebasan lebih tinggi, dan lebih efisien, (3) data panel lebih mampu mempelajari perubahan yang dinamis, (4) data panel lebih mampu mengidentifikasi dan mengukur pengaruh-pengaruh yang tidak dapat diobservasi pada data *cross section* murni dan data *time series* murni, (5) data panel lebih unggul dalam menguji model yang lebih rumit dibanding menggunakan data *cross section* saja atau data *time series* saja.

Pada kenyataannya, terkadang kondisi yang terjadi pada suatu lokasi mempengaruhi kondisi lainnya pada periode tertentu. Kondisi yang dipengaruhi oleh efek spasial dapat diatasi oleh regresi spasial. Efek spasial dibedakan menjadi dua bagian, yaitu *spatial dependence* dan *spatial heterogeneity*. Pada kasus ketergantungan spasial (*spatial dependence*) dikembangkan melalui model autoregresi spasial (*spatial autoregressive model*) dan model residual spasial (*spatial error model*). Sedangkan pada kasus keheterogenan spasial dikembangkan analisis regresi yang terboboti secara geografis yaitu *Geographically Weighted Regression* (GWR). *Geographically Weighted Regression* (GWR) didefinisikan sebagai pengembangan dari regresi dengan menambahkan faktor letak geografis dimana data tersebut didapatkan sehingga estimasi parameter yang dihasilkan akan bersifat lokal (Fotheringham et al., 2002). Setiap parameter regresi diestimasi di setiap titik lokasi geografis sehingga hubungan antara variabel respon (Y) dan variabel penjelas (X) bervariasi (tidak sama) di sepanjang lokasi (Lutfiani, dkk, 2017).

Pemodelan untuk data bertipe panel dan terdapat masalah heterogenitas spasial, dapat diatasi dengan model *Geographically Weighted Panel Regression* (GWPR) yang merupakan gabungan model *Geographically Weighted Regression* (GWR) dengan model regresi data panel. Pada model GWPR, unsur waktu dilibatkan pada model GWR (Qur'ani, 2014). GWPR yang merupakan penggabungan model GWR dengan regresi data panel akan menghasilkan model *fixed effect* GWPR atau *random effect* GWPR (Yu, 2010).

Beberapa penelitian yang telah dilakukan menggunakan *Geographically Weighted Panel Regression* antara lain Yu (2010) melakukan pengembangan metode untuk analisis spasial temporal dengan menggabungkan antara model GWR dan model regresi panel untuk pertama kalinya yaitu *Geographically Weighted Panel Regression* (GWPR) dengan *Fixed Effect Model*, yang diterapkan pada pengembangan wilayah perekonomian di Beijing. Hasil penelitian tersebut menyimpulkan bahwa model GWPR lebih baik daripada GWR *cross-sectional* maupun model data panel. Penelitian selanjutnya dilakukan oleh Bruna dan YU (2013) yang memodelkan serta mengestimasi persamaan upah *New Economic Geography* dengan model GWPR di Eropa. Kemudian Tabak, dkk (2013) menggunakan pendekatan *Geographically Weighted* pada data panel untuk kasus bank tabungan di Amerika. Cai, Yu dan Oppenheimer (2014) mengkaji model GWPR untuk mengetahui pengaruh variasi iklim terhadap produksi jagung di negara bagian Amerika Serikat. Qur'ani (2014) memodelkan GWR-Panel menggunakan *fixed effect model* tren waktu dengan pembobot *adaptive gaussian kernel* terhadap presentase penduduk miskin di Provinsi Jawa Timur. Rahayu, N (2017) mengkaji model GWPR untuk pemodelan persentase penduduk miskin Jawa Tengah menggunakan pembobot *adaptive bisquare*. Sedangkan Meutuah (2017) mengkaji model *Fixed Effect Geographically Weighted Panel Regression* untuk Indeks Pembangunan Manusia di Jawa Tengah menggunakan pembobot *fixed exponential kernel*. Warsito, dkk (2018) mengkaji model *Geographically Weighted Panel Regression* untuk menggambarkan data Indeks Pengukuran Polusi Udara menggunakan pembobot *fixed exponential kernel* yang hasilnya lebih baik daripada Regresi *Panel Fixed Effect*. Dan Jezria (2018) mengkaji model *Geographically Weighted Panel Regression* dengan pembobot *Fixed Gaussian Kernel* dan *Adaptive Gaussian Kernel* studi kasus pada presentase penduduk miskin Provinsi Jawa Tengah yang hasilnya model *Geographically Weighted Panel Regression* dengan pembobot *Adaptive Gaussian Kernel* merupakan model terbaik.

Sumber Daya Manusia (SDM) yang berkualitas merupakan salah satu tolok ukur dalam keberhasilan pembangunan. Suatu pembangunan diperlukan untuk mewujudkan upaya negara dalam meningkatkan kesejahteraan masyarakatnya. Pembangunan manusia adalah proses perluasan pilihan masyarakat. Pada prinsipnya, pilihan manusia sangat banyak jumlahnya dan berubah setiap saat. Tetapi pada semua level pembangunan, ada tiga pilihan yang paling mendasar yaitu untuk berumur panjang dan hidup sehat, untuk memperoleh pendidikan dan untuk memiliki akses terhadap sumber-sumber kubutuhan agar hidup secara layak.

Berdasarkan latar belakang di atas, maka penelitian ini membahas tentang bagaimana model *Geographically Weighted Panel Regression* dengan matriks pembobot *Adaptive Gaussian* dan *Adaptive Bisquare* untuk Indeks Pembangunan Manusia di Jawa Tengah. Untuk memudahkan perhitungan pemodelan data, maka penulis menggunakan bantuan dengan *software* R.

1.2 Rumusan Masalah

Permasalahan yang dibahas dalam penulisan skripsi ini adalah:

1. Bagaimana model *Geographically Weighted Panel Regression* yang terbentuk pada data Indeks Pembangunan Manusia di Provinsi Jawa Tengah dengan matriks pembobot *Adaptive Gaussian* ?
2. Bagaimana model *Geographically Weighted Panel Regression* yang terbentuk pada data Indeks Pembangunan Manusia di Provinsi Jawa Tengah dengan matriks pembobot *Adaptive Bisquare* ?
3. Model *Geographically Weighted Panel Regression* manakah yang terbaik antara matriks pembobot *Adaptive Gaussian* dan matriks pembobot *Adaptive Bisquare*?
4. Variabel-variabel apa saja yang mempengaruhi Indeks Pembangunan Manusia di Jawa Tengah?

1.3 Batasan Masalah

Dalam penulisan skripsi ini, permasalahan dibatasi pada:

1. Pembobot yang digunakan pada model *Geographically Weighted Panel Regression* yaitu *Adaptive Gaussian* dan *Adaptive Bisquare*

2. Kasus yang diterapkan adalah persentase indeks pembangunan manusia di Jawa Tengah dengan periode penelitian dari tahun 2015-2017
3. Variabel-variabel yang digunakan yaitu umur harapan hidup saat lahir (UHH), harapan lama sekolah (HLS), rata-rata lama sekolah (RLS), pengeluaran per kapita disesuaikan

1.4 Tujuan Penelitian

Tujuan dari penelitian ini adalah:

1. Mengetahui model *Geographically Weighted Panel Regression* yang terbentuk pada data Indeks Pembangunan Manusia di Provinsi Jawa Tengah dengan matriks pembobot *Adaptive Gaussian*.
2. Mengetahui model *Geographically Weighted Panel Regression* yang terbentuk pada data Indeks Pembangunan Manusia di Provinsi Jawa Tengah dengan matriks pembobot *Adaptive Bisquare*.
3. Mengetahui model terbaik diantara model *Geographically Weighted Panel Regression* dengan matriks pembobot *Adaptive Gaussian* dan model *Geographically Weighted Panel Regression* dengan matriks pembobot *Adaptive Bisquare*.
4. Mengidentifikasi variabel-variabel yang mempengaruhi Indeks Pembangunan Manusia di Jawa Tengah.

1.5 Manfaat Penelitian

Manfaat yang diharapkan dari penulisan ini adalah sebagai berikut:

1. Bagi penulis

   Menambah dan memperkaya pengetahuan *Geographically Weighted Panel Regression* dengan matriks pembobot *Adaptive Gaussian* dan *Adaptive Bisquare* untuk Indeks Pembangunan Manusia di Jawa Tengah.

2. Bagi Mahasiswa Matematika

   Menambah pengetahuan mengenai model *Geographically Weighted Panel Regression* dengan matriks pembobot *Adaptive Gaussian* dan *Adaptive Bisquare*

1.6 Sistematika Penulisan

Sistematika penulisan skripsi ini adalah sebagai berikut:

1. Bab 1 Pendahuluan

   Bab ini berisi latar belakang masalah, permasalahan, pembatasan masalah, tujuan penelitian, manfaat penelitian, serta sistematika penulisan.

2. Bab 2 Tinjauan Pustaka

   Tinjauan pustaka berisi kajian teori dan hasil-hasil penelitian terdahulu yan menjadi kerangka pikir penyelesaian masalah penelitian yang disajikan ke dalam beberapa sub-bab.

3. Bab 3 Metodologi Penelitian

   Bagian ini berisi penemuan masalah, perumusan masalah, studi pustaka, pengumpulan data, prosedur penelitian dan penarikan kesimpulan.

4. Bab 4 Hasil dan Pembahasan

   Bagian ini berisi tentang uraian metode dan hasil model *Geographically Weighted Panel Regression* dengan matriks pembobot *Adaptive Gaussian* dan *Adaptive Bisquare* untuk Indeks Pembangunan Manusia di Jawa Tengah.

5. Bab 5 Penutup

   Pada bab ini berisi simpulan dari hasil penelitian serta saran-saran sebagai masukan untuk pengembangan penelitian selanjutnya.

BAB 2

TINJAUAN PUSTAKA

2.1 Landasan Teori

2.1.1 Regresi Linear

Regresi merupakan suatu metode untuk mengukur besarnya pengaruh variabel respon terhadap prediktor (Gujarati D., 2004). Dalam penggunaan regresi, terdapat beberapa asumsi dasar yang dapat menghasilkan estimator linier tak bias yang terbaik model regresi yang diperoleh dari metode kuadrat terkecil (*ordinary least squares*). Dengan asumsi-asumsi tertentu, metode OLS mempunyai beberapa sifat statistik yang sangat menarik yang membuatnya menjadi satu metode analisis regresi yang kuat dan populer. Asumsi-asumsi dasar itu dikenal dengan asumsi klasik yang terdiri atas homoskedastisitas, non-autokorelasi, non-multikolinearitas, dan normalitas residual. Bentuk paling sederhana dari hubungan stokastik antara dua variabel X dan Y disebut model regresi linear.

$$Y_i = \alpha + \beta X_i + U_i \ (i = 1, \dots, n) \tag{2.1}$$

Y disebut variabel terikat (*dependent variabel*), X adalah variabel bebas (*independent variable*), U adalah variabel gangguan stokastik (*stochastic disturbance*), α dan β adalah parameter-parameter regresi. Subskrip i menunjukkan pengamatan yang ke-i. Parameter α dan β ditaksir atas dasar yang tersedia untuk variabel X dan Y.

Persamaan umum untuk model regresi linear dengan sampel n dan jumlah prediktor p adalah sebagai berikut :

$$y_i = \beta_0 + \beta_1 x_{i1} + \cdots + \beta_p x_{ip} + \varepsilon_i, \qquad i = 1,2,\dots,n \tag{2.2}$$

dengan,

β_0 : intersep

$\beta_1, \beta_2, \dots, \beta_k$: *slope*

ε_i : *error* $\varepsilon_i \sim N(0, \sigma^2)$

i : observasi (pengamatan ke i)

n : banyaknya observasi

Dalam bentuk matriks, persamaan umum model regresi linear adalah

$$Y = \beta X + \varepsilon \tag{2.3}$$

dengan,

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}; X = \begin{bmatrix} 1 & x_{11} & \dots & x_{1p} \\ 1 & x_{21} & \dots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & \cdots & x_{np} \end{bmatrix};\ \beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_p \end{bmatrix};\ \varepsilon = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix}$$

2.1.2 Asumsi Klasik Model Regresi

Metode OLS dibangun menggunakan beberapa asumsi klasik, yaitu tentang masalah multikolinearitas, heteroskedastisitas, autokorelasi dan normalitas residual.

a. Multikolinearitas

Hubungan linier antara beberapa atau semua variabel prediktor didalam model regresi disebut multikolinearitas. Salah satu asumsi model regresi linier klasik adalah tidak terdapat multikolinearitas diantara variabel-variabel prediktor yang masuk dalam model (Gujarati D. , 2004). Multikolinearitas terjadi karena terdapat korelasi atau hubungan linear yang kuat diantara beberapa variabel prediktor, sehingga sulit untuk memisahkan pengaruh antara variabel-variabel itu secara individu terhadap variabel dependennya (Pangestika, 2015).

Beberapa indikator yang dapat digunakan dalam mendeteksi multikolinearitas adalah sebagai berikut (Gujarati dalam Yuniarti, 2010):

1. Jika R^2 sangat tinggi tetapi tidak ada satupun koefisien regresi signifikan secara statistik atas pengujian t.
2. Jika koefisien korelasi antara dua variabel prediktor cukup tinggi
3. Jika R^2 sangat tinggi tetapi korelasi parsial rendah.
4. Meregresikan tiap variabel x_k atas sisa variabel x dalam model dan mengetahui koefisien determinasi yang berhubungan dengan R_k^2. Suatu R_k^2 yang tinggi akan menguraikan bahwa x_k sangat berkorelasi dengan sisa variabel x.

Ada beberapa metode untuk mendeteksi multikolinearitas, diantaranya ialah menghitung nilai *Variance Inflation Factors* (VIF) dengan rumus $(VIF)_j = \frac{1}{1-R_j^2}$ dengan R_j^2 adalah nilai koefisien determinasi variabel ke j. Jika $(VIF)_j > 10$ maka mengindikasikan bahwa terdapat multikolinearitas (Isbiyantoro, dkk, 2014).

b. Heteroskedastisitas

Salah satu asumsi penting dari model regresi linier adalah bahwa *error* yang muncul dalam fungsi regresi adalah homoskedastik, yaitu mempunyai varians yang sama (Gujarati D. , 2004).

$$E(\varepsilon_i^2) = \sigma^2, \quad i = 1, 2, \dots, n \tag{2.4}$$

Pelanggaran atas asumsi ini disebut heteroskedastisitas, yaitu varians *error* tidak sama. Ada beberapa cara untuk mendeteksi ada tidaknya masalah heteroskedastisitas seperti Uji *Park*, Uji *Glejser*, Uji *White*, Uji *Breusch-Pagan-Goldfrey*, dll. Salah satu cara mendeteksi heteroskedastisitas yaitu dengan menggunakan uji *Glejser*. Pengujian ini dilakukan dengan meregresikan nilai absolut dari ε_i, yaitu $|\varepsilon_i|$ terhadap semua variabel prediktor yang digunakan. Jika variabel prediktornya signifikan mempengaruhi nilai absolut error, berarti bahwa dalam data tersebut terdapat kasus heteroskedastisitas (Isbiyantoro, dkk, 2014).

c. Autokorelasi

Menurut Gujarati (1978), istilah autokorelasi dapat didefinisikan sebagai korelasi antara anggota serangkaian observasi yang diurutkan menurut waktu (seperti dalam data runtun waktu) atau ruang (seperti dalam data *cross-sectional*). Dalam model regresi linier klasik, diasumsikan bahwa autokorelasi seperti itu tidak terdapat dalam *error*.

$$E\left(\varepsilon_i \varepsilon_j\right) = 0, \quad \text{untuk } i \neq j \tag{2.5}$$

Salah satu metode yang dapat digunakan untuk mendeteksi autokorelasi yaitu dengan uji Durbin-Watson. Model ini diperkenalkan oleh J. Durbin dan G.S Watson tahun 1951. Deteksi autokorelasi dilakukan dengan membandingkan nilai statistik Durbin Watson hitung dengan Durbin Watson tabel.

d. Normalitas

Regresi linier klasik mengasumsikan bahwa tiap error (ε_i) berdistribusi secara normal dengan rata-rata $E(\varepsilon_i) = 0$, varians $E(\varepsilon_i^2) = \sigma^2$, dan $E\left(\varepsilon_i \varepsilon_j\right) = 0$ untuk $i \neq j$. Secara ringkas dapat ditulis

$$\varepsilon_i \sim N(0, \sigma^2) \tag{2.6}$$

Menurut Gujarati D. (2004), dengan asumsi kenormalan, estimator OLS mempunyai sifat tidak bias, efisien dan konsisten. Salah satu metode yang dapat digunakan untuk menguji normalitas yaitu uji *Jarque-Bera* (JB).

2.1.3 Regresi Data Panel

Data panel merupakan data gabungan antara data *cross section* dan data *time series*. Menurut Jaya, I. G., dan Sunengsih (2009) dalam Meutuah (2017) analisis regresi data panel adalah regresi yang didasarkan pada data panel untuk mengamati hubungan antara satu variabel dependen dengan satu atau lebih variabel independen. Model regresi panel yang hanya dipengaruhi oleh salah satu unit saja (unit *cross-sectional* atau unit waktu) disebut model komponen satu arah, sedangkan model regresi panel yang dipengaruhi oleh kedua unit (unit *cross-sectional* dan unit waktu) disebut model komponen dua arah (Pangestika, 2015).

Unit *cross section* dapat berupa individu, rumah tangga, perusahaan, *region*, negara dan lain-lain, sedangkan unit *time series* dapat berupa harian, bulanan, tahunan dan sebagainya. Data panel memiliki struktur khusus yaitu setiap baris pada data sesuai dengan individu tertentu dan periode waktu (Croissant, 2008). Pada data panel, setiap unit *cross section* diobservasi secara berulang-ulang selama beberapa waktu. Jika dipunyai individu (dimana $i = 1,2,3, \dots, N$) dalam periode pengamatan selama waktu (dimana $t = 1,2,3, \dots, T$), maka dengan data panel dipunyai total observasi sebanyak NT. Model umum regresi data panel adalah (Baltagi, 2005)

$$y_{it} = \alpha + \beta X_{it}^{T} + \mu_{it} \tag{2.7}$$

dengan:

y_{it} : variabel dependen pada unit ke-i dan waktu ke-t

α : koefisien intersep yang merupakan skalar

β : vektor parameter

X_{it}^{T} : $\left(X_{1it}, X_{21t}, \dots, X_{pit}\right)$variabel independen untuk pengamatan ke-i pada periode waktu ke-t berukuran $1 \times p$

μ_{it} : residual pada unit ke-i dan waktu ke-t

Model komponen residual satu arah untuk model regresi data panel didefinisikan pada persamaan berikut:

$$\mu_{it} = \mu_i + \varepsilon_{it} \tag{2.8}$$

Sehingga model umum data panel menjadi

$$y_{it} = \alpha + \mu_i + \beta X_{it}^{T} + \varepsilon_{it} \tag{2.9}$$

Dimana μ_i merupakan pengaruh spesifik individu yang tidak diamati (Baltagi, 2005) dan ε_{it} merupakan residual pengamatan ke-i pada periode waktu ke-t. Secara umum, menggunakan data panel akan dihasilkan intersep dan slope koefisien yang berbeda-beda pada setiap individu dan setiap periode waktu (Rahayu, 2017).

Tabel 2. 1 Struktur Data Panel Secara Umum

Lokasi (i)	Tahun (t)	Variabel Respon (y_{it})	Variabel Prediktor (x_{1it})	Variabel Prediktor (x_{2it})	...	Variabel Prediktor (x_{pit})
1	1	y_{11}	$x_{1.11}$	$x_{2.11}$	...	$x_{p.11}$
2	1	y_{21}	$x_{1.21}$	$x_{2.21}$	...	$x_{p.21}$
...	...	...	...	...	...	...
N	1	y_{N1}	$x_{1.N1}$	$x_{2.N1}$	...	$x_{p.N1}$
1	2	y_{12}	$x_{1.12}$	$x_{2.12}$	...	$x_{p.12}$
2	2	y_{22}	$x_{1.22}$	$x_{2.22}$	...	$x_{p.22}$
...	...	...	...	...	...	...
N	2	y_{N2}	$x_{1.N2}$	$x_{2.N2}$	...	$x_{p.N2}$
...	...	...	...	...	...	...
...	...	...	...	...	...	...
...	...	...	...	...	...	...
1	T	y_{1T}	$x_{1.1T}$	$x_{2.1T}$	...	$x_{p.1T}$
2	T	y_{2T}	$x_{1.2T}$	$x_{2.2T}$	...	$x_{p.2T}$
...	...	...	...	...	...	...
N	T	y_{NT}	$x_{1.NT}$	$x_{2.NT}$	...	$x_{p.NT}$

Sumber: Rahayu, N.S (2017) dimodifikasi dari Park (2005)

2.1.4 Pendekatan dan Model Estimasi pada Model Regresi Data Panel

Terdapat 3 pendekatan yang biasa digunakan dalam mengestimasi model regresi data panel, yaitu pendekatan *common effect model, fixed effect model, dan random effect model.*

2.1.4.1 *Common Effect Model* (CEM)

Pada metode *common effect model*, seluruh data digabungkan tanpa memperdulikan waktu dan tempat kejadian, sehingga diasumsikan bahwa perilaku data antar unit *cross-section* sama dalam berbagai kurun waktu (Rahmadeni, dan Nindya Wulandari, 2017). Menurut Baltagi (2005) model tanpa pengaruh individu (*common effect*) adalah pendugaan yang menggabungkan (*pooled*) seluruh data *time series* dan *cross section* dan menggunakan pendekatan OLS (*Ordinary Least Square*) untuk menduga parameternya. Menurut Winarno (dalam Latuconsina, 2017) kelemahan model CEM yaitu adanya ketidaksesuaian model dengan keadaan sesungguhnya, dimana kondisi tiap objek saling berbeda, bahkan satu objek pada suatu waktu akan sangat berbeda dengan kondisi objek tersebut pada waktu yang lain. Metode OLS merupakan salah satu metode populer untuk menduga nilai parameter dalam persamaan regresi linear. Secara umum, persamaan modelnya dituliskan sebagai berikut (Greene, 2000).

$$Y_{it} = \alpha + \beta X_{it}^{T} + \varepsilon_{it} \tag{2.10}$$

dengan:

Y_{it} : Variabel respon pada unit observasi ke-i dan waktu ke-t

X_{it}^{T} : $(X_{1it}, X_{21t}, \dots, X_{pit})$variabel independen untuk pengamatan ke-i pada periode waktu ke-t berukuran $1 \times p$

β : Koefisien *slope* atau koefisien arah

α : *Intercept* model regresi

ε_{it} : Galat atau komponen *error* pada unit observasi ke-i dan waktu ke-t

2.1.4.2 *Fixed Effect Model* (FEM)

Menurut Hsiao (dalam Rizki, dkk, 2015) *Fixed Effect Model* (FEM) merupakan model yang mengasumsikan bahwa koefisien intersep berbeda tiap individu. Menurut Gujarati (2004), salah satu cara untuk memperhatikan unit *cross section* adalah dengan mengijinkan nilai intersep berbeda-beda untuk setiap unit *cross section* tetapi masih mengasumsikan *slope* koefisien tetap. Menurut Wooldridge (2002), salah satu pendekatan yang dapat digunakan untuk mengestimasi model *fixed effect* yaitu model *fixed effect within transformation*. Pendekatan ini dilakukan dengan cara mengeliminasi efek unit *cross-section* (α_i), kemudian nilai variabel dependen dan variabel independen dari setiap unit *cross-section* dirata-ratakan terhadap waktu. Model *fixed effect within transformation* dan persamaan rata-rata dinyatakan dalam persamaan sebagai berikut

$$y_{it} = \alpha_i + \sum_{k=1}^{p} \beta_k X_{kit} + \varepsilon_{it}$$

$$\bar{y}_i = \alpha_i + \sum_{k=1}^{p} \beta_k \bar{X}_{ki} + \bar{\varepsilon}_i$$

Kemudian persamaan model *fixed effect within transformation* dikurangkan terhadap persamaan rata-rata, sehingga diperoleh persamaan berikut

$$y_{it} - \bar{y}_i = \alpha_i - \alpha_i + \sum_{k=1}^{p} \beta_k (X_{kit} - \bar{X}_{ki}) + \varepsilon_{it} - \bar{\varepsilon}_i$$

$$y_{it} - \bar{y}_i = \sum_{k=1}^{p} \beta_k (X_{kit} - \bar{X}_{ki}) + \varepsilon_{it} - \bar{\varepsilon}_i$$

Persamaan tersebut dapat disederhanakan menjadi

$$y_{it}^* = \textstyle\sum_{k=1}^{p} \beta_k X_{kit}^* + \varepsilon_{it}^* \qquad (2.11)$$

dengan:

$y_{it}^* = y_{it} - \bar{y}_i$

$X_{itk}^* = X_{itk} - \bar{X}_{ik}$

$\varepsilon_{it}^* = \varepsilon_{it} - \bar{\varepsilon}_i$

Estimasi model *fixed effect within transformation* dapat dilakukan dengan *metode Ordinary Least Squares* (OLS).

2.1.4.3 *Random Effect Model* (REM)

Random Effect Model (REM) merupakan metode yang mengasumsikan perbedaan intersep pada unit *cross section* adalah variabel acak. Persamaan REM diformulasikan sebagai berikut (Greene, 2000)

$$Y_{it} = (\alpha + \mu_i) + \beta X_{it}^T + \varepsilon_{it} \qquad (2.12)$$

dimana :

Y_{it} : Variabel respon pada unit observasi ke-i dan waktu ke-t

X_{it}^T : $(X_{1it}, X_{21t}, \dots, X_{pit})$variabel independen untuk pengamatan ke-i pada periode waktu ke-t berukuran $1 \times p$

β : Koefisien *slope* atau koefisien arah

α : *Intercept* model regresi

ε_{it} : Galat atau komponen *error* pada unit observasi ke-i dan waktu ke-t

μ_i : Komponen *error cross section*

Adapun asumsi yang digunakan untuk komponen error tersebut adalah: (2.13)

$$E[\varepsilon_{it}|X] = E[u_i|X] = 0$$

$$E[\varepsilon_{it}^2|X] = \sigma_\varepsilon^2$$

$$E[u_{it}^2|X] = \sigma_u^2$$

$$E\left[\varepsilon_{it}u_j\middle|X\right] = 0 \text{ untuk semua } i, t, \text{ dan } j$$

$$E\left[\varepsilon_{it}\varepsilon_{js}\middle|X\right] = 0 \text{ jika } t \neq s \text{ atau } i \neq j$$

$$E\left[u_i u_j\middle|X\right] = 0 \text{ jika } i \neq j$$

Asumsi dalam model REM adalah *error* ε_{it} tidak saling berkorelasi dan tidak berautokorelasi antar unit *cross section* maupun antar unit *time series*. Metode estimasi model REM adalah *Generalized Least Square* (GLS).

2.1.5 Pemilihan Model Estimasi Regresi Data Panel

2.1.5.1 Uji Chow

Uji ini digunakan untuk memilih salah satu model pada regresi data panel, yaitu antara model efek tetap (*fixed effect model*) dengan model koefisien tetap (*common effect model*). Prosedur pengujiannya sebagai berikut (Baltagi, 2005).

Hipotesis:

$H_0 = \alpha_1 = \alpha_2 = \cdots = \alpha_n = 0$ (efek unit cross section secara keseluruhan tidak berarti)

$H_1 =$ minimal ada satu $\alpha_i \neq 0; i = 1, 2, \dots, n$ (efek wilayah berarti)

Statistik uji yang digunakan merupakan uji F, yaitu

$$F_{hitung} = \frac{[RRSS - URSS]/(n-1)}{URSS/(nT-n-K)} \quad (2.14)$$

Keterangan:

n : Jumlah individu (*cross section*)

T : Jumlah periode waktu (*time series*)

K : Jumlah variabel penjelas

$RRSS$: *restricted residual sums of squares* yang berasal dari model koefisien tetap

$URSS$: *unrestricted residual sums of squares* yang berasal dari model efek tetap

Jika nilai $F_{hitung} > F_{n-1, nT-n-K}$ atau $p - value < \alpha$ (taraf signifikansi), maka tolak hipotesis awal (H_0) sehingga model yang terpilih adalah model efek tetap.

2.1.5.2 Uji Hausman

Uji Hausman digunakan untuk memilih *random effect model* dengan *fixed effect model*. Uji ini bekerja dengan menguji apakah terdapat hubungan antara galat pada model (galat komposit) dengan satu atau lebih variabel penjelas (independen) dalam model. Hipotesis awalnya adalah tidak terdapat hubungan antara galat model dengan satu atau lebih variabel penjelas. Prosedur pengujiannya sebagai berikut (Baltagi, 2008: 310).

Hipotesis:

H_0: korelasi $(X_{it}, \varepsilon_{it}) = 0$ (efek *cross-sectional* tidak berhubungan dengan regresor lain)

H_1: korelasi $(X_{it}, \varepsilon_{it}) \neq 0$ (efek *cross-sectional* berhubungan dengan regresor lain)

Statistik uji yang digunakan adalah uji *chi-squared* berdasarkan kriteria *Wald*, yaitu

$$W = \hat{q}'[var(\hat{q}')]^{-1}\hat{q} \tag{2.15}$$

$$\Leftrightarrow W = \left(\hat{\beta}_{MET} - \hat{\beta}_{MEA}\right)' \left[var\left(\hat{\beta}_{MET} - \hat{\beta}_{MEA}\right)\right]^{-1} (\hat{\beta}_{MET} - \hat{\beta}_{MEA})$$

Keterangan:

$\hat{\beta}_{MET}$: vektor estimasi *slope* model efek tetap

$\hat{\beta}_{MEA}$: vektor estimasi *slope* model efek acak

Jika nilai $W > X^2_{(\alpha,K)}$ atau nilai *p-value* kurang dari taraf signifikansi yang ditentukan, maka tolak hipotesis awal (H_0) sehingga model yang terpilih adalah model efek tetap

2.1.5.3 Uji Lagrange Multiplier

Menurut Rahayu, N. S (2017), untuk mengetahui apakah model *Random Effect* lebih baik daripada model *Common Effect*. Hipotesis yang digunakan adalah (Greene, 2000):

$H_0 : \sigma_u^2 = 0$ (model CEM)

$H_1 : \sigma_u^2 \neq 0$ (model REM)

Statistik uji:

$$LM = \frac{NT}{2(T-1)}\left[\frac{\sum_{i=1}^{N}[\sum_{t=1}^{T}\varepsilon_{it}]^2}{\sum_{i=1}^{N}\sum_{t=1}^{T}\varepsilon_{it}^2} - 1\right]^2 \quad (2.16)$$

Statistik uji LM mengikuti distribusi *Chi-Square* dengan derajat bebas 1. Jika nilai uji LM lebih besar daripada $\chi^2_{(1)}$ maka H_0 ditolak, yang berarti model REM lebih tepat.

2.1.6 Pengujian Signifikansi Parameter Data Panel

Menurut Rahayu, N. S (2017) pengujian signifikansi pada regresi data panel pada dasarnya identik dengan pengujian signifikansi pada regresi linier berganda. Pengujian ini dimaksudkan untuk mengetahui apakah parameter yang terdapat dalam model regresi data panel telah menunjukkan hubungan yang tepat antara variabel prediktor dengan variabel respon serta untuk mengetahui apakah model yang memuat parameter tersebut telah mampu menggambarkan keadaan data yang sebenarnya, ada dua tahap pengujian parameter dalam regresi data panel, yaitu pengujian secara serentak (*overall*) dan pengujian secara parsial.

2.1.7 Aspek Data Spasial

Analisis spasial dilakukan jika data yang digunakan memenuhi aspek spasial. Efek spasial dibagi menjadi dua yaitu memiliki sifat *error* yang saling berkorelasi (*spatial dependence*) dan memiliki heterogenitas spasial (*spatial heterogeneity*).

2.1.7.1 *Spatial Dependence*

Menurut Rahayu, N.S (2017) salah satu masalah yang terjadi karena perbedaan lokasi adalah adanya ketergantungan spasial. Hukum pertama tentang geografi yang dikemukakan oleh Tobler dalam Anselin (1988) mengatakan bahwa "*Everything is related to everything else, but near thing are more related than distant things*". Segala sesuatu saling berhubungan satu dengan yang lainnya, tetapi sesuatu yang dekat lebih mempunyai pengaruh daripada sesuatu yang jauh. Pengujian s*patial dependence* dilakukan untuk melihat apakah pengamatan di suatu lokasi berpengaruh terhadap pengamatan di lokasi lain yang berdekatan (Anselin, 1988).

2.1.7.2 *Spatial Heterogeneity*

Menurut Munikah, dkk (2014), heterogenitas spasial adalah suatu kondisi pada suatu wilayah yang memiliki perbedaan kondisi antar satu lokasi dengan lokasi lain, yang ditinjau dari segi geografis, keadaan sosial budaya maupun hal lain yang dapat menimbulkan kondisi heterogenitas spasial pada lokasi yang diteliti. Pengujian heterogenitas spasial dilakukan dengan menggunakan statistik uji *Breusch-Pagan*. Hipotesisnya adalah:

$H_0: \sigma_1^2 = \sigma_2^2 = \cdots = \sigma_n^2 = \sigma^2$

H_1: minimal ada satu $\sigma_i^2 \neq \sigma^2$

Nilai dari *Breusch Pagan test* adalah :

$$BP = \left(\frac{1}{2}\right) \mathbf{f^T Z (Z^T Z)^{-1} Z^T f} \quad \sim \chi^2_{(p)} \tag{2.17}$$

dimana:

$\mathbf{f} = (f_1, f_2, \dots, f_n)^T$ dengan $\mathbf{f} = \left(\frac{e_i^2}{\sigma^2} - \mathbf{1}\right)$, $\varepsilon_i = y_i - \hat{y}_i$ adalah *least square* residual untuk pengamatan ke-i. $\mathbf{Z}$ merupakan matriks berukuran

$n \times (p+1)$ yang berisi vektor yang sudah dinormal standarkan untuk setiap pengamatan.

e_i : galat least square pengamatan ke i

e : vektor galat e_i

σ^2 : ragam galat e_i

T : $Tr[W^T W + W^2]$

W : matriks pembobot W_{ij}

Tolak H_0 bila $BP > \chi^2_{(p)}$ atau jika *p-value* $< \alpha$ dengan p adalah banyaknya prediktor.

2.1.8 Geographically Weighted Regression

GWR merupakan pengembangan dari model regresi linear OLS menjadi model regresi terboboti dengan memperhatikan efek spasial, sehingga menghasilkan penduga parameter yang hanya dapat digunakan untuk memprediksi setiap titik atau lokasi di mana data tersebut diamati dan disimpulkan (Fotheringham, dkk, 2002). Menurut Brivand (2017) *Geographically Weighted Regression* (GWR) merupakan teknik eksplorasi yang dimaksudkan untuk menunjukkan dimana non-stasioneritas terjadi di peta. Jika dibandingkan dengan metode lain, teknik GWR relatif lebih sederhana namun bermanfaat secara geografis untuk mengeksplorasi nonstasioner spasial (Leung, 2000). Menurut Rahayu, N. S (2017), parameter untuk model regresi di setiap lokasi akan menghasilkan nilai yang berbeda-beda. Model GWR ditulis sebagai berikut:

$$y_i = \beta_0(u_i, v_i) + \sum_{k=1}^{p} \beta_k(u_i, v_i) x_{ik} + \varepsilon_i, \quad i = 1,2,\dots,n \qquad (2.18)$$

Dimana

y_i : nilai observasi variabel respon ke-i

x_{ik} : nilai observasi variabel prediktor ke-k pada pengamatan ke-i

β : koefisien regresi

(u_i, v_i) : titik koordinat lokasi i

ε_i : *error* ke-i

Bentuk error $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$ diasumsikan independen, identik, dan mengikuti distribusi normal dengan mean nol dan variasi konstan ($\varepsilon_i \sim iid\ N(0, \sigma^2)$).

2.1.9 Koordinat Spasial

Variabel koordinat spasial *longitude* dan *latitude* merupakan variabel yang digunakan dalam pembobotan pada pembentukan model GWR. Koordinat *latitude* dan *longitude* dari suatu pengamatan, akan membangun struktur kedekatan yang disebut sebagai pengamatan ketetanggaan (Lesage, 1999). *Longitude* adalah garis membujur yang menghubungkan antara sisi utara dan sisi selatan bumi (kutub) yang digunakan untuk mengukur sisi barat-timur koordinat suatu titik di belahan bumi. Sedangkan *latitude* adalah garis melintang diantara kutub utara dan selatan yang menghubungkan antara sisi timur dan barat bagian bumi yang dijadikan ukuran dalam mengukur sisi utara-selatan koordinat suatu titik di belahan bumi (Isbiyantoro, dkk, 2014).

2.1.10 Fungsi Pembobot Model GWR

Peran pembobot pada model GWR sangat penting karena nilai pembobot tersebut mewakili letak data observasi satu dengan lainnya

(Rahayu, N. S, 2017). Menurut Gwarda (2018), setiap persamaan disesuaikan menggunakan pembobot yang berbeda dari pengamatan yang terkandung dalam data. Diasumsikan bahwa pengamatan yang dekat satu sama lain memiliki pengaruh yang lebih besar pada setiap estimasi parameter daripada pengamatan yang mempunyai jarak lebih jauh, seperti pada Hukum Tobler. Terdapat beberapa literatur yang dapat digunakan untuk menentukan besarnya pembobot untuk masing-masing lokasi yang berbeda pada model GWR, diantaranya.

a. Fungsi Invers Jarak (*Invers Distance Function*)

   Misalkan $1/d_{ij}$ adalah fungsi invers jarak yang mewakili pembobot antara lokasi (u_i, v_i) dan lokasi (u_j, v_j) $\left(d_{ij}\right)^2 = \left(u_i - u_j\right)^2 + \left(v_i - v_j\right)^2$ adalah jarak *Eucledian* antara lokasi (u_i, v_i) dan lokasi (u_j, v_j). Pembobot ini dapat ditulis

$$w_{ij} = \begin{cases} 1, jika\ d_{ij} \leq h \\ 0, jika\ d_{ij} > h \end{cases} \tag{2.19}$$

b. Fungsi Pembobot Kernel (*Kernel Function*)

   Pembobot yang terbentuk dengan menggunakan fungsi kernel ini dapat dibedakan menjadi :

   1. Fungsi *Kernel Fixed*, yaitu fungsi *kernel* yang memiliki *bandwidth* yang sama pada setiap lokasi pengamatan. Fungsi kernel ini diantaranya adalah

(i) *Gaussian*

Menggunakan kernel *Gaussian*, data pembobot akan menurun berdasarkan pada kurva *Gaussian* karena jarak antara i dan j, d_{ij}, meningkat (Pijnenburg, 2013).

$$w_{ij} = \exp\left(-\frac{1}{2}\left(\frac{d_{ij}}{h}\right)^2\right) \tag{2.20}$$

(ii) *Bisquare*

Kernel *Bisquare* bersifat kontinu, jika nilai *bandwidth* melebihi jarak i dan j (d_{ij}) maka nilai pembobot diatur ke nol (Pijnenburg, 2013).

$$w_{ij} = \begin{cases} \left(1 - \left(\frac{d_{ij}}{h}\right)^2\right)^2, untuk\ d_{ij} \leq h \\ 0, untuk\ lainnya \end{cases} \tag{2.21}$$

(iii) *Tricube*

$$w_{ij} = \begin{cases} \left(1 - \left(\frac{d_{ij}}{h}\right)^3\right)^3, untuk\ d_{ij} \leq h \\ 0, untuk\ lainnya \end{cases} \tag{2.22}$$

d_{ij} adalah jarak antara titik di lokasi i dan lokasi j yang diperoleh dari jarak *euclidean* $(d_{ij})^2 = (u_i - u_j)^2 + (v_i - v_j)^2$. Sementara h adalah parameter non negatif yang dikenal dengan *bandwidth* atau parameter penghalus.

2. Fungsi Kernel Adaptif, yaitu fungsi kernel yang memiliki *bandwidth* yang berbeda pada masing-masing lokasi pengamatan. Fungsi kernel ini diantaranya adalah

a. *Adaptive Gaussian*

Menurut Susanti, D. S, dkk (2016), fungsi *adaptive gaussian kernal* yang diusulkan oleh Brunsdon et al (1998) memiliki persamaan:

$$w_{ij} = \exp\left(-\frac{1}{2}\left(\frac{d_{ij}}{h_i}\right)^2\right) \tag{2.23}$$

Dimana h_i adalah parameter non negatif yang biasa disebut sebagai *bandwidth*. Nilai pembobot dari suatu data akan mendekati 1 jika jaraknya berdekatan atau berhimpitan dan akan semakin mengecil sehingga mendekati 0 jika jaraknya semakin jauh.

b. *Adaptive Bisquare*

Menurut Susanti, D. S, dkk (2016), fungsi *adaptive bisquare* yang diusulkan oleh Brundson et al (1998) memiliki persamaan

$$w_{ij} = \begin{cases} \left(1 - \left(\frac{d_{ij}}{h_i}\right)^2\right)^2, untuk\ d_{ij} \leq h_i \\ 0, untuk\ lainnya \end{cases} \tag{2.24}$$

Yang merupakan fungsi pembobot kontinu dan menyerupai fungsi gaussian sampai jarak sejauh h_i dari lokasi pengamatan ke-i dan bernilai 0 untuk lokasi data yang memiliki jarak lebih besar daripada h_i. h_i merupakan *bandwidth* yang menunjukkan jumlah atau proporsi dari observasi untuk dimasukkan pada estimasi regresi di lokasi pengamatan ke-i.

2.1.11 Penentuan Bandwidth

Bandwidth analog dengan radius suatu lingkaran, sehingga lokasi pengamatan yang berada di dalam radius suatu lingkaran tersebut masih dianggap berpengaruh dalam pembentukan parameter pada satu titik lokasi pengamatan (Baltagi, 2005). Estimasi parameter pada GWR sebagian bergantung pada fungsi pembobot yang dipilih (Charlton & Fotheringham et.al., 2009). Pada fungsi pembobot *adaptive gaussian kernel* tampak bahwa jika nilai *d* bertambah besar maka nilai bobotnya mendekati 0 atau model yang dihasilkan akan mendekati model *Ordinary Least Square* (OLS). Jika nilai *d* menunjukkan jarak terjauh antar lokasi pengamatan, maka model yang dihasilkan akan sama dengan model OLS yaitu yang disebut dengan Model Regresi Global (Susanti, D. S, dkk, 2016).

Jika nilai *bandwidth* (h) mendekati tak terhingga, maka pembobot (w_{ij}) yang dihasilkan antar lokasi pengamatan akan mendekati angka 1, sehingga parameter yang diduga akan seragam dan model GWR yang dihasilkan akan mendekati model OLS. Sebaliknya jika nilai *bandwidth* semakin kecil, pendugaan parameter akan semakin tergantung pada lokasi pengamatan yang memiliki jarak yang dekat dengan lokasi pengamatan ke-i, sehingga nilai variansi yang dihasilkan akan semakin besar. Permasalahan yang harus diselesaikan adalah bagaimana menentukan nilai *bandwidth* atau fungsi pembobot yang tepat pada pemodelan GWR (Susanti, D. S, dkk, 2016).

Pada model GWR, ukuran *bandwidth* pada *fixed kernel* dioptimalkan oleh jarak (Bidanset dan Lombard, 2014). Untuk mendapatkan *bandwidth* optimum pada *fixed kernel* dapat menggunakan pendekatan *Cross Validation* (CV). *Bandwidth* yang optimum diperoleh jika nilai CV yang dihasilkan adalah yang paling minimum (Fotheringham, 2002).

$$CV = \sum_{i=1}^{n} [y_i - \hat{y}_{\neq i}(h)]^2 \quad (2.25)$$

Untuk *bandwidth* pada *adaptive kernel* dioptimalkan pada jumlah pengamatan lokasi terdekat (Bidanset dan Lombard, 2014). Jika pada *fixed kernel* untuk memperoleh nilai *bandwidth* dapat menggunakan nilai *cross validation* (CV), tetapi pada *adaptive kernel* untuk memperoleh nilai *bandwidth* jauh lebih intensif menggunakan teknik komputasi (Brivand, 2017).

2.1.12 *Geographically Weighted Panel Regression*

Ide utama GWPR adalah sama halnya dengan analisis GWR *cross sectional*. GWPR merupakan model pengembangan yang memadukan antara model GWR dengan regresi data panel. Dalam GWPR diasumsikan bahwa runtun waktu (*time series*) dari observasi pada sebuah lokasi geogafis merupakan realisasi dari sebuah proses *smooth spatiotemporal*. Proses ini mengikuti sebuah distribusi yang observasi terdekat (salah satu lokasi geografis atau pada waktu) lebih berhubungan daripada observasi yang jauh. Pada analisis GWPR, bertujuan untuk menggabungkan secara keseluruhan lokasi (*cross sectional*) dan observasi (Yu, 2010). Persamaan model

Geographically Weighted Panel Regression model FEM diperoleh dari gabungan antara model GWR dengan regresi panel *fixed effect within transformation* adalah sebagai berikut:

$y_{it} = \beta_0(u_{it}, v_{it}) + \sum_{k=1}^{p} \beta_k(u_{it}, v_{it})X_{itk} + \varepsilon_{it}, \quad i = 1, 2, \dots, n \; dan \; t = 1, 2, \dots, T$ (2.26)

dengan,

y_{it} : variabel dependen di lokasi pengamatan ke-i pada waktu ke-t

$\beta_0(u_{it}, v_{it})$: intercept dari persamaan yang terbentuk pada pengamatan ke-i dan waktu ke-t

$\beta_k(u_{it}, v_{it})$: koefisien regresi variabel independen ke-k di lokasi pengamatan ke-i pada waktu ke-t

(u_{it}, v_{it}) : titik koordinat letak geografis lokasi pengamatan ke-i dan waktu ke-t

k : jumlah variabel independen

X_{itk} : variabel independen ke-k di lokasi pengamatan ke-i waktu ke-t

ε_{it} : residual pengamatan ke-i pada waktu ke-t

2.1.12.1 Estimasi Parameter Model GWPR

Estimasi parameter model GWPR menggunakan pendekatan Weighted Least Square (WLS) seperti estimasi pada model GWR yaitu dengan memberikan unsur pembobot $w_{it}(u_{it}, v_{it})$ pada persamaan 2.26. Menurut Warsito, dkk (2018) matriks pembobot pada model GWPR adalah nilai diagonal dari pembobot yang telah diperoleh dan diulang sebanyak satuan waktu untuk mendapatkan estimasi parameter. Sehingga model yang terbentuk akan berbeda di setiap lokasi.

$$\sum_{t=1}^{T}\sum_{i=1}^{n} w_{it}(u_{it},v_{it})\varepsilon_{it}^2 = \sum_{t=1}^{T}\sum_{i=1}^{n} w_{it}(u_{it},v_{it})\left[y_{it} - \beta_0(u_{it},v_{it}) - \sum_{k=1}^{p}\beta_k(u_{it},v_{it})x_{itk}\right]^2$$

$$\sum_{t=1}^{T}\sum_{i=1}^{n} w_{it}(u_{it},v_{it})\varepsilon_{it}^2$$

$$= \sum_{t=1}^{T}\sum_{i=1}^{n} w_{it}(u_{it},v_{it})\left[y_{it} - \beta_0(u_{it},v_{it}) - \beta_1(u_{it},v_{it})x_{it1} - \beta_p(u_{it},v_{it})x_{itp}\right]^2$$

Atau dalam bentuk matriks jumlah kuadrat residual adalah sebagai berikut

$$\varepsilon^T W(u_{it},v_{it})\varepsilon = [y - X\beta(u_{it},v_{it})]^T W(u_{it},v_{it})[y - X\beta(u_{it},v_{it})]$$

$$= y^T W(u_{it},v_{it})y - y^T W(u_{it},v_{it})X\beta(u_{it},v_{it})$$
$$- \beta^T(u_{it},v_{it})X^T W(u_{it},v_{it})y$$
$$+ \beta^T(u_{it},v_{it})X^T W(u_{it},v_{it})X\beta(u_{it},v_{it})$$

$$= y^T W(u_{it},v_{it})y - 2\beta^T(u_{it},v_{it})X^T W(u_{it},v_{it})y$$
$$+ \beta^T(u_{it},v_{it})X^T W(u_{it},v_{it})X\beta(u_{it},v_{it})$$

Kemudian, untuk mendapatkan nilai optimum dari penduga β, persamaan diatas diturunkan terhadap $\beta^T(u_{it},v_{it})$ dan disamadengankan nol menjadi

$$\frac{\partial \varepsilon^T W(u_{it},v_{it})\varepsilon}{\partial \beta^T(u_{it},v_{it})} = 0$$

$$\frac{\partial(y^T W(u_{it},v_{it})y - 2\beta^T(u_{it},v_{it})X^T W(u_{it},v_{it})y + \beta^T(u_{it},v_{it})X^T W(u_{it},v_{it})X\beta(u_{it},v_{it}))}{\partial\beta^T(u_{it},v_{it})}$$

$$= 0$$

$$0 - 2X^T W(u_{it},v_{it})Y + 2X^T W(u_{it},v_{it})X\hat{\beta}(u_{it},v_{it}) = 0$$

$$-2X^T W(u_{it},v_{it})Y + 2X^T W(u_{it},v_{it})X\hat{\beta}(u_{it},v_{it}) = 0$$

$$2X^T W(u_{it},v_{it})X\hat{\beta}(u_{it},v_{it}) = 2X^T W(u_{it},v_{it})Y$$

$$X^T W(u_{it},v_{it})X\hat{\beta}(u_{it},v_{it}) = X^T W(u_{it},v_{it})Y$$

Untuk memperoleh $\hat{\beta}(u_{it},v_{it})$ kedua ruas dikalikan dengan invers dari $X^T W(u_{it},v_{it})X$ sehingga diperoleh

$$[X^T W(u_{it},v_{it})X]^{-1}\, X^T W(u_{it},v_{it})X\hat{\beta}(u_{it},v_{it})$$
$$= [X^T W(u_{it},v_{it})X]^{-1}X^T W(u_{it},v_{it})Y$$

$$\hat{\beta}(u_{it},v_{it}) = [X^T W(u_{it},v_{it})X]^{-1}X^T W(u_{it},v_{it})Y$$

sehingga diperoleh estimator dari parameter model sebagai berikut

$$\hat{\beta}(u_{it},v_{it}) = [X^T W(u_{it},v_{it})X]^{-1}X^T W(u_{it},v_{it})y \qquad (2.27)$$

dimana $\hat{\beta}(u_{it},v_{it}) = (\hat{\beta}_{it0},\hat{\beta}_{it1},\hat{\beta}_{it2},\dots,\hat{\beta}_{itp})^T$ adalah vektor koefisien regresi lokal, dan matriks W berukuran $nt \times nt$ yaitu sebagai berikut (2.28)

$$W(u_{it},v_{it}) = diag\ (\ w_{11}(u_{it},v_{it}), w_{21}(u_{it},v_{it}), w_{31}(u_{it},v_{it}),\dots, w_{n1}(u_{it},v_{it}),\dots,)$$
$$\vdots$$
$$w_{1t}(u_{it},v_{it}), w_{2t}(u_{it},v_{it}),\dots, w_{nt}(u_{it},v_{it}))$$

$W(u_{it}, v_{it})$ dapat dituliskan menjadi $W(it)$. Dalam notasi matriks, β merupakan matriks yang berisi parameter lokal dengan struktur:

$$\beta = \begin{bmatrix} \beta_0(u_{11}, v_{11}) & \beta_1(u_{11}, v_{11}) & \cdots & \beta_p(u_{11}, v_{11}) \\ \beta_0(u_{21}, v_{21}) & \beta_1(u_{21}, v_{21}) & \cdots & \beta_p(u_{21}, v_{21}) \\ \vdots & \vdots & \ddots & \vdots \\ \beta_0(u_{N1}, v_{N1}) & \beta_1(u_{N1}, v_{N1}) & \cdots & \beta_p(u_{N1}, v_{N1}) \\ \beta_0(u_{12}, v_{12}) & \beta_1(u_{12}, v_{12}) & \cdots & \beta_p(u_{12}, v_{12}) \\ \beta_0(u_{22}, v_{22}) & \beta_2(u_{22}, v_{22}) & \cdots & \beta_p(u_{22}, v_{22}) \\ \vdots & \vdots & \ddots & \vdots \\ \beta_0(u_{N2}, v_{N2}) & \beta_1(u_{N2}, v_{N2}) & \cdots & \beta_p(u_{N2}, v_{N2}) \\ \vdots & \vdots & \vdots & \vdots \\ \beta_0(u_{1T}, v_{1T}) & \beta_1(u_{1T}, v_{1T}) & \cdots & \beta_p(u_{1T}, v_{1T}) \\ \beta_0(u_{2T}, v_{2T}) & \beta_1(u_{2T}, v_{2T}) & \ddots & \beta_p(u_{2T}, v_{2T}) \\ \vdots & \vdots & \cdots & \vdots \\ \beta_0(u_{NT}, v_{NT}) & \beta_1(u_{NT}, v_{NT}) & & \beta_p(u_{NT}, v_{NT}) \end{bmatrix}$$

Sehingga dapat dituliskan estimasi untuk parameter pada setiap baris dari matriks tersebut:

$$\hat{\beta}(it) = [X^T W(it) X]^{-1} X^T W(it) y$$

Dimana it merupakan lokasi ke-i dan waktu ke-t pada matriks β dan $W(it)$ adalah matriks pembobot spasial untuk lokasi pengamatan ke-i dan waktu ke-t (Rahayu, 2017).

2.1.12.2 Pengujian Hipotesis Parameter Model GWPR

Pengujian kesesuaian model GWPR sama halnya dengan model GWR, pengujian ini dilakukan dengan menguji kesesuaian dari parameter secara serentak. Menurut Brunsdon et. al. (dalam Utami, dkk, 2016), hipotesis pada uji kecocokan model seperti berikut

$H_0: \beta_k(u_i, v_i) = \beta_k$ untuk setiap $k = 1, 2, \dots, p$ dan $i = 1,2, \dots, n$ (tidak ada perbedaan yang signifikan antara model regresi data panel dan GWR-Panel)

H_1: minimal terdapat satu $\beta_k(u_i, v_i) \neq \beta_k$untuk setiap $k = 1, 2, \dots, p$ dan $i = 1,2, \dots, n$ (terdapat perbedaan yang signifikan antara model regresi data panel dan GWR-Panel)

Statistik uji:

$$F = \frac{RSS(H_1)/df_2}{RSS(H_0)/df_1} \tag{2.29}$$

Dengan:

$RSS(H_0) = y^T(I - H)y$: *Residual Sum of Square* model regresi data panel

dimana $H = X(X^TX)^{-1}X^T$

$RSS(H_1) = y^T(I - L)^T(I - L)y$: *Residual Sum of Square* model regresi GWR-Panel

$df_1 = nT - p - 1$

$df_2 = \frac{\delta_1^2}{\delta_2}$, dimana $\delta_1 = tr\left([(I - L)^T(I - L)]^i\right), i = 1,2$

I merupakan matriks identitas berukuran $nt \times nt$ serta L merupakan matriks proyeksi dari model GWR-Panel. Dimisalkan $x_i^T = \left(1, x_{i1}, x_{i2}, \dots, x_{ip}\right)$ adalah baris ke-i dari matriks X, dan $\hat{\beta}(i)$ adalah vektor estimasi parameter di lokasi ke-i, maka estimasi nilai y pada lokasi ke-i dapat diperoleh sebagai berikut (Rahayu, 2017):

$$\hat{y}_i = x_i^T \hat{\beta}(i)$$

$$\hat{y}_i = x_i^T [X^T W(i) X]^{-1} X^T W(i) y$$

Dimana $x_i^T [X^T W(i) X]^{-1} X^T W(i)$ disebut juga matriks proyeksi yaitu matriks yang memproyeksikan nilai y menjadi $\hat{y}$ pada lokasi ke-i.

$$\hat{y} = Ly$$

$$L = \begin{bmatrix} \ddot{x}_{11}^T \left(\ddot{X}^T W(11) \ddot{X}\right)^{-1} \ddot{X}^T W(11) \\ \ddot{x}_{21}^T \left(\ddot{X}^T W(21) \ddot{X}\right)^{-1} \ddot{X}^T W(21) \\ \vdots \\ \ddot{x}_{N1}^T \left(\ddot{X}^T W(N1) \ddot{X}\right)^{-1} \ddot{X}^T W(N1) \\ \ddot{x}_{12}^T \left(\ddot{X}^T W(12) \ddot{X}\right)^{-1} \ddot{X}^T W(12) \\ \ddot{x}_{22}^T \left(\ddot{X}^T W(22) \ddot{X}\right)^{-1} \ddot{X}^T W(22) \\ \vdots \\ \ddot{x}_{N2}^T \left(\ddot{X}^T W(N2) \ddot{X}\right)^{-1} \ddot{X}^T W(N2) \\ \vdots \\ \ddot{x}_{1T}^T \left(\ddot{X}^T W(1T) \ddot{X}\right)^{-1} \ddot{X}^T W(1T) \\ \ddot{x}_{2T}^T \left(\ddot{X}^T W(2T) \ddot{X}\right)^{-1} \ddot{X}^T W(2T) \\ \vdots \\ \ddot{x}_{NT}^T \left(\ddot{X}^T W(NT) \ddot{X}\right)^{-1} \ddot{X}^T W(NT) \end{bmatrix}$$

Kriteria pengujian tolak H_0 jika nilai $F > F_{\alpha, df_1, df_2}$ artinya terdapat perbedaan yang signifikan antara model regresi data panel dan GWR-Panel.

2.1.12.3 Pengujian Parameter Model secara Parsial

Pengujian signifikansi parameter model dilakukan untuk mengetahui parameter mana saja yang signifikan mempengaruhi variabel dependen pada lokasi ke-i. Uji signifikansi parameter dilakukan menggunakan hipotesis berikut (Qur'ani, 2014):

$H_0 : \beta_k(u_i, v_i) = 0$, untuk $k = 1,2, \dots, p$ dan $i = 1,2, \dots, n$ (koefisien parameter variabel X_k tidak signifikan terhadap y)

H_1: minimal ada satu $\beta_k(u_i, v_i) \neq 0$ untuk $k = 1,2, \dots, p$ dan $i = 1,2, \dots, n$ (koefisien parameter variabel X_k signifikan terhadap y)

Estimasi parameter $\hat{\beta}_k(u_i, v_i)$ akan mengikuti distribusi normal dengan rata-rata $\beta_k(u_i, v_i)$ dan matriks varian kovarian $C_i C_i^T \sigma^2$, dengan $C_i = (X^T W(u_i, v_i) X)^{-1} X^T W(u_i, v_i)$ sehingga diperoleh:

$$\frac{\hat{\beta}_k(u_i,v_i) - \beta_k(u_i,v_i)}{\sigma\sqrt{C_{kk}}} \sim N(0,1) \qquad (2.30)$$

dengan C_{kk} adalah elemen diagonal ke-k dari matriks $C_i C_i^T$ dan $\hat{\sigma} = \sqrt{\frac{RSS(H_1)}{\delta_1}}$

$RSS(H_0) = y^T(I - H)y$: *Residual Sum of Square* model regresi data panel

dimana $H = X(X^T X)^{-1} X^T$

$RSS(H_1) = y^T(I - L)^T(I - L)y$: *Residual Sum of Square* model regresi GWR-Panel

Sehingga statistik uji yang digunakan adalah

$$T_{hit} = \frac{\hat{\beta}_k(u_i,v_i)}{\hat{\sigma}\sqrt{C_{kk}}} \qquad (2.31)$$

Kriteria ujinya adalah tolak H_0 jika nilai $|T_{hit}| > t\alpha_{/2;df}$ atau $p - value < \alpha$ dimana

$df = \frac{\delta_1^2}{\delta_2}$. $\delta_i = tr\big((I-L)^T(I-L)\big)^i,\ i = 1,2$

2.1.13 Koefisien Determinasi

Menurut Gujarati (2004), besaran koefisien determinasi (R^2) merupakan besaran yang paling lazim digunakan untuk mengukur kecocokan model *(goodness of fit)* garis regresi. R^2 dapat digunakan untuk mengetahui besarnya daya menerangkan dari variabel independen terhadap variabel dependen (Putri dan Salamah, 2013). Nilai R^2 pada *Fixed Effect* GWPR dengan matriks pembobot W ukuran $(nT \times nT)$ dan matriks Y berukuran $(nT \times 1)$ didefinisikan sebagai berikut (Qur'ani, 2014): (2.32)

$$R^2(u_i, v_i) = \frac{TSS - RSS}{TSS}$$

dimana TSS merupakan *total sum of squares* model GWPR dan RSS merupakan *residual sum of squares* model GWPR.

$TSS = \sum_{j=1}^{N} w_{ij}\ (y_i - \bar{y}_i)^2$

$RSS = \sum_{i=1}^{N} w_{ij}(y_i - \hat{y}_i)^2$

y_i : variabel dependen lokasi ke-i

$\bar{y}_i$: rata-rata variabel dependen

$\hat{y}_{it}$: nilai prediksi variabel dependen

2.1.14 Akaike Information Criterion (AIC)

Menurut Fotheringham, et al. (2002) sebagaimana dikutip oleh Pamungkas, dkk (2016) *Akaike Information Criterion* (AIC) adalah salah satu kriteria pemilihan model terbaik berdasarkan nilai terkecil. Rumus perhitungan nilai AIC adalah sebagai berikut:

$$AIC = 2n\ln(\hat{\sigma}) + n\ln(2\pi) + n + tr(L) \qquad (2.33)$$

Dengan

$\hat{\sigma}$: nilai estimator standar deviasi dari residual, yaitu $\hat{\sigma} = \frac{RSS}{n}$

L : matriks proyeksi dimana $\hat{y} = Ly$

2.2 Pembangunan Manusia

Pembangunan manusia adalah proses perluasan pilihan masyarakat. Pada prinsipnya, pilihan manusia sangat banyak jumlahnya dan berubah setiap saat. Tetapi pada semua level pembangunan, ada tiga pilihan yang paling mendasar yaitu untuk berumur panjang dan hidup sehat, untuk memperoleh pendidikan dan untuk memiliki akses terhadap sumber-sumber kubutuhan agar hidup secara layak (BPS, 2017).

Pembangunan manusia memiliki dua sisi. Pertama, pembentukan kapabilitas manusia seperti peningkatan kesehatan, pendidikan, dan kemampuan. Kedua, penggunaan kapabilitas yang mereka miliki, seperti untuk menikmati waktu luang, untuk tujuan produktif atau aktif dalam kegiatan budaya, sosial, dan urusan politik. Apabila skala pembangunan manusia tidak seimbang, kemungkinan akan terjadi ketidakstabilan.

Berdasarkan konsep pembangunan manusia, pendapatan merupakan salah satu pilihan yang harus dimiliki. Akan tetapi, pembangunan bukan sekadar perluasan pendapatan dan kesejahteraan. Pembangunan manusia harus memfokuskan pada manusia (HDR 1990 :10).

Berdasarkan beberapa konsep pembangunan manusia yang ada, UNDP mendefinisikan pembangunan manusia dalam *Human Development Report* 1996 sebagai proses dimana masyarakat dapat memperluas berbagai pilihan-pilihannya. Pendapatan merupakan salah satu faktor penentu pilihan, tetapi faktor yang lebih penting lainnya adalah kesehatan, pendidikan, lingkungan fisik yang baik serta kebebasan dalam bertindak.

2.2.1 Pengukuran Pembangunan Manusia

Pembangunan manusia menggunakan pengukuran yang sudah dikenalkan oleh UNDP pada tahun 1990, yaitu Indeks Pembangunan Manusia (IPM). Menurut Melliana dan Zain (2013) Indeks Pembangunan Manusia merupakan salah satu alat ukur yang dapat digunakan untuk menilai kualitas pembangunan manusia, baik dari sisi dampaknya terhadap kondisi fisik manusia (kesehatan dan kesejahteraan) maupun yang bersifat non-fisik (pendidikan). Pembangunan yang berdampak pada kondisi fisik masyarakat misalnya tercermin dalam angka harapan hidup, serta kemampuan daya beli masyarakat, sedangkan dampak non-fisik dapat dilihat dari kualitas pendidikan masyarakat.

2.2.2 Variabel-Variabel yang diduga mempengaruhi Indeks Pembangunan Manusia

1. Umur Harapan Hidup saat Lahir (UHH)

   Umur Harapan Hidup saat Lahir (UHH) didefinisikan sebagai rata-rata perkiraan banyak tahun yang dapat ditempuh oleh seseorang sejak lahir. UHH mencerminkan derajat kesehatan suatu masyarakat. Sumber data yang digunakan dalam penghitungan UHH dihitung dari hasil Proyeksi SP2010.

2. Harapan Lama Sekolah (HLS)

   Angka Harapan Lama Sekolah (HLS) didefinisikan sebagai lamanya sekolah (dalam tahun) yang diharapkan akan dirasakan oleh anak pada umur tertentu di masa mendatang. HLS dapat digunakan untuk mengetahui kondisi pembangunan sistem pendidikan di berbagai jenjang. HLS dihitung pada usia 7 tahun ke atas karena mengikuti kebijakan pemerintah yaitu program wajib belajar. Untuk mengakomodir penduduk yang tidak tercakup dalam Susenas, HLS dikoreksi dengan siswa yang bersekolah di pesantren.

$$HLS_a^t = FK \times \sum_{i=a}^{n} \frac{E_i^t}{P_i^t} \qquad (2.35)$$

   Keterangan:

   HLS_a^t : Harapan Lama Sekolah pada umur a di tahun t

   E_i^t : Jumlah penduduk usia i yang bersekolah pada tahun t

   P_i^t : Jumlah penduduk usia i pada tahun t

   i : Usia $(a, a+1, \dots, n)$

   F : faktor koreksi pesantren

3. Rata-rata Lama Sekolah (RLS)

   Rata-rata Lama Sekolah (RLS) didefinisikan sebagai jumlah tahun yang digunakan oleh penduduk dalam menjalani pendidikan formal. Cakupan penduduk yang dihitung RLS adalah penduduk berusia 25 tahun ke atas. RLS dihitung untuk usia 25 tahun ke atas dengan asumsi pada umur 25 tahun proses pendidikan sudah berakhir. Penghitungan RLS pada usia 25 tahun ke atas juga mengikuti standard internasional yang digunakan oleh UNDP.

4. Pengeluaran per Kapita Disesuaikan

   Pengeluaran per kapita disesuaikan ditentukan dari nilai pengeluaran per kapita dan paritas daya beli. Rata-rata pengeluaran per kapita setahun diperoleh dari Susenas Modul, dihitung dari level provinsi hingga level kab/kota. Ratarata pengeluaran per kapita dibuat konstan/riil dengan tahun dasar 2012=100. Perhitungan paritas daya beli pada metode baru menggunakan 96 komoditas dimana 66 komoditas merupakan makanan dan sisanya merupakan komoditas non makanan. Metode penghitungannya menggunakan Metode Rao.

2.3 Kerangka Berpikir

Menurut Gujarati (2004) regresi merupakan suatu metode untuk mengukur besarnya pengaruh variabel respon terhadap variabel prediktor. Analisis regresi adalah hubungan yang didapat dan dinyatakan dalam bentuk persamaan matematika yang menyatakan hubungan fungsional antar variabel-variabel (Sudjana, 2005). Macam-macam analisis regresi yaitu analisis regresi sederhana, analisis regresi spasial, dan analisis regresi data panel. Analisis regresi spasial merupakan analisis regresi yang melibatkan pengaruh spasial atau ruang ke dalam model (Purwaningsih, 2014). Salah satu tipe data spasial yaitu data titik. Model *Geographically Weighted Regression* merupakan salah satu model yang dimunculkan dari metode pendekatan titik yaitu pendekatan berdasarkan posisi koordinat garis lintang (*latitude*) dan garis bujur (*longitude*) (Qur'ani, 2014). Regresi data panel adalah regresi yang menggunakan data pengamatan terhadap satu atau lebih variabel pada suatu unit secara terus menerus selama beberapa periode waktu (Ratnasari, dkk, 2014). Regresi data panel memiliki tiga pendekatan untuk mengestimasi model, yaitu *Common Effect Model* (CEM), *Fixed Effect Model* (FEM), dan *Random Effect Model* (REM). Menggunakan data panel yang merupakan gabungan dari data silang dan data runtun waktu tentu akan memberikan hasil yang lebih baik dibanding hanya melakukan pengamatan dalam satu waktu tertentu saja. Tetapi ada faktor lain yang juga perlu diperhatikan yaitu mengenai pengaruh efek spasial. Pengaruh spasial yang berkaitan dengan perbedaan karakteristik lingkungan dan geografis antar wilayah pengamatan adalah keragaman spasial atau heterogenitas spasial (Sari, dkk, 2013). Untuk mengatasi adanya heterogenitas spasial pada data bertipe panel dapat menggunakan metode statistik yang merupakan pengembangan dari *Geographically Weighted Regression* yaitu *Geographically Weighted Panel Regression*. *Geographically Weighted Panel Regression* merupakan gabungan model *Geographically Weighted Regression* (GWR) dengan model regresi data panel. Model GWPR akan menghasilkan model *fixed effect* GWPR atau *random effect* GWPR (Yu, 2010). Pada penelitian ini lebih difokuskan pada model *fixed effect* GWPR.

Estimasi parameter pada model *Geographically Weighted Panel Regression* adalah dengan metode *Weighted Least Square* (WLS) yaitu dengan memberikan pembobot yang berbeda untuk setiap lokasi dimana data tersebut diambil. Sama halnya pada model GWR, peran pembobot dalam GWPR sangat penting karena nilai pembobot mewakili letak data observasi antara satu dengan yang lainnya. Fungsi pembobot terdiri dari 2 jenis yaitu fungsi invers jarak dan fungsi kernel. Fungsi invers jarak mempunyai kelemahan yaitu tidak bisa digunakan sebagai pembobot untuk dirinya sendiri karena akan menghasilkan nilai yang tak terhingga, sedangkan fungsi kernel digunakan jika fungsi jarak adalah fungsi yang kontinu dan monoton menurun (Chasco et al, 2007). Fungsi kernel dibagi menjadi dua bagian yaitu fungsi kernel *fixed* dan fungsi kernel *adaptive*. Kernel *fixed* adalah kernel yang memiliki *bandwidth* yang sama untuk semua lokasi pengamatan sedangkan kernel *adaptive* adalah kernel yang memiliki *bandwidth* yang berbeda untuk setiap titik lokasi pengamatan, hal ini disebabkan kemampuan fungsi kernel *adaptive* yang dapat disesuaikan dengan kondisi titik-titik pengamatan (Pamungkas, dkk, 2016). Fungsi kernel adaptive terbagi menjadi tiga yaitu *adaptive gaussian*, *adaptive bisquare*, dan *adaptive tricube*. Pada penelitian ini difokuskan pada *adaptive gaussian* dan *adaptive bisquare.*

Pengujian hipotesis pada model GWPR terdiri dari dua macam yaitu uji kesesuaian dari parameter secara serentak dan uji signifikansi parameter model. Pemilihan model terbaik dilakukan berdasarkan nilai koefisien determinasi dan nilai AIC.

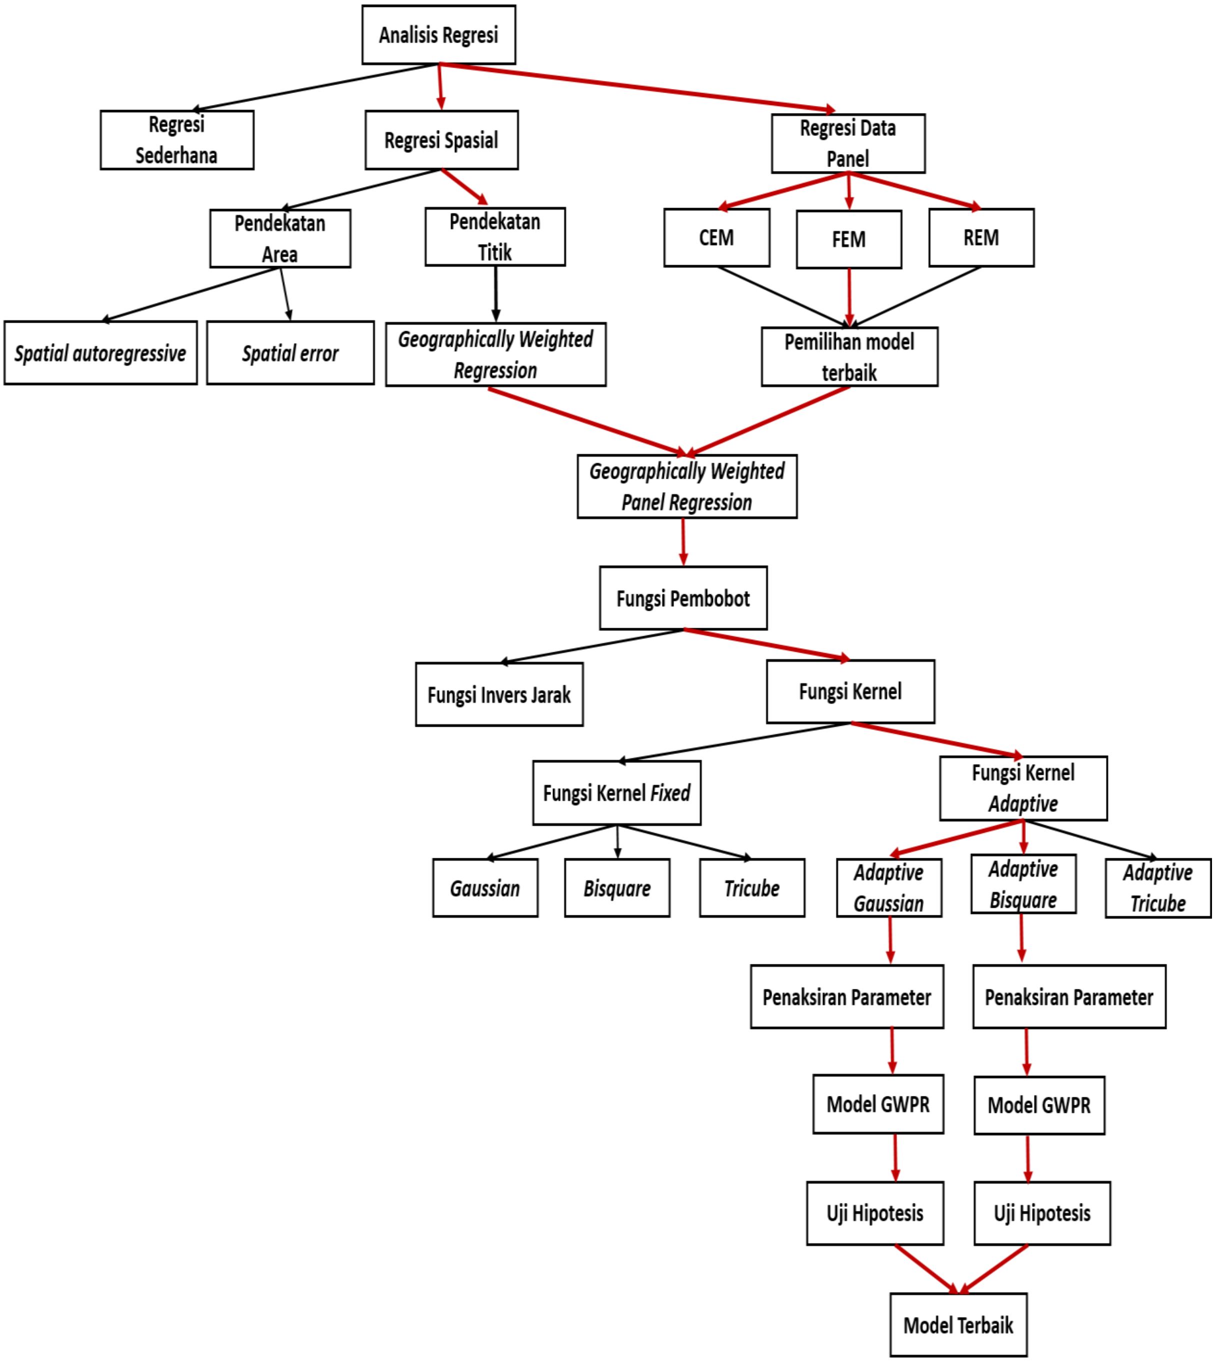

Gambar 2.1 *Kerangka Berpikir*

BAB 5

PENUTUP

5.1 Simpulan

Berdasarkan hasil dan pembahasan, dapat diambil simpulan sebagai berikut:

1. Model *Geographically Weighted Panel Regression* dengan fungsi pembobot *Adaptive Gaussian* sebagai contoh pada Kabupaten Brebes adalah sebagai berikut:

$$\hat{y}_{29t} = 0{,}615648\,\mathrm{X}_{29\mathrm{t}1} + 0{,}176231\,\mathrm{X}_{29\mathrm{t}2} + 1{,}517739\,\mathrm{X}_{29\mathrm{t}3} + 0{,}001099\,\mathrm{X}_{29\mathrm{t}4}$$

dengan

X_{29t1} : nilai umur harapan hidup saat lahir (UHH) untuk wilayah ke-29 tahun ke-t

X_{29t2} : nilai harapan lama sekolah (HLS) untuk wilayah ke-29 tahun ke-t

X_{29t3} : nilai rata-rata lama sekolah (RLS) untuk wilayah ke-29 tahun ke-t

X_{29t4} : nilai pengeluaran per kapita disesuaikan untuk wilayah ke-29 tahun ke-t

2. Model *Geographically Weighted Panel Regression* dengan fungsi pembobot *Adaptive Bisquare* sebagai contoh pada Kabupaten Brebes adalah sebagai berikut:

$$\hat{y}_{29t} = 0{,}620885\,\mathrm{X}_{29\mathrm{t}1} + 0{,}122763\,\mathrm{X}_{29\mathrm{t}2} + 1{,}426407\,\mathrm{X}_{29\mathrm{t}3} + 0{,}001198\,\mathrm{X}_{29\mathrm{t}4}$$

dengan

X_{29t1} : nilai umur harapan hidup saat lahir (UHH) untuk wilayah ke-29 tahun ke-t

X_{29t2} : nilai harapan lama sekolah (HLS) untuk wilayah ke-29 tahun ke-t

X_{29t3} : nilai rata-rata lama sekolah (RLS) untuk wilayah ke-29 tahun ke-t

X_{29t4} : nilai pengeluaran per kapita disesuaikan untuk wilayah ke-29 tahun ke-t

3. Model terbaik antara model *fixed effect* GWPR dengan pembobot *adaptive gaussian* dan model *fixed effect* GWPR dengan pembobot *adaptive bisquare* dapat diketahui berdasarkan nilai koefisien determinasi dan nilai AIC. Model *fixed effect* GWPR dengan pembobot *adaptive bisquare* merupakan model yang terbaik karena memiliki nilai koefisien determinasi terbesar yaitu 0,9954 dan nilai AIC terkecil sebesar 65,61756. Sehingga model *fixed effect* GWPR dengan *adaptive bisquare* lebih baik daripada model *fixed effect* GWPR dengan *adaptive gaussian* untuk pemodelan Indeks Pembangunan Manusia di Provinsi Jawa Tengah.
4. Semua variabel independen yaitu Umur Harapan Hidup, Harapan Lama Sekolah, Rata-rata Lama Sekolah, dan Pendapatan Perkapita yang disesuaikan berpengaruh signifikan terhadap Indeks Pembangunan

Manusia di Jawa Tengah berdasarkan pada model *fixed effect* GWPR dengan fungsi pembobot terbaik.

5.2 Saran

Berdasarkan hasil penelitian dan pembahasan, saran yang dapat diberikan peneliti adalah sebagai berikut :

1. Pada penelitian ini estimasi model regresi data panel yang terpilih yaitu yang menggunakan *fixed effect model* (FEM). Karena penulis hanya fokus pada kondisi tiap unit *cross-section* berbeda. Untuk penelitian selanjutnya dapat dikembangkan model yang memasukkan unsur *time-invariant*. Model estimasi regresi data panel dengan REM (*Random Effect Model*) dapat digunakan sehingga model *Geographically Weighted Panel Regression* yang terbentuk berupa *Random Effect* GWPR. Namun masalah endogenitas yaitu korelasi antar *error* dengan variabel independen kemungkinan akan muncul jika menggunakan REM.
2. Fungsi pembobot yang digunakan dalam penelitian ini yaitu *adaptive gaussian* dan *adaptive bisquare*, penelitian selanjutnya dapat menggunakan fungsi pembobot lain seperti *adaptive tricube*.

DAFTAR PUSTAKA

(BPS), Badan Pusat Statistik. 2018. *Berita Resmi Statistik.* Semarang: Badan Pusat Statistik Jawa Tengah.

(BPS), Badan Pusat Statistik. 2018. *Indikator Kesejahteraan Rakyat Provinsi Jawa Tengah 2017/2018.* Semarang: Badan Pusat Statistik Jawa Tengah.

Anselin, Luc, dan Anil Bera. 1998. *Spatial Dependence In Linear Regression Models With An Introduction To Spatial Econometrics.* New York: DAlam Ullah, A. & Gilles, D Handbook of Applied Economics Statistic. Selected reading, pp. 273-289, Marcel Dekker.

Baltagi, B. H. 2005. *Econometrics Analysis of Panel Data (3 ed).* Chicester, England: John Wiley & Sons Ltd.

Baltagi, B. H. 2008. *Econometrics. Fourth Edition.* Heidelberg: Springer.

Bidanset, P E, dan J R Lombard. 2014. "The Effect of Kernel and Bandwidth Specification in Geographically Weighted Regression Models on The Accuracy and Uniformity of Mass Real Estate Appraisal." *Journal of Property Tax Assessment & Administration, Vol. 10, Issue. 3.*

Brivand, R. 2017. "Geographically Weighted Regression."

Bruna, F, & Yu, D. 2013. "Geographically Weighted Panel Regression ." *XI Congreso Galego de Estatistica e Investigacion de Operations, A Coruna* 24-26.

Cai, R, Yu, D., & Oppenheimer, M. 2014. "Estimating the Spatially Varying Responses of Corn Yields to Weather Variations using Geographically Weighted Panel Regression." *Journal of Agricultural and Resource Economics, 39(2).*

Charlton, M., & Fotheringham, S. 2009. "Geographically Weighted Regression White Paper."

Chasco, C., Garcia, I., & Vicens, J. 2007. "Modelling Spatial Variations in Household Disposable Income with Geographically Weighted Regression." *MPRA Paper No. 1682* 1-28.

Chatterjee, S, & Hadi A S. 2006. *Regression Analysis by Example.* Canada: John Wiley & Sons, Inc.

Croissant, Yves, & Millo, G. 2008. "Panel Data Econometrics in R: The Palm Package." *Journal of Statistical Software* 1-51.

Fotheringham, A. S., Brundson, C., & Charlton, M. E. 2002. *Geographically Weighted Regression: The Analysis of Spatially Varying Relationships.* Chichester: Willey.

Greene, W. H. 2000. *Econometric Analysis, 4th edition.* Upper Saddle River, Nwe Jersey: Prentice-Hall Inc.

Gujarati, D. 2004. *Basic Econometrics.* New York: MCGraw-Hill.

Gujarati, D. 1978. *Ekonometrika Dasar. Terjemahan dari Sumarno Zain.* Jakarta: Erlangga.

Gwarda, K L. 2018. "Geographically Weighted Regression in the Analysis of Unemployment in Poland." *International Journal of Geo-Information.*

Isbiyantoro, K, Wilandari, Y., & Sugito. 2014. "Perbandingan Model Pertumbuhan Ekonomi di Jawa Tengah dengan Metode Regresi Linier Berganda dan Metode Geographically Weighted Regression." *Jurnal Gaussian, 3(3):* 461-469.

Jezria, F. 2018. Pemodelan Geographically Weighted Panel Regression dengan Pembobot Fixed Gaussian Kernel dan Adaptive Gaussian Kernel (Studi Kasus Presentase Penduduk Miskin Provinsi Jawa Tengah). *Skripsi.* Tidak dipublikasikan. Semarang: Universitas Diponegoro.

Latuconsina, Z M. Y. 2017. "Analisis Faktor-faktor yang Mempengaruhi Indeks Pembangunan Manusia Kabupaten Malang Berbasis Pendekatan Perwilayahan dan Regresi Panel." *Journal of Regional and Rural Development Planning, 1 (2),* 202-216.

Lesage, J. P. 1999. *The Theory and Practice of Spatial Econometrics.* University of Toledo.

Leung, Y., C.L., & Zhang, W. 2000. "Statistical Tests for Spatial Non Stationarity Based on The Geographically Weighted Regression Model Environment and Planning." *A. 32* 9-32.

Lutfiani, N, Sugiman, & Mariani, S. 2017. "Pemodelan Geographically Weighted Regression (GWR) dengan Fungsi Pembobot Kernel Gaussian dan Bisquare." *UNNES Journal of Mathematics.*

Melliana, A, & Zain, I. 2013. "Analisis Statistika Faktor yang Mempengaruhi Indeks Pembangunan Manusia di Kabupaten/Kota Provinsi Jawa Timur dengan Menggunakan Regresi Panel ." *Jurnal Sains dan Seni Pomits. 2 (2)* D237-D242.

Meutuah, S. M., Yasbin, H., & Maruddani, D. 2017. "Pemodelan Fixed Effect Geographically Weighted Panel Regression Untuk Indeks Pembangunan Manusia di Jawa Tengah." *Jurnal Gaussian 6(2):* 241-250.

Munikah, T, Pramoedyo, H., & Fitriani, R. 2014. "Pemodelan Geographically Weighted Regression dengan Pembobot Fixed Gaussian Kernel pada Data Spasial (Studi Kasus Ketahanan Pangan di Kabupaten Tanah Laut Kalimantan Selatan)." *Natural B, 2(3):* 296-302.

Pamungkas, R. A., Yasin, H., & Rahmawati, R. 2016. "Perbandingan Model GWR dengan Fixed dan Adaptive Bandwidth untuk Presentase Penduduk Miskin di Jawa Tengah." *jurnal gaussian 5(3):* 535-544.

Pangestika, S. 2015. "Analisis Estimasi Model Regresi Data Panel dengan Pendekatan Common Effect Model (CEM), Fixed Effect Model (FEM), dan Random Effect Model (REM)." Skripsi Universitas Negeri Semarang.

Pijnenburg, K. 2013. *Spatial Dependence and Spatial Heterogeneity in the Analysis of Regional Economic Performance and House Price Developments.* Freie Universitat Berlin.

Pratiwi, Diah, Y., Mariani, S., & Hendikawati, P. 2018. "Pemodelan Regresi Spasial Menggunakan Geographically Weighted Regression dengan Pembobot Fixed Kernel Gaussian dan Adaptive Kernel Bisquare." *UNNES Journal of Mathematics.*

Purwaningsih, T. 2014. *Kajian Pengaruh Matriks Pembobot Spasial Dalam Model Data Panel Spasial.* Institut Pertanian Bogor.

Putri, A, & Salamah, M. 2013. "Pemodelan Kasus Balita Gizi Buruk di Kabupaten Bojonegoro dengan Geographically Weighted Regression." *FMIPA, Institut Teknologi Sepuluh November (ITS) Jurnal Sains dan Seni Pomits 2(1).*

Qur'ani, A. Y. 2014. "Pemodelan Geographically Weighted Regression Panel (GWR-Panel) Sebagai Pendekatan Model Geographically Weighted Regression (GWR) dengan Menggunakan Fixed Effect Model Time Trend." *Jurnal Mahasiswa Statistik, 2(3).*

Rahayu, N. S. 2017. Geographically Weighted Panel Regression Untuk Pemodelan Persentase Penduduk Miskin di Provinsi Jawa Tengah. Tesis Institut Teknologi Sepuluh November.

Rahmadeni, & Wulandari, N. 2017. "Analisis Faktor-Faktor yang Mempengaruhi Inflasi pada Kota Metropolitan di Indonesia dengan Menggunakan Analisis Data Panel." *Jurnal Sains Matematika dan Statistika* 34-42.

Ratnasari, N, Kencana, I., & Gandhiadi, G. K. 2014. "Aplikasi Regresi Data Panel dengan Pendekatan Fixed Effect Model." *E-Jurnal Matematika Vol. 3, No. 1* 1-7.

Rizki, M, Rusgiyono, A, & Mukid, M. A. 2015. "Pemodelan Indeks Pembangunan Manusia di Provinsi Jawa Tengah tahun 2008-2013 dengan menggunakan Regresi Data Panel." *Jurnal Gaussian, 4, (2):* 345-354.

Sari, I. R, Saputro, D. R., & Widyaningsih, P. 2013. "Model Geographically Weighted Regression Penderita Diare di Provinsi Jawa Tengah dengan Fungsi Pembobot Kernel Bisquare." *UNS* 135-142.

Sudjana. 2005. *Metoda Statistika.* Bandung: Tarsito.

Susanti, D. S., Lestia, A. S., & Sukmawaty, Y. 2016. "Pemodelan Tingkat Kesejahteraan Penduduk Propinsi Kalimantan Selatan dengan Pendekatan Geographically Weighted Regression (GWR)."

Tabak, B, Miranda, R. B, & Fazio, D. M. 2013. "A geographically Weighted Approach to Measuring Efficiency in Panel Data: The Case of US Saving Banks." *Journal of Banking & Finance* 3747-3756.

Utami, T. W., Rohman, A, & Prahutama, A. 2016. "Pemodelan Regresi Berganda dan Geographically Weighted Regression pada Tingkat Pengangguran Terbuka di Jawa Tengah ." *Media Statistika 9(2)*:133-147.

Warsito, B., Yasin, H., & Hakim, A. R. 2018. "The Step Construction of Geographically Weighted Panel Regression in Air Polluter Standard Index (APSI) Data."ICENIS 1-4.

Wooldridge, J M. 2002. *Econometric Analysis of Cross Section and Panel Data.* London: The MIT Press Cambridge.

Yu, D. 2010. "Explorating Spatiotemporally Varying Regressed Relationships: The Geographically Weighted Panel Regression Analysis." *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Science, Vol. 38, Part II.*

Yuniarti, D. 2010. Pemodelan Persentase Penduduk Miskin di Jawa Timur Tahun 2004-2008 dengan Regresi Panel. Tesis Institut Teknologi Sepuluh Nopember.