

BAB 2

TINJAUAN PUSTAKA

2.1 Tinjauan Statistik

2.1.1 Regresi Linier

Metode regresi linier yang merupakan metode yang memodelkan hubungan antara variabel terikat y dan variabel bebas x_1, x_2, \dots, x_p . Model regresi linier untuk variabel prediktor secara umum ditulis sebagai (Lutfiani, 2019) :

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p + \varepsilon$$

dengan :

y = variabel terikat

β = parameter model

x = variabel bebas

ε = error

Jika diambil sebanyak n pengamatan, maka model untuk pengamatan ke- i adalah (Lutfiani, 2019) :

$$y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_p x_{ip} + \varepsilon_i$$

dengan

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

$\beta_0, \beta_1, \dots, \beta_p$ = parameter model

$\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$ = nilai residual disetiap pengamatan yang diasumsikan identik, bebas, dan berdistribusi Normal dengan mean nol dan varians konstan σ^2 ($\varepsilon_i \sim IIDN((0, \sigma^2))$).

Pada model ini, hubungan antara variabel terikat dan variabel bebas dianggap konstan pada setiap lokasi pengamatan. Jika dituliskan dalam notasi matriks maka menjadi:

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$$

dengan :

$$\mathbf{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix}, \mathbf{X} = \begin{bmatrix} 1 & x_{11} & \dots & x_{1p} \\ 1 & x_{12} & \dots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & \dots & x_{np} \end{bmatrix}, \boldsymbol{\beta} = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_p \end{bmatrix}, \boldsymbol{\varepsilon} = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix}$$

dimana \mathbf{y} adalah variabel terikat, \mathbf{X} adalah matriks variabel bebas, $\boldsymbol{\beta}$ adalah vektor parameter, dan $\boldsymbol{\varepsilon}$ adalah vektor error. Dengan metode *Ordinary Least Square* (OLS) untuk meminimumkan jumlah kuadrat error, sehingga didapatkan estimator parameter $\boldsymbol{\beta}$.

Penduga parameter $\boldsymbol{\beta}$ diperoleh dari menurunkan $\boldsymbol{\varepsilon}^T \boldsymbol{\varepsilon}$ terhadap $\boldsymbol{\beta}$ dan kemudian disamakan dengan nol.

$$\frac{\partial(\boldsymbol{\varepsilon}^T \boldsymbol{\varepsilon})}{\partial \boldsymbol{\beta}} = 0$$

$$0 - 2\mathbf{X}^T \mathbf{y} + 2\mathbf{X}^T \mathbf{X} \hat{\boldsymbol{\beta}} = 0$$

sehingga,

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

$\hat{\boldsymbol{\beta}}$ merupakan penaksir yang tak bias untuk $\boldsymbol{\beta}$.

2.1.2 Asumsi Klasik

Metode OLS dibangun menggunakan beberapa asumsi klasik, yaitu multikolinieritas, heteroskedastisitas, autokorelasi dan normalitas residual.

2.1.2.1 Uji Normalitas

Uji normalitas bertujuan untuk menguji apakah dalam model regresi, variabel terikat dan variabel bebas memiliki data yang terdistribusi normal atau tidak. Data yang terdistribusi normal menunjukkan bahwa tidak terdapat nilai ekstrem yang nantinya dapat mengganggu hasil data penelitian. Model regresi yang baik adalah yang memiliki data normal atau mendekati normal (Lutfiani, 2019). Untuk mendeteksi normalitas data maka dilakukan analisis statistik yang salah satunya dapat dilihat melalui uji Shapiro Wilk. Uji Shapiro Wilk adalah sebuah metode atau rumus perhitungan sebaran data yang dibuat oleh shapiro dan wilk. Metode shapiro wilk adalah metode uji normalitas yang efektif dan valid digunakan untuk sampel berjumlah kecil .

Hipotesis :

H_0 : data residual berdistribusi normal

H_1 : data residual tidak berdistribusi normal

Pedoman yang digunakan dalam pengambilan keputusan yaitu :

1. Jika nilai *asympt.sig (2 tailed)* > 0,05 maka data berdistribusi normal.
2. Jika nilai *asympt.sig (2 tailed)* < 0,05 maka data tidak berdistribusi normal.

2.1.2.2 Uji Multikolinieritas

Uji Multikolinieritas bertujuan menguji adanya korelasi antar variabel bebas pada model regresi. Model regresi yang baik seharusnya tidak terjadi korelasi diantara variabel bebas. Jika variabel bebas saling berkorelasi, maka

variabel–variabel ini tidak ortogonal atau memiliki koefisien korelasi yang tidak sama dengan nol terhadap variabel bebas lainnya. Adanya multikolinearitas menyebabkan suatu model regresi memiliki varian yang besar, sehingga mengakibatkan sulit mendapatkan estimasi yang tepat, interval konsistensi cenderung lebih lebar dan nilai hitung statistik uji t akan lebih kecil. Pedoman yang digunakan dalam pengambilan keputusan yaitu (Lutfiani, 2019) :

1. Jika nilai *tolerance* > 0,1 dan *VIF* < 10 maka tidak terdapat multikolinearitas.
2. Jika nilai *tolerance* < 0,1 dan *VIF* > 10 maka terdapat multikolinearitas.

2.1.2.3 Uji Heteroskedastisitas

Uji heteroskedastisitas digunakan untuk melihat apakah terdapat ketidaksamaan varians dari residual satu ke pengamatan-pengamatan lainnya. Untuk mendeteksi ada atau tidaknya gejala heteroskedastisitas dalam model penelitian yang dianalisis dapat dilakukan menggunakan uji *breusch-pagan*.

Hipotesisnya adalah:

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

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

Nilai dari *BP test* adalah :

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

dimana :

BP = *Breusch Pagan*.

$$\mathbf{f} = (f_1, f_2, \dots, f_n)^T; \mathbf{f} = \left(\frac{\varepsilon_i^2}{\sigma^2} - 1\right).$$

ε_i = $(y_i - \hat{y}_i)$ *least square residual* untuk pengamatan ke-i.

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

Tolak H_0 jika $p\text{-value} < \alpha$ dengan p adalah banyaknya prediktor.

2.1.2.4 Uji Autokorelasi

Autokorelasi dapat diartikan sebagai adanya korelasi antara observasi satu dengan observasi lain yang berlainan waktu. Dalam kaitannya dengan asumsi metode kuadrat terkecil (OLS), autokorelasi merupakan korelasi antara satu residual dengan residual yang lain. Sedangkan asumsi penting, metode OLS berkaitan dengan residual adalah tidak adanya hubungan antara residual satu dengan residual lain. Cara yang digunakan untuk mendeteksi masalah autokorelasi adalah dengan menggunakan uji Durbin Watson. Menurut Ghozali (2009) dalam Lutfiani (2019), uji Durbin Watson merupakan uji paling baik digunakan pada penelitian dengan jumlah data ≤ 100 .

Tabel 2.1 Ketentuan Autokorelasi

Kesimpulan	Daerah Pengujian
Terjadi Autokorelasi Positif	$d_w < d_L$
Terjadi Autokorelasi Negatif	$d_w > (4 - d_L)$
Tidak Ada kesimpulan	$d_L \leq d_w \leq d_u$ atau $4 - d_u \leq d_w \leq 4 - d_L$
Tidak Terjadi Autokorelasi	$d_u < d_w < 4 - d_u$

2.1.3 Regresi Data Panel

Data panel merupakan data gabungan antara data *cross section* dan data *time series*. Menurut Jaya & Sunengsih (2009) dalam Meutuah (2017) analisis regresi data panel adalah regresi yang didasarkan pada data panel untuk mengamati hubungan antara satu variabel terikat dengan satu atau lebih variabel

bebas. Model regresi panel yang hanya dipengaruhi oleh salah satu unit saja (unit *cross section* atau unit waktu) disebut model komponen satu arah, sedangkan model regresi panel yang dipengaruhi oleh kedua unit (unit *cross section* dan unit waktu) disebut model komponen dua arah (Pangestika, 2015 dalam Fitri, 2019).

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 dalam Fitri, 2019). Model regresi linier menggunakan data *cross section* dan *time series*.

1. Model dengan data *cross section*

$$Y_i = \alpha + \beta X_i + \varepsilon_i ; i = 1, 2, \dots, N$$

dengan :

Y_i = peubah terikat unit individu ke- i

α = konstanta

β = koefisien regresi

X_i = peubah bebas unit individu ke- i

N = banyaknya data *cross section*

ε_i = *error data cross section*

2. Model dengan data *time series*

$$Y_t = \alpha + \beta X_t + \varepsilon_t ; t = 1, 2, \dots, T$$

dengan :

Y_t = peubah terikat unit waktu ke-t

α = konstanta

β = koefisien regresi

X_t = variabel bebas unit waktu ke-t

T = banyaknya data *time series*

ε_i = *error data time series*

Mengingat data panel merupakan gabungan dari data *cross section* dan data *time series*, maka modelnya dituliskan dengan (Caraka, 2017) :

$$Y_{it} = \alpha + \beta'x_{it} + u_{it} ; i = 1,2,\dots,N; t = 1,2,\dots,T$$

dengan:

$i = 1, 2, \dots, N$, menunjukkan individu

$t = 1, 2, \dots, T$, menunjukkan dimensi deret waktu

α = koefisien intersep yang merupakan skalar

β = koefisien slope dengan dimensi $K \times 1$, dimana K adalah banyaknya peubah bebas

Y_{it} = peubah terikat unit individu ke-i dan unit waktu ke-t

x_{it} = peubah bebas untuk unit individu ke-i dan unit waktu ke-t

2.1.4 Estimasi Parameter 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*

Teknik ini tidak ubahnya dengan membuat regresi dengan data *cross section* atau *time series*. Akan tetapi, untuk data panel, sebelum membuat regresi data harus digabungkan terlebih dahulu yaitu data *cross-section* dengan data *time series*. Kemudian data gabungan ini diperlakukan sebagai suatu kesatuan pengamatan untuk mengestimasi model dengan metode *Ordinary Least Square* (OLS). Metode ini dikenal dengan estimasi *Common Effect*. Akan tetapi, dengan menggabungkan data tersebut, maka tidak dapat dilihat perbedaannya baik antar individu maupun antar waktu. Atau dengan kata lain, dalam pendekatan ini tidak memperhatikan dimensi individu maupun waktu (Caraka, 2017).

Persamaan *Common Effect Model* dituliskan sebagai berikut (Greene, 2000 dalam Fitri, 2019) :

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

dengan :

Y_{it} : variabel respon pada ke- i dan waktu ke- t

α : koefisien intersep model regresi

β : koefisien *slope* atau koefisien arah

X_{it}^T : $(X_{1it}, X_{2it}, \dots, X_{pit})$ variabel bebas untuk pengamatan ke- i pada periode waktu ke- t

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

Estimasi parameter model CEM yaitu :

$$\hat{\beta} = (X^T X)^{-1} X^T Y$$

2.1.4.2 Fixed Effect Model

Pendekatan metode kuadrat terkecil biasa adalah pendekatan dengan mengasumsikan bahwa intersep dan koefisien regresi dianggap konstan untuk seluruh unit wilayah/daerah maupun unit waktu. Salah satu cara untuk memperhatikan unit *cross section* atau unit *time series* adalah dengan memasukkan variabel dummy untuk memberikan perbedaan nilai parameter yang berbeda-beda, baik lintas unit *cross section* maupun unit *time series*. Oleh karena itu pendekatan dengan memasukkan variabel dummy ini dikenal juga dengan *Least Square Dummy Variable* (LSDV) atau juga disebut *covariance* model. Pendekatan yang sering paling dilakukan adalah dengan mengizinkan intersep bervariasi antar unit *cross section* namun tetap mengasumsikan bahwa slope koefisien adalah konstan antar unit *cross section*. Pendekatan ini dalam literatur dikenal dengan sebutan model *fixed effect* (FEM) (Caraka, 2017). Model FEM dapat dinyatakan sebagai berikut (Greene, 2000 dalam Rahayu, 2017) :

$$y_{it} = \mathbf{x}_{it}^T \boldsymbol{\beta} + \mathbf{i} \alpha_i + \varepsilon_i$$

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{bmatrix} = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_N \end{bmatrix} \boldsymbol{\beta} + \begin{bmatrix} \mathbf{i} & 0 & \dots & 0 \\ 0 & \mathbf{i} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \mathbf{i} \end{bmatrix} \begin{bmatrix} \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_N \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_N \end{bmatrix}$$

atau

$$\mathbf{y} = [\mathbf{X} \quad \mathbf{d}_1 \quad \mathbf{d}_2 \quad \dots \quad \mathbf{d}_N] \begin{bmatrix} \boldsymbol{\beta} \\ \boldsymbol{\alpha} \end{bmatrix} + \boldsymbol{\varepsilon}$$

dimana

\mathbf{d}_i = variabel dummy unit pengamatan ke- i

Misalkan $\mathbf{D} = [\mathbf{d}_1 \quad \mathbf{d}_2 \quad \dots \quad \mathbf{d}_N]$ matriks berukuran $\mathbf{NT} \times \mathbf{N}$, maka,

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{D}\boldsymbol{\alpha} + \boldsymbol{\varepsilon}$$

Model di atas disebut *fixed effect* meskipun intersep berbeda untuk setiap unit *cross section*, namun konstan untuk setiap unit *time series* (Gurajati D, 2004 dalam Rahayu, 2017). Estimator parameter untuk $\boldsymbol{\beta}$ adalah :

$$\boldsymbol{\beta} = [\mathbf{X}^T \mathbf{M}_D \mathbf{X}]^{-1} [\mathbf{X}^T \mathbf{M}_D \mathbf{y}]$$

dimana $\mathbf{M}_D = \mathbf{I} - \mathbf{D}(\mathbf{D}^T \mathbf{D})^{-1} \mathbf{D}^T$

2.1.4.3 Random Effect Model

Random Effect Model (REM) merupakan metode yang mengasumsikan perbedaan intersep pada unit *cross section* adalah variabel acak. Persamaan REM diformulasikan sebagai berikut (Greene, 2000 dalam Fitri, 2019) :

$$Y_{it} = (\alpha + \mu_i) + \boldsymbol{\beta} \mathbf{x}_{it}^T + \varepsilon_{it}$$

dimana :

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

\mathbf{x}_{it}^T : (X_{1it} , X_{2it} , ..., X_{pit}) variabel bebas untuk pengamatan ke-i pada periode waktu ke- t berukuran $1 \times p$

$\boldsymbol{\beta}$: koefisien *slope* atau koefisien arah

α : *intercept* model regresi

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

μ_i : komponen error *cross section*

Adapun asumsi yang digunakan untuk komponen error yaitu :

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

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

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

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

$$E[\varepsilon_{it}\varepsilon_{js} | X] = 0 \text{ untuk semua } t \neq s \text{ atau } i \neq j$$

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

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). Estimasi parameter model REM yaitu :

$$\hat{\beta} = Y^T(I - X(X^T W X)^{-1} X^T W) Y$$

2.1.5 Aspek Data Spasial

Analisis spasial dilakukan jika data yang digunakan memenuhi aspek spasial, yaitu memiliki sifat error yang saling berkorelasi (*spatial dependence*) dan memiliki heterogenitas spasial (*spatial heterogeneity*) (Rahayu, 2017).

2.1.5.1 Spatial Dependence

Salah satu masalah yang terjadi karena perbedaan lokasi adalah adanya ketergantungan spasial. Pengujian *spatial dependence* dilakukan untuk melihat apakah pengamatan di suatu lokasi berpengaruh terhadap pengamatan di lokasi lain yang berdekatan. Pengujian ini dapat dilakukan melalui *Moran's I Statistic* (Anselin, 1988 dalam Rahayu, 2017).

$$I = \frac{[N]}{[S]} \cdot \left\{ \frac{|\varepsilon^T W \varepsilon|}{\varepsilon^T \varepsilon} \right\}$$

Dimana ε adalah vektor residual dari OLS, W yaitu matriks pembobot spasial, N adalah jumlah observasi dan S adalah faktor standarisasi. Untuk matrik

pembobot yang terstandarisasi maka $\left[\frac{M}{S}\right]$ bernilai satu. Hipotesis pada statistik

Morans' I adalah:

H_0 = Tidak terjadi *spatial dependence*

H_1 = Terjadi *spatial dependence*

Statistik uji yang digunakan adalah (Rahayu, 2017):

$$ZI = \frac{(\hat{I} - \varepsilon(\hat{I}))}{\sqrt{\text{var}(\hat{I})}}$$

Tolak H_0 jika $|ZI| \geq Z_{\alpha/2}$

2.1.5.2 *Spatial Heterogeneity*

Heterogenitas spasial terjadi akibat adanya perbedaan karakteristik satu wilayah dengan wilayah lainnya (efek wilayah yang random). Menguji heterogenitas spasial dalam model regresi sangat penting karena mengabaikan hal tersebut akan menyebabkan estimasi tidak efisien dan kesimpulan yang diperoleh kurang sesuai. Pengujian heterogenitas spasial dilakukan dengan menggunakan statistik uji Breusch-Pagan (Rahayu, 2017). Hipotesisnya adalah:

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

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

Nilai dari *BP test* adalah :

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

dimana :

BP = Breusch Pagan.

$$\mathbf{f} = (f_1, f_2, \dots, f_n)^T; \mathbf{f} = \left(\frac{\varepsilon^2}{\sigma^2} - 1\right).$$

$\varepsilon_i = (y_i - \hat{y}_i)$ *least square residual* untuk pengamatan ke- i .

\mathbf{Z} = matriks berukuran $n \times (p + 1)$ yang berisi vektor yang sudah dinormal standarkan untuk setiap pengamatan. Tolak H_0 jika $p\text{-value} < \alpha$ dengan p adalah banyaknya prediktor.

2.1.6 Pemilihan Model Estimasi Regresi Data Panel

Pemilihan model secara statistik dilakukan agar dugaan yang diperoleh dapat seefisien mungkin. Ada dua pengujian dalam menentukan model yang akan digunakan dalam pengolahan data panel yaitu uji chow (*Chow Test*) dan uji hausman (*Hausman Test*).

2.1.6.1 Uji Chow

Chow test digunakan untuk memilih kedua model diantara Model *Common Effect* dan Model *Fixed Effect*. Asumsi bahwa setiap unit *cross section* memiliki perilaku yang sama cenderung tidak realistis mengingat dimungkinkannya setiap unit *cross section* memiliki perilaku yang berbeda menjadi dasar dari uji chow. Dalam pengujian ini dilakukan hipotesa sebagai berikut :

$H_0 : \alpha_1 = \alpha_2 = \dots = \alpha_N = 0$ (Model *Common Effect*)

H_1 : sekurang-kurangnya ada satu intersep α_i yang berbeda (Model *Fixed Effect*)

Dasar penolakan terhadap H_0 adalah dengan menggunakan F-statistik seperti berikut (Caraka, 2017) :

$$\text{Chow} = \frac{RSS_1 - RSS_2 / (N - 1)}{RSS_2 / (NT - N - K)}$$

dengan:

RSS_1 = *residual sum of square* hasil pendugaan model *common effect*

RSS_2 = *residual sum of square* hasil pendugaan model *fixed effect*

N = jumlah data *cross section*

T = jumlah data *time series*

K = jumlah variabel bebas

Statistik *Chow Test* mengikuti sebaran F-statistik yaitu $F_{(N-1,NT-N-K);\alpha}$. Jika nilai Chow statistik lebih besar dari F-tabel, maka cukup bukti untuk menolak H_0 dan sebaliknya.

2.1.6.2 Uji Hausman

Uji hausman digunakan untuk membandingkan model *Fixed Effect* dengan *Random effect*. Alasan dilakukannya uji hausman didasarkan pada model *fixed effect* model yang mengandung suatu unsur trade off yaitu hilangnya unsur derajat bebas dengan memasukkan variabel dummy dan model *Random Effect* yang harus memperhatikan ketiadaan pelanggaran asumsi dari setiap komponen galat. Dalam pengujian ini dilakukan hipotesis sebagai berikut:

$H_0 : \text{corr}(X_{it}, U_{it}) = 0$ (Model *Random Effect*)

$H_1 : \text{corr}(X_{it}, U_{it}) \neq 0$ (Model *Fixed Effect*)

Dasar penolakan H_0 dengan menggunakan Statistik Hausman dirumuskan sebagai berikut (Caraka, 2017) :

$$X^2K = (\mathbf{b} - \boldsymbol{\beta})' \text{var} [(\mathbf{b} - \boldsymbol{\beta})]^{-1} (\mathbf{b} - \boldsymbol{\beta})$$

dengan:

X^2 = chi-square

\mathbf{b} = koefisien *random effect*

$\boldsymbol{\beta}$ = koefisien *fixed effect*

Statistik hausman menyebar *Chi-Square*, jika nilai 2 hasil pengujian lebih besar dari 2 (K, α) (K = jumlah variabel bebas) atau $p\text{-value} < \alpha$, maka cukup bukti untuk melakukan penolakan terhadap H_0 begitu pula sebaliknya.

2.1.7 *Geographically Weighted Regression*

Model *Geographically Weighted Regression* (GWR) merupakan pengembangan dari metode regresi. Hanya saja pada model GWR parameter persamaan untuk setiap lokasi pengamatan berbeda dengan lokasi lainnya sehingga banyaknya vektor parameter yang diduga adalah sebanyak lokasi pengamatan yang digunakan dalam data. Dalam analisis GWR, model yang dihasilkan juga tidak dapat digunakan untuk menduga parameter selain parameter di lokasi pengamatan (Walter et al. 2005 dalam Lutfiani, 2019).

GWR adalah salah satu analisis yang bersifat lokal dan regresi merupakan contoh analisis global. Secara garis besar, perbedaan analisis regresi dan GWR dapat dirumuskan seperti Tabel 2.2. Dalam regresi, nilai parameter diasumsikan sama untuk semua titik lokasi pengamatan, sehingga penduga parameter yang dihasilkan juga bersifat tunggal dan diberlakukan untuk semua lokasi. Sedangkan dalam GWR, nilai parameter tiap lokasi berbeda dengan lokasi lainnya sehingga penduga parameter yang dihasilkan juga banyak sesuai jumlah lokasi pengamatan data yang digunakan (*multi-valued statistics*). Berbeda dengan regresi yang tidak memperhatikan faktor lokasi (tempat), dalam GWR sangat memperhatikan lokasi (*space*) sehingga analisis ini seringkali dilanjutkan dengan pemetaan dan dapat didekati dengan Sistem Informasi Geografis atau *Geographic Information System* (GIS) (Lutfiani, 2019).

Tabel 2.2 Perbedaan Regresi dan GWR

	Regresi Biasa	GWR
Nilai parameter	Sama untuk semua lokasi, tidak bisa dipetakan	Berbeda untuk setiap lokasi, sehingga bisa dipetakan
Nilai Statistik	Tunggal (hanya satu)	Banyak (sebanyak lokasi)
GIS	Tidak ada	Ada
Faktor Lokasi	Tidak diperhatikan	Diperhatikan

Pendekatan yang dilakukan dalam GWR adalah pendekatan titik. Setiap nilai parameter ditaksir pada setiap titik lokasi pengamatan, sehingga setiap titik lokasi pengamatan mempunyai nilai parameter yang berbeda-beda.

Model dari Geographically Weighted Regression (GWR) dapat ditulis sebagai berikut :

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

dimana :

Y_i : nilai variabel terikat pada titik lokasi pengamatan ke- i

X_{ik} : nilai variabel bebas ke- k pada titik lokasi pengamatan ke- i

(u_i, v_i) : koordinat titik lokasi pengamatan ke- i (longitude, latitude)

$\beta_0(u_i, v_i)$: koordinat / *intercept* GWR

$\beta_k(u_i, v_i)$: koefisien regresi ke- k pada titik lokasi pengamatan ke- i

ε_i : error pada titik lokasi ke- i yang diasumsikan dengan rata-rata nol dan varians σ^2

2.1.8 Fungsi Pembobot

Dalam menganalisis model yang mempertimbangkan pengaruh spasial diperlukan pembobot spasial dalam perhitungannya. Pembobot spasial menjelaskan letak lokasi amatan yang satu dengan yang lainnya. Menurut Fotheringham et al (2002) dalam Lutfiani (2019), terdapat beberapa fungsi kernel yang dijadikan sebagai pembobot spasial dalam analisis spasial, antara lain:

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) , $(d_{ij})^2 = (u_i - u_j)^2 + (v_i - v_j)^2$ adalah jarak *eucliden* antara lokasi (u_i, v_i) dan lokasi (u_j, v_j) . Pembobot ini dapat ditulis (Lutfiani, 2019) :

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

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 diantaranya :

i. Gaussian

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

ii. Bisquare

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

iii. Tricube

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

d_{ij} adalah jarak antara titik di lokasi i dan lokasi j yang didapatkan 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 :

i. *Adaptive Gaussian*

Menurut Susanti, D. S, dkk (2016), fungsi *adaptive gaussian kernel* yang diusulkan oleh Brunson et al. (1998) dalam Fitri (2019) memiliki persamaan:

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

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.

ii. *Adaptive Bisquare*

Menurut Susanti, D. S, dkk (2016), fungsi *adaptive bisquare kernel* yang diusulkan oleh Brunson et al. (1998) dalam Fitri (2019) memiliki persamaan :

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

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 *bandwith* yang menunjukkan jumlah atau proporsi dari observasi untuk dimasukkan pada estimasi regresi di lokasi pengamatan ke- i .

iii. *Adaptive Exponential*

Menurut Pamungkas et al (2016) fungsi *adaptive exponential kernel* yaitu :

$$W_{ij} = \exp\left(\frac{-d_{ij}}{h_i}\right)$$

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

2.1.9 Penentuan *Bandwith*

Dalam fungsi pembobot kernel di atas, terdapat parameter *bandwidth* yang nilainya tidak diketahui. Sehingga, perlu dilakukan penaksir terhadap parameter *bandwidth* tersebut. *Bandwidth* dapat di analogikan sebagai radius (b) suatu lingkaran, sehingga sebuah titik lokasi pengamatan yang berada dalam radius lingkaran masih dianggap berpengaruh dalam membentuk parameter di titik lokasi pengamatan ke- i . Pemilihan *bandwidth* optimum dalam GWR merupakan hal

yang penting karena akan mempengaruhi ketepatan model terhadap data (Lutfiani, 2019).

Nilai *bandwidth* yang sangat kecil akan mengakibatkan penaksiran parameter di lokasi pengamatan ke- i semakin bergantung pada titik lokasi pengamatan lain yang memiliki jarak terdekat dengan lokasi pengamatan ke- i , sehingga varians yang dihasilkan akan semakin besar. Sebaliknya, jika nilai *bandwidth* sangat besar maka akan mengakibatkan bias yang semakin besar, sehingga model yang diperoleh terlalu halus (Dwinata, 2012 dalam Lutfiani, 2019).

Validasi silang (*cross validation*) merupakan salah satu cara yang dapat digunakan sebagai kriteria untuk mendapatkan nilai lebar jendela optimum. Lebar jendela optimum yang digunakan adalah yang menghasilkan nilai koefisien validasi silang minimum, dengan rumus koefisiennya adalah (Fortheringham et al, 2002 dalam Lutfiani, 2019) :

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

dengan:

CV : *Cross Validation*

$\hat{y}_{\neq i}(b)$: nilai dugaan y_i (*fitting value*) dengan pengamatan di lokasi ke- i dihilangkan dari proses prediksi .

Lebar jendela optimum diperoleh dengan proses iterasi hingga didapatkan CV minimum.

2.1.10 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 geografis merupakan realisasi dari sebuah proses *smooth spatiotempora*. 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 (Fitri, 2019) :

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

dengan:

y_{it} : variabel terikat 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 bebas ke-di lokasi pengamatan ke-i pada waktu ke-t.

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

K : jumlah variabel bebas

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

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

2.1.10.1 Estimasi Parameter Model GWPR

Estimasi parameter pada model GWPR menggunakan metode *Weighted Least Square* (WLS) yaitu dengan memberikan unsur pembobot yang berbeda di setiap lokasi dan waktu pengamatan. Unsur pembobot $W_{it}(u_{it}, v_{it})$, sehingga :

$$w_{it}^{\frac{1}{2}}(u_{it}, v_{it}) \dot{y}_{it} = w_{it}^{\frac{1}{2}}(u_{it}, v_{it}) + \beta_0(u_{it}, v_{it}) + w_{it}^{\frac{1}{2}}(u_{it}, v_{it}) \sum_{k=1}^p \beta_k(u_{it}, v_{it}) \ddot{x}_{k,it} + w_{it}^{\frac{1}{2}}(u_{it}, v_{it}) \ddot{\varepsilon}_{it}$$

Selanjutnya, meminumkan jumlah kuadrat error menjadi :

$$\begin{aligned} & \sum_{t=1}^T \sum_{i=1}^N W_{it}(u_{it}, v_{it}) \ddot{\varepsilon}_{it}^2 \\ &= \sum_{t=1}^T \sum_{i=1}^N W_{it}(u_{it}, v_{it}) [\dot{y}_{it} - \beta_0(u_{it}, v_{it}) - \sum_{k=1}^p \beta_k(u_{it}, v_{it}) \ddot{x}_{k,it}]^2 \\ &= \sum_{t=1}^T \sum_{i=1}^N W_{it}(u_{it}, v_{it}) [\dot{y}_{it} - \beta_0(u_{it}, v_{it}) - \beta_1(u_{it}, v_{it}) \ddot{x}_{1,it} - \dots - \beta_p(u_{it}, v_{it}) \ddot{x}_{p,it}]^2 \end{aligned}$$

Misalkan $l = (u_{it}, v_{it})$ maka penyelesaian dalam bentuk matriks sebagai berikut :

$$\begin{aligned} \boldsymbol{\varepsilon}^T \mathbf{W}_l \boldsymbol{\varepsilon} &= [\dot{\mathbf{y}} - \ddot{\mathbf{X}} \boldsymbol{\beta}_l]^T \mathbf{W}_l [\dot{\mathbf{y}} - \ddot{\mathbf{X}} \boldsymbol{\beta}_l] \\ &= [\dot{\mathbf{y}}^T - \boldsymbol{\beta}_l^T \ddot{\mathbf{X}}^T] \mathbf{W}_l [\dot{\mathbf{y}} - \ddot{\mathbf{X}} \boldsymbol{\beta}_l] \\ &= \dot{\mathbf{y}}^T \mathbf{W}_l \dot{\mathbf{y}} - \dot{\mathbf{y}}^T \mathbf{W}_l \ddot{\mathbf{X}} \boldsymbol{\beta}_l - \boldsymbol{\beta}_l^T \ddot{\mathbf{X}}^T \mathbf{W}_l \dot{\mathbf{y}} + \boldsymbol{\beta}_l^T \ddot{\mathbf{X}}^T \mathbf{W}_l \ddot{\mathbf{X}} \boldsymbol{\beta}_l \\ &= \dot{\mathbf{y}}^T \mathbf{W}_l \dot{\mathbf{y}} - (\dot{\mathbf{y}}^T \mathbf{W}_l \ddot{\mathbf{X}} \boldsymbol{\beta}_l)^T - \boldsymbol{\beta}_l^T \ddot{\mathbf{X}}^T \mathbf{W}_l \dot{\mathbf{y}} + \boldsymbol{\beta}_l^T \ddot{\mathbf{X}}^T \mathbf{W}_l \ddot{\mathbf{X}} \boldsymbol{\beta}_l \\ &= \dot{\mathbf{y}}^T \mathbf{W}_l \dot{\mathbf{y}} - \boldsymbol{\beta}_l^T \ddot{\mathbf{X}}^T \mathbf{W}_l \dot{\mathbf{y}} - \boldsymbol{\beta}_l^T \ddot{\mathbf{X}}^T \mathbf{W}_l \dot{\mathbf{y}} + \boldsymbol{\beta}_l^T \ddot{\mathbf{X}}^T \mathbf{W}_l \ddot{\mathbf{X}} \boldsymbol{\beta}_l \\ &= \dot{\mathbf{y}}^T \mathbf{W}_l \dot{\mathbf{y}} - 2 \boldsymbol{\beta}_l^T \ddot{\mathbf{X}}^T \mathbf{W}_l \dot{\mathbf{y}} + \boldsymbol{\beta}_l^T \ddot{\mathbf{X}}^T \mathbf{W}_l \ddot{\mathbf{X}} \boldsymbol{\beta}_l \end{aligned}$$

Kemudian diturunkan terhadap $\boldsymbol{\beta}_l^T$

$$\begin{aligned} \frac{\partial \boldsymbol{\varepsilon}^T \mathbf{W}_l \boldsymbol{\varepsilon}}{\partial \boldsymbol{\beta}_l^T} &= \frac{\partial (\dot{\mathbf{y}}^T \mathbf{W}_l \dot{\mathbf{y}} - 2 \boldsymbol{\beta}_l^T \ddot{\mathbf{X}}^T \mathbf{W}_l \dot{\mathbf{y}} + \boldsymbol{\beta}_l^T \ddot{\mathbf{X}}^T \mathbf{W}_l \ddot{\mathbf{X}} \boldsymbol{\beta}_l)}{\partial \boldsymbol{\beta}_l^T} \\ &= \mathbf{0} - 2 \ddot{\mathbf{X}}^T \mathbf{W}_l \dot{\mathbf{y}} + \ddot{\mathbf{X}}^T \mathbf{W}_l \ddot{\mathbf{X}} \boldsymbol{\beta}_l + \mathbf{W}_l (\ddot{\mathbf{X}}^T \boldsymbol{\beta}_l^T \ddot{\mathbf{X}})^T \end{aligned}$$

$$\begin{aligned}
&= -2\ddot{X}^T W_l \ddot{y} + \ddot{X}^T W_l \ddot{X} \beta_l + \ddot{X}^T W_l \ddot{X} \beta_l \\
&= -2\ddot{X}^T W_l \ddot{y} + 2\ddot{X}^T W_l \ddot{X} \beta_l
\end{aligned}$$

Kedua ruas persamaan di atas dikalikan dengan invers dari $\ddot{X}^T W_l \ddot{X}$, sehingga diperoleh :

$$\begin{aligned}
(\ddot{X}^T W_l \ddot{X})^{-1} \ddot{X}^T W_l \ddot{X} \beta_l &= (\ddot{X}^T W_l \ddot{X})^{-1} \ddot{X}^T W_l \ddot{y} \\
\beta_l &= (\ddot{X}^T W_l \ddot{X})^{-1} \ddot{X}^T W_l \ddot{y}
\end{aligned}$$

Kemudian substitusi $l = (u_{it}, v_{it})$, sehingga didapat estimator untuk koefisien regresi lokal pada model GWPR sebagai berikut :

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

dengan $\hat{\beta}(u_{it}, v_{it}) = (\hat{\beta}_{0,it}, \hat{\beta}_{1,it}, \hat{\beta}_{2,it}, \dots, \hat{\beta}_{k,it})^T$ adalah vektor koefisien regresi lokal dan $W(u_{it}, v_{it})$ adalah matriks diagonal dengan elemen pada diagonalnya merupakan pembobot geografis pada setiap data untuk lokai pengamatan ke- i dan waktu ke- t dan 0 merupakan elemen lainnya.

2.1.11 Pemilihan Model Terbaik

Dalam menentukan model terbaik dari *Geographically Weighted panel Regression* dapat dilihat dari nilai koefisien determinasi dan AICnya.

2.1.11.1 Koefisien Determinasi (R^2)

Dalam model regresi global (model regresi linear klasik) koefisien determinasi digunakan untuk mengukur proporsi dari variasi dalam data pengamatan yang dapat dijelaskan oleh model. Nilai R^2 yang kecil atau mendekati nol berarti kemampuan variabel bebas dalam menjelaskan variabel terikat sangat terbatas, sedangkan nilai R^2 mendekati satu berarti kemampuan dari variabel

bebas dalam menjelaskan variabel terikat sangat kuat, sehingga mengidentifikasi bahwa model mampu menjelaskan variabilitas data (Putri, 2013). Nilai R^2 pada fixed effect GWPR dengan matriks pembobot \mathbf{W} ukuran $(nT \times nT)$ dan matriks \mathbf{Y} berukuran $(nT \times 1)$ didefinisikan sebagai berikut :

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

dimana :

TSS = total sum of squares

RSS = residual sum of squares

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

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

y_i = variabel terikat lokasi ke-i

\bar{y}_i = rata-rata variabel terikat

\hat{y}_i = nilai prediksi variabel terikat

2.1.10.2 Akaike Information Criterion (AIC)

Pemilihan model terbaik merupakan proses evaluasi dari model untuk mengetahui seberapa besar peluang masing-masing model yang terbentuk sudah sesuai dengan data. (Fortheringham, et al, 2002 dalam Lutfiani, 2019) menuliskan bahwa selain dapat digunakan untuk menentukan *bandwidth* optimum, AIC juga dapat digunakan dalam pemilihan model untuk menentukan model mana yang terbaik. Penentuan nilai AIC dilakukan dengan perhitungan sebagai berikut (Lutfiani, 2019) :

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

Dimana ($\hat{\sigma}$) adalah nilai duga standar deviasi residual, S adalah hat matrix dan π adalah kostanta . Model yang didapatkan dari perhitungan dengan nilai AIC terkecil.

2.2 Tinjauan Non Statistik

2.2.1 Teori Produk Domestik Regional Bruto (PDRB)

A. Pengertian Produk Domestik Regional Bruto (PDRB)

Produk Domestik Regional Bruto (PDRB) menurut Badan Pusat Statistik adalah sebagai jumlah nilai tambah bruto yang dihasilkan oleh unit usaha dalam suatu wilayah domestik. Atau merupakan jumlah hasil seluruh nilai barang dan jasa akhir yang dihasilkan oleh seluruh kegiatan ekonomi dalam suatu wilayah. PDRB merupakan salah satu indikator penting dalam pertumbuhan ekonomi di suatu wilayah tertentu dan dalam suatu periode tertentu (setahun) yang dihasilkan oleh seluruh kegiatan ekonomi dalam suatu negara atau suatu daerah, ada dua cara dalam penyajian PDRB, yaitu atas dasar harga berlaku dan atas dasar harga konstan (Sukirno, 2011).

1. PDRB atas dasar harga berlaku menunjukkan nilai tambah barang dan jasa yang dihitung menggunakan harga pada tahun berjalan dan digunakan untuk mengetahui kemampuan sumber daya ekonomi dan struktur daerah ekonomi suatu daerah.
2. PDRB atas dasar harga konstan menunjukkan nilai tambah barang dan jasa tersebut dapat dihitung menggunakan harga barang yang berlaku pada satu tahun tertentu sebagai tahun dasar dan digunakan untuk mengetahui pertumbuhan ekonomi secara riil dari tahun ke tahun

Untuk menghitung angka-angka PDRB ada tiga pendekatan yang dapat digunakan yaitu pendekatan produksi, pendekatan pendapatan dan pendekatan pengeluaran:

1. Pendekatan Produksi, PDRB adalah jumlah nilai tambah atas barang dan jasa yang dihasilkan oleh berbagai unit produksi di wilayah suatu daerah dalam jangka waktu tertentu (biasanya satu tahun).
2. Pendekatan Pendapatan, PDRB merupakan jumlah balas jasa yang diterima oleh faktor-faktor produksi yang ikut serta dalam proses produksi di suatu daerah dalam jangka waktu tertentu (biasanya satu tahun). Pendekatan Pengeluaran, PDRB adalah semua komponen permintaan akhir yang terdiri dari: (1) pengeluaran konsumsi rumahtangga dan lembaga swasta nirlaba, (2) konsumsi pemerintah, (3) pembentukan modal tetap domestik bruto, (4) perubahan stok dan (5) ekspor neto, (ekspor neto merupakan ekspor dikurangi impor). Secara konsep tiga pendekatan tersebut akan menghasilkan angka yang sama. Dalam publikasi ini disajikan PDRB dengan pendekatan produksi dimana unit-unit produksi dalam penyajian ini dikelompokkan menjadi 17 kategori lapangan usaha.

B. Kegunaan Data PDRB

Data PDRB adalah salah satu indikator ekonomi makro yang dapat menunjukkan kondisi perekonomian daerah setiap tahun. Manfaat yang dapat diperoleh dari data ini antara lain:

1. PDRB atas dasar harga berlaku (nominal) menunjukkan kemampuan sumber daya ekonomi yang dihasilkan suatu daerah. Nilai PDRB yang besar

2. menunjukkan kemampuan sumber daya ekonomi yang besar, begitu juga sebaliknya.
3. PDRB atas harga konstan (riil) dapat digunakan untuk menunjukkan laju pertumbuhan ekonomi secara keseluruhan atau setiap lapangan usaha dari tahun ke tahun.
4. Distribusi PDRB atas harga berlaku menurut lapangan usaha menunjukkan struktur perekonomian atau peranan setiap lapangan usaha dalam suatu daerah. Lapangan usaha yang mempunyai peran besar menunjukkan basis perekonomian suatu daerah.
5. PDRB per kapita atas dasar harga berlaku menunjukkan nilai PDRB per kepala atau per satu orang penduduk.
6. PDRB per kapita atas dasar harga konstan berguna untuk mengetahui pertumbuhan nyata ekonomi per kapita penduduk suatu daerah.

2.2.2 Pengangguran

Pengangguran menurut Sukirno (2004) dalam Puteri (2018) dapat diartikan sebagai seseorang yang sudah digolongkan dalam angkatan kerja yang secara aktif sedang mencari pekerjaan pada suatu tingkat upah tertentu, tetapi tidak dapat memperoleh pekerjaan yang diinginkannya. Sementara itu menurut Nanga (2001) dalam Puteri (2018) memberikan definisi pengangguran sebagai suatu keadaan dimana seseorang yang tergolong dalam kategori angkatan kerja tidak memiliki pekerjaan dan secara aktif sedang mencari pekerjaan. Dari dua pengertian ini maka dapat disimpulkan bahwa pengangguran adalah keadaan dimana seseorang yang termasuk kedalam angkatan kerja namun tidak

mendapatkan pekerjaan. Berdasarkan cirinya menurut Sukirno (2000) dalam Puteri (2018) membaginya menjadi beberapa kelompok yaitu sebagai berikut:

1. Pengangguran Terbuka

BPS Jateng (2017) menggolongkan pengangguran terbuka dalam empat kategori berikut:

- a. Masyarakat yang tidak mempunyai pekerjaan dan sedang aktif mencari pekerjaan.
- b. Masyarakat yang tidak memiliki pekerjaan namun mereka sedang mempersiapkan usaha.
- c. Masyarakat yang tidak memiliki pekerjaan dan tidak berupaya mencari pekerjaan. Masyarakat pada kondisi ini adalah merakayang merasa tidak akan mungkin memperoleh pekerjaan kendati berupaya mencarinya.
- d. Masyarakat yang telah memiliki pekerjaan, namun mereka belum memulainya.

Secara definisi pengangguran terbuka menurut Sukirno (2000) dalam Puteri (2018) adalah persentase penduduk yang mencari pekerjaan, yang mempersiapkan usaha, yang tidak mencari pekerjaan, karena merasa tidak mungkin mendapatkan pekerjaan, yang sudah mempunyai pekerjaan tetapi belum mulai bekerja dari sejumlah angkatan kerja yang ada.

Tingginya pengangguran terbuka mengindikasikan jika penduduk yang telah memasuki usia kerja namun belum mendapatkan pekerjaan. Tingkat pengangguran kerja diukur sebagai persentase jumlah penganggur terhadap jumlah angkatan kerja. Sebagaimana formula berikut :

$$TPT = \frac{\text{Jumlah Pengangguran}}{\text{Jumlah Angkatan Kerja}} \times 100$$

Pada umumnya menurut Kuncoro (2000) dalam Puteri (2018) angka pengangguran terbuka pada daerah yang memiliki industri banyak maka angka pengangguran terbukanya akan cenderung tinggi. Hal ini disebabkan masyarakat yang baru saja menyelesaikan pekerjaan akan mencari pekerjaan yang sesuai dengan kompetensi yang mereka dapatkan ketika menempuh pendidikan. Sehingga tidak menutup kemungkinan jika masyarakat tersebut mencari atau menunggu peluang untuk bekerja pada sektor industri yang mereka harapkan.

2. Pengangguran Tersembunyi

Pengangguran semacam ini merupakan tenaga kerja yang telah bekerja namun tidak melakukan pekerjaan itu secara optimal. Hal ini disebabkan kapasitas perusahaan atau industri yang kecil, sehingga untuk menghemat biaya tenaga kerja perusahaan tidak mempekerjakan karyawannya secara penuh. Dengan demikian akan terjadi surplus tenaga kerja, surplus inilah yang menurut Sukirno (2000) dalam Puteri (2018) digolongkan dalam pengangguran tersembunyi.

3. Setengah Menganggur

Pengangguran jenis ini biasanya disebabkan oleh ketiadaan lapangan kerja disuatu daerah (Sukirno, 2000 dalam Puteri, 2018). Keterbatasan inilah yang menyebabkan masyarakat hanya dapat bekerja hanya 2 hari dalam seminggu. Kondisi semacam ini maka dapat dikategorikan setengah menganggur.

4. Pengangguran Bermusim

Menurut Sukirno (2000) dalam Puteri (2018) jenis pengangguran ini banyak terjadi pada daerah pertanian. Pada musim panen banyak lapangan pekerjaan yang dapat dimanfaatkan, namun pasca panen pekerjaan sudah tidak ada lagi.

2.2.3 Angkatan Kerja

Angkatan kerja dapat dikatakan sebagai bagian dari tenaga kerja yang sesungguhnya terlibat atau berusaha untuk terlibat dalam kegiatan produktif, yaitu memproduksi barang atau jasa dalam kurun waktu tertentu. (Kusumosuwidho, 2010 dalam Puteri, 2018). Sementara itu menurut Zenda & Suparno (2017) dalam Puteri (2018) angkatan kerja adalah penduduk usia kerja yang sedang bekerja, sedang tidak bekerja dan sedang mencari pekerjaan.

2.2.4 Kemiskinan

Kemiskinan adalah ketidakmampuan individu dalam memenuhi kebutuhan dasar minimal untuk hidup layak (BPS dan Depsos, 2002 dalam Puteri, 2018). Kemiskinan bersifat multidimensial, yang berarti kebutuhan manusia bermacam-macam sehingga terdapat banyak aspek dalam kemiskinan. Aspek primer berupa miskin akan asset, organisasi social politik dan pengetahuan, serta ketrampilan. Aspek sekunder berupa miskin jaringan social, sumber-sumber keuangan dan informasi, dimensi-dimensi kemiskinan tersebut termanifestasi dalam bentuk kekurangan gizi, air, perumahan sehat, perawatan kesehatan yang kurang baik dan rendahnya tingkat pendidikan (Sukirno, 2006 dalam Puteri, 2018).

2.2.5 Pengeluaran Pemerintah

Pemerintah berperan di dalam menyediakan kebutuhan akan barang dan jasa publik yang tak dapat disediakan sektor swasta. Menurut pendapat Keynes dalam Sukirno (2000) bahwa peranan atau campur tangan pemerintah masih sangat diperlukan yaitu apabila perekonomian sepenuhnya diatur oleh kegiatan pasar bebas, bukan saja perekonomian tidak selalu mencapai tingkat kesempatan kerja penuh tetapi juga kestabilan kegiatan ekonomi tidak dapat diwujudkan.

Barang publik memiliki ciri khas yaitu tersedianya adalah karena campur tangan pemerintah dalam rangka memenuhi kebutuhan masyarakat akan barang dan jasa yang relatif murah (karena harga disubsidi pemerintah), tidak dapat dikecualikan (non-excludable), karena dapat dinikmati oleh orang lain dan tidak pula bersaing (non-rival). Dalam hal ini fokus penelitian pada sektor pendidikan, kesehatan dan infrastruktur. Ketiga elemen ini sangat penting dan pemerintah bertanggungjawab dalam hal menyediakan sarana dan prasarana ini untuk publik/masyarakat. Total pengeluaran pemerintah merupakan penjumlahan keseluruhan dari keputusan anggaran pada masing-masing tingkat pemerintahan (pusat-propinsi-daerah). (Lee Robert, Jr dan Ronal W. Johnson, 1998 dalam Ii, 2002).

2.2.6 Fasilitas Kesehatan

Pembangunan kesehatan adalah upaya untuk memenuhi salah satu hak dasar rakyat terakses fasilitas pelayanan kesehatan karena kesehatan adalah hak asasi manusia (Sulistyorini dkk, 2011 dalam Garcia Rayes dan Luis Enquire,2017).

Berdasarkan Peraturan Menteri Kesehatan No 6 tahun 2013 fasilitas pelayanan kesehatan dibagi menjadi tiga yaitu :

- A. Fasilitas kesehatan tingkat pertama adalah jenis fasilitas pelayanan kesehatan yang melayani dan melaksanakan pelayanan kesehatan dasar.
- B. Fasilitas kesehatan tingkat kedua adalah jenis fasilitas pelayanan kesehatan yang melayani dan memberikan pelayanan kesehatan dasar dan pelayanan kesehatan spesialisik
- C. Fasilitas kesehatan tingkat ketiga adalah jenis pelayanan kesehatan yang melayani dan melaksanakan pelayanan kesehatan dasar, pelayanan kesehatan spesialisik, dan pelayanan kesehatan sub spesialisik.

2.2.7 Rata - Rata Lama Sekolah

Rata-rata lama sekolah didefinisikan sebagai pendidikan formal yang digunakan penduduk dalam jumlah tahun. Cakupan penduduk yang dihitung adalah usia 25 tahun ke atas. Angka harapan lama sekolah didefinisikan sebagai lamanya sekolah (tahun) yang diharapkan akan dirasakan oleh anak umur tertentu di masa mendatang. Angka harapan lama sekolah dihitung untuk penduduk usia 7 tahun ke atas. Dimensi pendidikan ini digunakan untuk mengetahui kondisi pembangunan sistem pendidikan (Kabualdi, 2014).