

## BAB II

### TINJAUAN PUSTAKA

#### 2.1 Matriks

Matriks adalah susunan bilangan atau elemen yang tersusun menurut baris dan kolom sehingga berbentuk persegi. Matriks dinotasikan dengan huruf kapital A,B,K dan sebagainya. Banyaknya baris dan kolom suatu matriks menentukan ukuran dari segi matriks tersebut yang disebut dengan ordo matriks.

Secara umum, matriks  $A_{m \times n} =$

$$\begin{matrix} a_{11} & a_{12} & a_{13} & \dots & a_{1n} \\ a_{21} & a_{22} & a_{23} & \dots & a_{2n} \\ a_{31} & a_{32} & a_{33} & \dots & a_{3n} \\ \dots & \dots & \dots & \dots & \dots \\ a_{m1} & a_{m2} & a_{m3} & \dots & a_{mn} \end{matrix} \quad (2.1)$$

$a_{ij}$  adalah elemen yang terdapat pada baris  $i$  dan kolom  $j$  dari A, dimana  $i = 1, 2, 3, \dots, m$  (indeks baris) dan  $j = 1, 2, 3, \dots, n$  (indeks kolom).

Matriks A dapat ditulis sebagai berikut :

$$A_{m \times n} = [a_{ij}]_{m \times n} \text{ dengan } i = 1, 2, 3, \dots, m ; j = 1, 2, 3, \dots, n$$

#### 2.1. Analisis Regresi Linier

Analisis regresi linier berganda adalah hubungan secara linier antara dua atau lebih variabel independen ( $X_1, x_2, \dots, X_n$ ) dengan variabel dependen ( $Y$ ). Analisis ini untuk mengetahui arah hubungan antara variabel independen dengan variabel dependen apakah masing-masing variabel independen berhubungan positif atau negatif dan untuk memprediksi terjadinya satu peningkatan atau penurunan dengan data yang sering digunakan adalah berskala rasio atau interval. Persamaan regresi linier berganda sebagai berikut :

$$Y = a + b_1 x_1 + b_2 x_2 + \dots + b_n x_n + \varepsilon \quad (2.2)$$

Keterangan :

- Y = Variabel dependen (nilai yang akan diprediksi)
- $X_1$  dan  $X_2$  = Variabel independen
- a = Konstanta (nilai pada Y apabila  $X_1, x_2, \dots, X_n = 0$ )
- b = Koefisien regresi nilai (peningkatan atau penurunan)
- $\varepsilon$  = terjadinya eror

Jika model regresi linier berganda dengan  $p$  variabel independen  $b_j, j = 0, 1, \dots, n$  disebut dengan bilangan koefisien regresi. Dengan parameter  $b_j$  mewakili peubah pada variabel dependen  $Y$  di unit independen ke  $X_j$  ketika semua variabel independen yang tersisa  $X_i (i \neq j)$  tidak berubah.

Dengan bentuk secara matriks sebagai berikut :

$$\begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix} = \begin{pmatrix} 1 & X_{11} & X_{12} & \dots & X_{1p} \\ 1 & X_{21} & X_{22} & \dots & X_{2p} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & X_{n1} & X_{n2} & \dots & X_{np} \end{pmatrix} \begin{pmatrix} b_1 \\ b_2 \\ \vdots \\ b_p \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{pmatrix} \text{ atau } (y = xb + \varepsilon) \quad (2.3)$$

Dimana :

$y$  = vektor kolom  $n \times 1$  variabel independen  $Y$

$x$  = matriks  $n \times (p+1)$  dari variabel dependen  $X$

$b$  = vektor pada kolom  $(p+1)$  untuk parameter tidak diketahui  $b_0, b_1, \dots, b_p$

$\varepsilon$  = vektor kolom  $n \times 1$  dari terjadinya eror

Adanya variabel independen ini dapat lebih menjelaskan hubungan antar variabel meski masih ada variabel yang terabaikan.

## 2.2. Asumsi Analisis Regresi

Pengujian asumsi analisis regresi adalah uji asumsi statistik yang harus memenuhi analisis regresi linier berganda dan beberapa asumsinya menurut Gujarati (2003) adalah sebagai berikut :

- Nilai residual berdistribusi normal.
- Tidak terdapat multikolinieritas yang sempurna.
- Tidak terdapat autokorelasi antara nilai residual.
- Variabel bebas berpengaruh secara signifikan terhadap variabel terikat.

### 2.3.1 Uji Normalitas

Menurut Sulianto (2004) cara mengetahui apakah residual telah terstandarisasi berdistribusi normal atau tidak adalah dengan cara uji Kolmogrov-Smirnov.

Dengan hipotesis :

$H_0$  : data berasal dari populasi berdistribusi normal

$H_1$  : data berasal dari tidak berdistribusi normal

Langkah-langkah dalam pengujian :

1. Melakukan persamaan regresi
2. Mencari nilai prediksinya ( $\hat{Y}$ )
3. Mencari nilai residualnya ( $Y - \hat{Y}$ )
4. Mengurutkan nilai standarisasi dari terkecil hingga terbesar
5. Mencari nilai  $Z_t$  relatif kumulatif
6. Mencari nilai  $Z_t$  teoritis berdasarkan nilai tabel Z
7. Menghitung nilai  $Z_r$  dengan  $Z_r$  dan diberi kolom K
8. Mencari nilai K mutlak terbesar dan diberi nama  $K_{hitung}$
9. Membandingkan nilai  $K_{hitung}$  dengan tabel Kolmogorov-Smirnov ( $K_{tabel}$ )
10. Menarik kesimpulan dengan kriteria jika  $K_{hitung} < K_{tabel}$  maka residual tersebut terstandarisasi berdistribusi normal jika  $\text{sig} > 0,05$ .

### 2.3.2 Uji Multikolinieritas

Multikolinieritas adalah pengujian yang bertujuan untuk ditemukannya suatu korelasi pada variabel bebas (independen). Penyebab multikolinieritas menurut *Gurajati (2004)* ialah memasukkan variabel independen atau bebas yang seharusnya dikeluarkan dari model empiris, selain itu *Gurajati* mengungkapkan penyebab multikolinieritas ialah sifat-sifat pada variabel yang kebanyakan berubah secara bersamaan dalam waktu yang sama juga lalu kesalahan dalam membentuk model regresi yang digunakan dalam variabel independen atau bebas dan kecilnya jumlah pengamatan yang akan dianalisis dengan model regresi. Untuk mengetahui masalah tersebut menurut *Widarjono (2007)* adalah dengan cara mengecek korelasi antara variabel independen, jika koefisien korelasi tinggi, biasanya di atas 0,9 maka dapat diartikan terdapat multikolinieritas. Menurut *Johnson dan*

Wichen (2007) dengan cara menghitung korelasi koefisiennya dengan menggunakan rumus.

$$\rho_{jI} = \frac{s_{jI}}{s_{JJ} s_{II}} \text{ dengan hasil } s_{jI} = \frac{1}{n} \sum_{i=1}^n X_{iI} - X_{jI} (X_{iI} - \bar{X}_I) \quad (2.4)$$

Selain cara Widarjono, Johnson dan Winhen, adapun cara untuk melihat nilai variance inflation factor (VIF) dan nilai tolerance (TOL). Yaitu mengukur besarnya multikolinieritas dan menunjukkan peningkatan ragam koefisien regresi yang disebabkan karena adanya ketergantungan linier peubah prediktor tersebut peubah prediktor lain.

Dengan menggunakan rumus 
$$vif = \frac{1}{1-R_j^2} \quad (2.5)$$

Dengan  $R_j$  merupakan koefisien determinan ke  $j$ ,  $j = 1, 2, \dots, n$ . Dengan nilai multikolinieritas jika nilai  $VIF \geq 10$ . Jika nilai Tol kurang dari 0,01 atau nilai VIF lebih dari 10 maka diartikan bahwa multikolinieritas terjadi diantara variabel independen atau bebas.



### 2.3.3 Uji Linieritas

Uji linieritas dilakukan untuk membuktikan apakah model linier atau tidak. Apabila terdapat kesalahan dalam menentukan model regresi maka nilai prediksi yang dihasilkan akan terjadi bias. Menurut Sulianto (2008) uji Lagrange Multiplier (LM-Test) merupakan salah satu metode untuk mengukur linieritas yang dikembangkan oleh Engle pada tahun 1982. Prinsip metode ini ialah membandingkan antara nilai  $X_{hitung}^2$  dengan  $X_{tabel}^2$  dengan  $df = (n, a)$  dengan langkah-langkah sebagai berikut :

1. Membuat persamaan perseginya
2. Mencari nilai prediksinya ( $\hat{Y}$ )
3. Mencari nilai residualnya ( $Y - \hat{Y}$ )

4. Mengkuadratkan semua nilai variabel bebas
5. Meregresikan kuadrat variabel bebas terhadap nilai residualnya
6. Mencari nilai koefisien determinan  $R^2$
7. Menghitung nilai  $X_{hitung}^2 = (n \times R^2)$ . Dimana  $n$  adalah jumlah pengamatan
8. Menarik kesimpulan uji linieritas dengan kriteria hitung jika  $X_{hitung}^2 < X_{tabel}^2$  dengan  $df=(n,a)$  maka model dinyatakan linier.
9. Begitu sebaliknya. Dengan Hipotesis pengujian :

$H_0 : \rho = 0$  (tidak terdapat korelasi linier antara  $X_1, X_2, X_3, \dots, X_k$  dengan Y)

$H_1 : \rho \neq 0$  (terdapat korelasi linier antara  $X_1, X_2, X_3, \dots, X_k$  dengan Y)

Kriteria pengujian ini menggunakan taraf kesalahan  $\alpha$  dan  $df = (n, a)$  yaitu jika  $X_{hitung}^2 < X_{tabel}^2$  maka  $H_0$  ditolak begitupun sebaliknya.

### 2.3.4 Uji Simultan

Untuk mengetahui apakah semua variabel independent atau bebas yang akan dimasukkan akan berpengaruh secara simultan atau bersama-sama terhadap variabel dependent atau terikat maka dilakukan uji statistik F menurut *Ghozali(2006:16)*. Uji ini untuk mengetahui kelayakan model *goodness of fit*. Maka nilai  $F_{tabel}$  diperoleh dari tabel distribusi F dengan tingkat signifikan  $\alpha$  dan derajat kebebasan  $df = \alpha, k - 1, (n - k)$  dimana  $n$  adalah jumlah observasi dan  $k$  adalah jumlah variabel.

$$F = \frac{R^2/(k-1)}{1-R^2/(n-k)} \quad (2.6)$$

Dengan hipotesis :

$H_0: \beta_1 = \beta_2 = \beta_3 = \dots = \beta_i = 0$ . Semua  $\beta_i = 0$  untuk  $i = 1, 2, \dots, n$

$H_1$ : tidak semua  $\beta_i = 0$ . Untuk  $i = 1, 2, \dots, n$

Kriteria Uji :

Jika  $F_{hitung} \geq F_{tabel}$  atau nilai sig  $\alpha < \alpha$  maka  $H_0$  ditolak begitupun sebaliknya. Yang artinya secara simultan variabel independent atau bebas ( $X_1, X_2, \dots, X_n$ ) berpengaruh signifikan terhadap variabel independent atau bebas (Y).

### 2.3.5 Uji Keberartian Parsial

Uji keberartian parsial atau sering juga disebut uji t adalah untuk menunjukkan seberapa jauh satu variabel independent lainnya Ghozali(2009:17) nilai t tabel dengan derajat bebas yaitu  $df = n - k$ , dimana n adalah jumlah observasi dan k jumlah variabel.

Hipotesis pengujianya :

$H_0: \beta_j = 0, X_1$  tidak mempengaruhi Y

$H_1: \beta_k \neq 0, X_1$  mempengaruhi Y

⋮

$H_0: \beta_k = 0, X_k$  tidak mempengaruhi Y

$H_1: \beta_k \neq 0, X_k$  mempengaruhi Y

Jika  $F_{hitung} \geq F_{tabel}$  atau nilai sig  $\alpha < \alpha$  maka  $H_0$  ditolak begitupun sebaliknya.

Nilai t-hitung didapatkan menggunakan rumus Ghozali(2009):

$$t_{hitung} = \frac{\text{Koefisien Regresi}(bi)}{\text{Standar Deviasi } bi} \quad (2.7)$$

Pengambilan keputusan uji hipotesis parsial didasari pada nilai probabilitas yang didapatkan jika tingkat signifikansi lebih kecil dari  $\alpha$  maka hipotesis diterima atau dikatakan signifikan ( $H_1$  diterima) yang artinya secara parsial variabel independent atau bebas ( $X_1, X_2, \dots, X_n$ ) berpengaruh signifikan terhadap variabel dependent atau terikat (Y) begitupun sebaliknya.

## 2.4 Koefisien Determinan $R^2$

Uji koefisien determinasi ( $R^2$ ) yang digunakan untuk mengukur seberapa jauh kemampuan model dalam menerangkan variasi variabel dependent atau terikat menurut *ghozali (2006)*. Yang dinotasikan dengan nilai ( $R^2$ ) menggunakan rumus sebagai berikut :

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})}{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2} = \frac{JKR}{JKT} = 1 - \frac{JKG}{JKT}; \text{ dimana } 0 \leq R^2 \leq 1 \quad (2.8)$$

Bertambahnya suatu variabel prediktor pada model akan menaikkan nilai  $R^2$  itu sendiri, sebab JKG tidak akan bertambah jika variabel prediktor lebih banyak, sedangkan JKT tidak akan berubah jika data responsnya tetap sama. Karena nilai  $R^2$  sering dibuat lebih besar dengan menambah variabel prediktornya maka ukurnya diubah atau dimodifikasi dengan memperhitungkan seberapa banyaknya variabel prediktor dalam model.  $R^2$  terkoreksi atau adjusted dirumuskan :

$$R^2 = 1 - \frac{JKG/(n-p)}{JKT/(n-1)} = \frac{(n-1)JKG}{(n-p)JKT} \quad (2.8)$$

Nilai  $R^2$  yang mendekati nol menunjukkan bahwa data tersebut tidak cocok dengan model regresi. Sebaliknya jika mendekati satu menunjukkan bahwa model regresi tersebut cocok *Johson dan Wichern, (1996)*.

## 2.5 Koefisien Korelasi

Koefisien korelasi, dinotasikan dengan  $r$  digunakan untuk mengukur hubungan antara dua variabel pada analisis korelasi. Koefisien korelasi antara sampel X dan Y dinotasikan dengan  $r_{xy}$  adalah :

$$r_{xy} = \frac{S_{xy}}{\sqrt{S_{xx}}\sqrt{S_{yy}}} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{[\sum_{i=1}^n (X_i - \bar{X})^2 \sum_{i=1}^n (Y_i - \bar{Y})^2]^{1/2}} \quad (2.9)$$

$S_{xy}$  adalah kovariansi dari  $x$  dan  $y$  sedangkan  $S_x$  dan  $S_y$  adalah simpangan bakunya. Koefisien korelasi mengukur hubungan antara dua variabel nilainya  $-1 \leq r_{xy} \leq 1$ . Apabila  $r$  bernilai 1 atau -1 maka hubungan linier antara dua variabel tersebut sempurna atau sangat kuat. Jika korelasi bernilai positif maka kedua variabel mempunyai hubungan searah sedangkan korelasi yang bernilai negatif maka kedua variabel mempunyai hubungan yang berlawanan arah *Supranto(2008)*.

## 2.6 Mean Of Square (MSE)

Menurut *Ghazali (2006)* Mean of square error (MSE) adalah salah satu pengukuran kesalahan atau eror yang sering digunakan. Nilai Mse dihitung dengan cara mengkuadratkan selisih antara nilai prediksi dengan nilai sebenarnya, umumnya semakin kecil nilai MSE maka semakin tinggi tingkat keakuratan nilai suatu prediksi. Perhitungan MSE dilakukan dengan menggunakan rumus :

$$MSE = \frac{\sum_{i=1}^n Y_i - \hat{Y}_i^2}{n} \quad (2.9)$$

Keterangan :

$\hat{Y}_i$ : Variabel dependent dugaan

$\bar{y}$ : nilai rata rata dari variabel dependent

$n$  : jumlah data

## 2.7 Metode Ordinari Least Square (OLS)

Metode Ordinari least Square atau OLS atau yang sering kita sebut metode kuadrat terkecil merupakan metode yang sering kita jumpai pada estimasi fungsi regresi yang bertujuan untuk meminimalisir kudarat kesalahan  $e_i$  sehingga nilai regresi yang didapatkan akan mendekati nilai sesungguhnya. Estimasi regresi  $\beta$  diperoleh dengan meminimlisir kuarat erornya ( $\varepsilon'\varepsilon$ ) karena :

$$\begin{aligned} \varepsilon'\varepsilon &= (e_1, e_2, \dots, e_n) \begin{pmatrix} e_1 \\ e_2 \\ \vdots \\ e_n \end{pmatrix} && (2.10) \\ &= e_1^2, e_2^2, \dots, e_n^2 \\ &= \sum e_i^2 \text{ dengan } \varepsilon = Y - X\hat{\beta} \\ \varepsilon'\varepsilon &= (Y - X\hat{\beta})' (Y - X\hat{\beta}) \\ &= (Y' - X'\hat{\beta}') (Y - X\hat{\beta}) \\ &= Y'Y - Y'X\hat{\beta} + YX'\hat{\beta}' + X'\hat{\beta}'X\hat{\beta} \\ &= Y'Y - 2YX'\hat{\beta}' + X'\hat{\beta}'X\hat{\beta} \\ \frac{d(\varepsilon'\varepsilon)}{d\hat{\beta}} &= 0 \end{aligned}$$

$$0 - 2XY' + 2(XX')\hat{\beta} = 0$$

$$2(XX')\hat{\beta} = 2X'Y$$

Sehingga didapatkan estimasi OLS untuk  $\beta$  adalah  $\hat{\beta} = (X'X)^{-1}X'Y$  dan pada persamaan tersebut didapatkan bahwa  $\varepsilon$  bebas satu sama lain  $E(\varepsilon) = 0$  dan  $\text{var} = \sigma^2 I$  estimator kuadrat terkecil  $\beta_j$  terdapat suatu variansi yang minimum diantara seluruh estimator linier dan tak bias. Dengan sifat kuadrat terkecil adalah :

1. Linier dan tak bias

Jika  $E(\hat{\beta}) = \beta$  maka  $\hat{\beta}$  adalah estimator yang tak bias untuk  $\beta$ . Akan menunjukkan bahwa  $\hat{\beta}$  adalah penduga linier tak bias dari  $\beta$ .

$$\begin{aligned}\hat{\beta} &= (X'X)^{-1}X'Y \\ &= (X'X)^{-1}X'(X\beta + \varepsilon) \\ &= (X'X)^{-1}X'X\beta + (X'X)^{-1}X'\varepsilon \\ &= \beta + (X'X)^{-1}X'\varepsilon\end{aligned}$$

Sehingga  $\hat{\beta}$  adalah fungsi dari linier  $\beta$  dan  $\varepsilon$   $(X'X)^{-1}X'X = I$

$$\begin{aligned}E(\hat{\beta}) &= E[(X'X)^{-1}X'Y] \\ &= (X'X)^{-1}X'E(Y) \\ &= (X'X)^{-1}X'(X\beta) \\ &= (X'X)^{-1}X'X\beta \\ &= I\beta \\ &= \beta\end{aligned}$$

Karena  $E(\hat{\beta}) = \beta$  maka  $\hat{\beta}$  adalah estimator yang tak bias untuk  $\beta$

## 2. Varian minimum

$$\begin{aligned}\text{Var}(\hat{\beta}) &= E\left[\left((\hat{\beta} - E(\hat{\beta}))\right)\left((\hat{\beta} - E(\hat{\beta}))\right)'\right] \\ &= E\left[(\beta + (X'X)^{-1}X'\varepsilon - \beta)(\beta + (X'X)^{-1}X'\varepsilon - \beta)'\right] \\ &= E\left[((X'X)^{-1}X'\varepsilon)(X'X)^{-1}X'\varepsilon'\right] \\ &= E\left[((X'X)^{-1}X'\varepsilon\varepsilon'X(X'X)^{-1}\right] \\ &= (X'X)^{-1}X'X(X'X)^{-1}E(\varepsilon'\varepsilon) \\ &= (X'X)^{-1}I\sigma^2 \\ &= (X'X)^{-1}\sigma^2\end{aligned}$$

Jadi terbukti  $(\hat{\beta}) = (X'X)^{-1} \sigma^2$ . Jika  $\hat{\beta}$  dan  $\hat{\beta}_2$  sebuah estimator dari  $\beta$  dimana variansi untuk  $\hat{\beta}$  lebih kecil dari varian untuk  $\hat{\beta}_2$  maka estimator tersebut bervariasi minimum. Untuk membuktikan asumsi sebuah estimator alternatif yang linear dan tidak bisa kemudian dibuktikan variansi yang lebih besar dari pada variansi estimator model regresi. Misal  $\hat{\beta}_2 = [(X'X)^{-1'} + C]Y$  dimana  $c$  adalah matriks konstanta berukuran  $k \times n$  yang diketahui maka :

$$\hat{\beta}_2 = [(X'X)^{-1'} + C]Y$$

$$= [(X'X)^{-1'} + C](X\beta + \varepsilon)$$

$$= (X'X)^{-1'}X'(X\beta + \varepsilon) + C(X\beta + \varepsilon), \text{ nilai harapan}$$

pada estimator  $\hat{\beta}_2$  adalah :

$$E[\hat{\beta}_2] = E[(X'X)^{-1'}X'(X\beta + \varepsilon) + C(X\beta + \varepsilon)]$$

$$= E[(X'X)^{-1'}X'X\beta + (X'X)^{-1'}X'\varepsilon + CX\beta + CC] \quad \text{karena}$$

nilai  $E[\hat{\beta}_2] = \beta$ . Oleh karena itu, nilai  $CX = 0$  sehingga :

$$= E\{[(X'X)^{-1'}X'\varepsilon + C\varepsilon][(X'X)^{-1'}X'\varepsilon + C\varepsilon]'\}$$

$$= E\{[(X'X)^{-1'}X'\varepsilon + C\varepsilon]\{\varepsilon'X(X'X)^{-1'}X'\varepsilon + \varepsilon'C'\}\}$$

$$= E\{[(X'X)^{-1'}X' + C]\varepsilon\varepsilon'\{X(X'X)^{-1} + \varepsilon'C'\}\}$$

$$= \{[(X'X)^{-1'}X' + C]E(\varepsilon\varepsilon')\{X(X'X)^{-1} + \varepsilon'C'\}\}$$

$$= \sigma_\varepsilon^2[(X'X)^{-1'}X' + C]\{X(X'X)^{-1} + (X'X)^{-1} + C'\}$$

$$= \sigma_\varepsilon^2[(X'X)^{-1}X'X(X'X)^{-1} + CX(X'X)^{-1} + (X'X)^{-1}X'C'CC']$$

$$= \sigma_\varepsilon^2(X'X)^{-1} + CC'$$

$$= \sigma_{\varepsilon}^2 (X'X)^{-1} + \sigma_{\varepsilon}^2 CC'$$

$$\text{Var}(\widehat{\beta}_2) = \text{var}(\hat{\beta}_2) + \sigma_{\varepsilon}^2$$

Jadi terbukti  $(\hat{\beta}) < \text{var}(\hat{\beta}_2)$  maka  $\hat{\beta}$  adalah estimator yang terbaik. Dikarenakan estimator kuadrat terkecil memenuhi sifat linier, tak bias dan mempunyai variansi minimum.

## 2.8 Principal Component Regression (PCA)

Menurut Jolliffe (1986) *Principal component analysis (pca)* atau yang sering kita sebut dengan analisis komponen utama merupakan teknik statistik yang secara linier mentransformasikan sekelompok variabel data asli menjadi sekelompok variabel data substansial yang tidak terkorelasi. Setelah beberapa komponen hasil dari PCA yang bebas dari multikolinieritas maka komponen tersebut menjadi variabel bebas atau independent baru yang dianalisis pengaruhnya terhadap variabel terikat atau dependent dengan menggunakan analisis regresi.

Langkah-langkah PCA adalah sebagai berikut :

### a. Kaiser-Meyer-Olkin (KMO) dan Barlett Test

Mengenai layak atau tidaknya analisis faktor, maka perlu dilakukan uji Kaiser-Meyer-Olkin (KMO) dan Barlett Test. Apabila nilai KMO berkisar antara 0,5 sampai dengan 1 maka analisis faktor layak digunakan. Namun, jika nilai KMO kurang dari 0,5 maka analisis faktor tidak layak dilakukan. Sedangkan Barlett Test digunakan untuk menguji apakah benar variabel-variabel yang dilibatkan berkorelasi.

Hipotesis:

H0: tidak ada korelasi antarvariabel bebas

H1: ada korelasi antarvariabel bebas

Kriteria uji dengan melihat p-value (signifikan): terima  $H_0$  jika  $\text{sig.} > 0,05$  atau tolak  $H_0$  jika  $\text{sig.} < 0,05$ .

b. Anti Image Matriks

Bagian Anti Image Correlation, khususnya pada angka korelasi yang bertanda a (arah diagonal dari kiri atas ke kanan bawah). Angka MSA (Measure of Sampling Adequacy) berkisar dari 0 sampai 1, dengan kriteria sebagai berikut:

- $\text{MSA} = 1$ , variabel tersebut dapat diprediksi tanpa kesalahan oleh variabel lain.
- $\text{MSA} > 0,5$ , variabel masih bisa diprediksi dan bisa dianalisis lebih lanjut.
- $\text{MSA} < 0,5$ , variabel tidak bisa diprediksi dan tidak bisa dianalisis lebih lanjut, atau dikeluarkan dari variabel lainnya.

c. Communalities

Communalities menunjukkan berapa varians yang dapat dijelaskan oleh faktor yang terbentuk.

d. Total Variance Explained

Dalam analisis faktor terdapat beberapa komponen yang merupakan variabel. Setiap faktor mewakili variabel yang dianalisis. Kemampuan setiap faktor mewakili variabel yang dianalisis ditunjukkan oleh besarnya varians yang dijelaskan, yang disebut dengan eigenvalue. Eigenvalue menunjukkan kepentingan relatif masing-masing faktor dalam menghitung varians ketiga variabel yang dianalisis. Susunan eigenvalue selalu diurutkan dari yang terbesar sampai yang terkecil, dengan kriteria bahwa angka eigenvalue di bawah 1 tidak digunakan dalam menghitung jumlah faktor yang terbentuk.

e. Komponen Matriks

Komponen Matriks merupakan tabel yang berisikan factor loading (nilai korelasi) antara variabel-variabel analisis dengan faktor yang terbentuk.

f. Component Score Coefficient Matriks



Setelah didapatkan faktor yang terbentuk melalui proses reduksi, maka perlu dicari persamaan sehingga dapat dihitung skor setiap faktor secara manual. Persamaan yang dibuat mirip dengan regresi linear berganda, hanya dalam persamaan faktornya tidak terdapat konstanta. Setelah komponen hasil PCA yang bebas multikolinearitas diperoleh maka komponen-komponen tersebut diregresikan atau dianalisa pengaruhnya terhadap variabel tak bebas (Y) dengan menggunakan analisis regresi linear.

## 2.9 Pricipal Component Regression (PCR)

*Principal component regression (pcr)* adalah kombinasi antara regresi dengan *Principal component analisis (pca)* kegunaan metode yang digunakan untuk mengatasi masalah multikolinieritas. Metode ini akan menghasilkan komponen-komponen utama yang tidak berkorelasi. Perbedaan diantara kedua metode ini adalah jika *Principal component regression (pcr)* untuk mengetahui ada atau tidaknya hubungan variabel dependent dan independen, sedangkan *Principal component analysis (pca)* untuk menyederhanakan variabel yang diamati dengan cara menyusutkan (mereduksi) dimensi. Perlu diketahui jika komponen utama diikuti sertakan dalam model regresi, maka model yang dihasilkan sama seperti metode kuadrat terkecil. Sebaliknya jika beberapa komponen utama yang diikuti sertakan maka akan diperoleh penduga dengan koefisien regresi yang bias namun memiliki *variance* yang minimum. Menurut *Dreper dan Smith (1992)* *Principal component regression* adalah analisis regresi dari variabel-variabel dependent atau terikat terhadap komponen utama yang tidak saling berkorelasi, dimana semua komponen utama merupakan kombinasi linier dari semua variabel independent atau bebas. Hal ini dilakukan untuk menghilangkan korelasi diantara variabel melalui transformasi variabel asal ke variabel baru (merupakan kombinasi linier dari variabel-variabel asal) yang tidak saling berkorelasi dari  $p$  hasil variabel asal dapat dibentuk  $p$  hasil komponen utama, dipilih  $k$  hasil dari komponen utama ( $k < p$ ) yang telah menerangkan keragaman data

yang cukup tinggi (antara 80% sampai 90%). Komponen utama yang dipih adalah (*k hasil*) dapat menggantikan  $p$  hasil variabel asal tanpa mengurangi informasi.

Pembentukan regresi utama melalui analisis komponen utama ada dua cara yaitu komponen utama yang berdasarkan matriks kovarians dan komponen utama yang berdasarkan matriks korelasi. Matriks korelasi dari data yang telah distandarisasi (bentuk buku Z) digunakan jika variabel yang diamati tidak memiliki satuan pengukuran yang sama. Sedangkan matriks kovarians digunakan jika semua variabel yang diamati mempunyai satuan pengukuran yang sama.

Analisis *Principal component regression (pcr)* adalah analisis regresi variabel dependent atau terikat terhadap komponen utama yang tidak saling berkorelasi, dengan regresi komponen utama yang dinyatakan sebagai berikut :

$$Y = w_0 + w_1K_1 + w_2K_2 + \dots + w_mK_m + \varepsilon$$

Dimana :

$Y$  : Variabel dependent

$K$  : Komponen utama

$W$  : Parameter regresi utama

$K_1, K_2, K_3, \dots, K_m$  menunjukkan komponen utama yang dilibatkan dalam analisis regresi komponen utama, dengan besaran  $m$  lebih kecil dari banyaknya variabel bebas yaitu  $p$ , serta  $Y$  sebagai variabel terikat.

Komponen utama adalah gabungan linier variabel baku Z, sehingga diperoleh

$$K_1 = a_{11}Z_1 + a_{21}Z_2 + \dots + a_{p1}Z_p$$

$$K_2 = a_{12}Z_1 + a_{22}Z_2 + \dots + a_{p2}Z_p$$

⋮

$$K_m = a_{1m}Z_1 + a_{2m}Z_2 + \dots + a_{pm}Z_p$$

Jika  $K_1, K_2, K_3, \dots, K_m$  dalam persamaan didistribusikan kembali kedalam persamaan regresi komponen utama, maka persamaan tersebut diperoleh :

$$\begin{aligned}
 Y &= W_0 + W_1(a_{11}Z_1 + a_{21}Z_2 + \dots + a_{p1}Z_p) + W_2(a_{12}Z_1 + a_{22}Z_2 + \dots + \\
 &a_{p2}Z_p) + \dots + W_m(a_{1m}Z_1 + a_{2m}Z_2 + \dots + a_{pm}Z_p) + \varepsilon \\
 &= W_0 + W_1a_{11}Z_1 + W_1a_{21}Z_2 + \dots + W_1a_{p1}Z_p + W_2a_{12}Z_1 + W_2a_{22}Z_2 \\
 &+ \dots + W_2a_{p2}Z_p + W_ma_{1m}Z_1 + W_ma_{2m}Z_2 + W_ma_{pm}Z_p + \varepsilon \\
 &= W_0 + (W_1a_{11} + W_2a_{12} + \dots + W_ma_{1m})Z_1 + (W_1a_{21} + W_2a_{22} + \dots + \\
 &W_ma_{2m})Z_2 + \dots + (W_1a_{p1} + W_2a_{p2} + \dots + W_ma_{pm})Z_p + \varepsilon
 \end{aligned}$$

Maka dari persamaan diatas diperoleh persamaan regresi dengan komponen utama sebagai berikut :



$Y = b_0 + b_1Z_1 + \dots + b_pZ_p$

$b_0 = W_0$

Dengan :

$$b_1 = W_1a_{11} + W_2a_{12} + \dots + W_ma_{1m}$$

$$b_2 = W_1a_{21} + W_2a_{22} + \dots + W_ma_{2m}$$

⋮

$$b_p = W_1a_{p1} + W_2a_{p2} + \dots + W_ma_{pm}$$

Syarat *Principal component regression (pcr)* adalah sebagai berikut :

1. Menghitung nilai eigen vektor dan nilai eigen value pada matrik korelasi atau kovarians
2. Terdapat  $p$  komponen utama yang orthogonal dan tidak terkorelasi
3. Dipilih komponen yang eigen value > 1 atau yang mampu menerangkan keragaman cukup tinggi (80%-90%)
4. Regresi variabel dependent atau terikat dengan komponen-komponen utama yang telah terpilih.

## 2.10 Regression Ridge

Regresi Ridge adalah salah satu metode untuk mengatasi multikolinieritas dengan cara memodifikasi metode kuadrat terkecil. Metode yang digunakan dalam mendeteksi multikolinieritas adalah *ridge trace*. Salah satu kendala dalam regresi ridge adalah menentukan nilai  $c$  yang tepat. *Centering* dan *rescaling* data merupakan bagian dari membekukan variabel. Bila terdapat multikolinieritas ganda yang besar maka kuadrat terkecil menghasilkan penaksir tak bias untuk koefisien regresi, tapi penaksir mempunyai variansi yang besar. Variansi yang besar menimbulkan dua kesulitan yaitu penaksir tidak stabil artinya sensitif terhadap perubahan kecil pada data yang kelihatan tidak penting dan penaksir cenderung menghasilkan koefisien yang terlalu besar. Cara mengatasinya adalah menggunakan metode kuadrat terkecil dan menggunakan penaksir yang bias, penggunaan bias tentu dalam dugaan variansi penaksur dapat diperkecil.

Regresi ridge diperoleh dengan memasukkan suatu konstanta pembiasan dalam persamaan normal kuadrat terkecil yaitu :

$$\beta^R(c) = (Z^T Z + cI)^{-1} Z^T Y^*$$

Keterangan :

$\beta^R$  = dugaan koefisien regresi ridge

$Z$  = matriks  $X$  yang tertransformasi (*centerd dan scaled matrix*)

$Z^T$  = matriks transpose dari  $Z$

$Y^*$  = vektor  $y$  yang telah ditransformasikan

$c$  = Parameter ridge, umumnya  $c$  terletak pada selang(0,1) atau  $0 \leq c \leq 1$

$I$  = matriks identitas yang berukuran  $p \times p$

Dalam hal ini  $\beta^R$  adalah vektor koefisien-koefisien ridge yaitu :

$$\beta^R(c) = \begin{bmatrix} \beta_1^R(c) \\ \beta_2^R(c) \\ \vdots \\ \beta_p^R(c) \end{bmatrix}$$

Dengan persamaan regresi ridge yaitu :

$$\hat{Y}^* = \beta_1^R Z_{i1} + \beta_2^R Z_{i2} + \dots + \beta_p^R Z_{ip}$$

Nilai VIF bagi koefisien regresi ridge  $\beta^R$  mirip untuk koefisien kuadrat terkecil.

Dengan kata kata lain nilai VIF untuk koefisien  $\beta^R$  mengukur besarnya variansi bagi  $\beta^R$  relatif terhadap variansi koefisien yang sama jika peubah besarnya tidak berkorelasi.

Ini menunjukkan bahwa nilai VIF bagi koefisien regresi ridge merupakan unsur-unsur diagonal dari matriks :

$$(Z^T Z + cI)^{-1} Z^T Z (Z^T Z + cI)^{-1}$$

## 2.11 Variabel Dependen dan independen

Variabel adalah fenomena yang bervariasi dalam bentuk kualitas, kuantitas, mutu, dan standar. Variabel merupakan suatu yang diukur dan cara mengukurnya berbeda-beda. Variabel juga memiliki jenis yaitu dependen (X) dan independen (Y). Variabel dependen adalah variabel terikat atau variabel yang dipengaruhi atau tergantung variabel lainnya sedangkan variabel independen adalah variabel bebas yang menjadi sebab timbulnya atau berubahnya variabel independen atau bisa diartikan variabel independen adalah variabel yang mempengaruhi variabel lainnya.

Pada penelitian tersebut memiliki variabel independen (Y) dan variabel dependen (X) yang masing-masing variabel diwakili oleh IPM untuk variabel independen (Y) sedangkan variabel dependen (X) diwakili oleh harapan lama sekolah (HLS), rata-rata lama sekolah (RLS), angka harapan hidup saat lahir (AHH), produk domestik regional bruto (PDRB), angka partisipasi sekolah (APS), angka melek huruf (AMH), tingkat pengangguran terbuka (TPT), tingkat partisipasi angkatan kerja (TPAK), pengeluaran perkapita non makanan (PPK), Presentase Penduduk Miskin (PPM) dan status kepemilikan rumah milik sendiri (SKTMS).

### **2.11.1 Indeks Pembangunan Manusia (Y)**

Untuk pertama kalinya ditahun 1990 pengukuran Indeks pembangunan manusia (IPM) dilakukan oleh United Nations Development Programme (UNDP). IPM dipublikasikan secara berkala dalam laporan tahunan Human Development Report (HDR). IPM menjelaskan bagaimana penduduk dapat mengakses hasil pembangunan dalam memperoleh pendapatan, kesehatan, pendidikan dan sebagainya. UNDP membuat suatu gagasan dimana pembangunan manusia dapat diukur melalui tiga dimensi yaitu :

- Umur panjang dan hidup yang sehat
- Pengetahuan
- standar layak hidup

Ketiga dimensi tersebut memiliki pengertian sangat luas karena terkait banyak faktor. Pada laporan pertamanya, UNDP mengukur dimensi kesehatan dengan menggunakan angka harapan hidup waktu lahir. Selanjutnya untuk mengukur dimensi pengetahuan digunakan angka melek huruf. Adapun untuk mengukur dimensi standar hidup layak digunakan indikator Produk Domestik Bruto (PDRB) per kapita.

### **2.11.2 Angka Harapan Hidup Saat Lahir (X)**

Angka harapan hidup saat lahir (AHH) adalah perkiraan rata-rata tambahan umur seseorang yang diharapkan dapat terus hidup. AHH juga didefinisikan sebagai jumlah tahun yang dijalani oleh seseorang setelah irang tersebut ulang tahun yang ke-x. Jadi pada umumnya AHH yang dimaksud adalah rata-rata jumlah tahun yang dijalani oleh seseorang sejak orang tersebut lahir. Rasio ketergantungan (Dependency Ratio) adalah perbandingan antara jumlah penduduk umur 0-14 tahun, ditambah dengan jumlah penduduk 65 tahun ke atas (kedanya disebut bukan angkatan kerja) dibandingkan dengan jumlah penduduk 15-64 tahun (angkatan kerja).

### **2.11.3 Rata – Rata Lama Sekolah (X)**

Rata-rata lama sekolah (RLS) / *mean year of school (MYS)* adalah jumlah tahun yang digunakan oleh penduduk dalam menjalani pendidikan formal. Asumsi dalam kondisi normal rata-rata lama sekolah suatu wilayah tidak akan turun. Rata-rata lama sekolah dihitung berdasarkan penduduk usia 25 tahun ke atas dengan asumsi pada umur 25 tahun proses pendidikan sudah berakhir. Perhitungan rata-rata lama sekolah pada usia 25 tahun ke atas juga mengikuti standar internasional yang digunakan oleh UNDP. Dalam perhitungan rata-rata lama sekolah, penduduk yang tamat SD dipehitungkan lama sekolah 6 tahun, tamat SMP dipehitungkan lama sekolah 9 tahun, penduduk tamat sekolah SMA dipehitungkan lama sekolah 12 tahun tanpa memperhitungkan apakah pernah tinggal kelas atau tidak.

### **2.11.4 Angka Partisipasi Sekolah (X)**

Angka partisipasi sekolah (APS) adalah perbandingan jumlah murid kelompok usia sekolah tertentu yang bersekolah pada berbagai jenjang pendidikan dengan penduduk kelompok usia sekolah yang bersesuaian. Semakin tinggi APS maka semakin banyak usia sekolah yang bersekolah di suatu daerah.

### **2.11.5 Angka Melek Huruf (X)**

Angka melek huruf (AMH) adalah proporsi penduduk usia 15 tahun keatas yang memiliki kemampuan membaca dan menulis kalimat sederhana dalam huruf latin, huruf arab dan huruf lainnya (seperti hrurf jawa, kanji dll). Tingkat melek huruf yang tinggi menunjukkan adanya sebuah sistem pendidikan dasar yang efektif atau program keasaraan yang memungkinkan sebagian besar penduduk yang memperoleh kemampuan menggunakan kata-kata tertulis dalam kehidupan sehari-hari.

### **2.11.6 Produk Domestik Regional Bruto (X)**

Produk domestik regional bruto merupakan produk domestik ditambah dengan pendapatan dari faktor-faktor produksi yang diterima dari luar daerah atau negeri dikurangi dengan pendapatan dari faktor produksi yang dibayarkan keluar daerah atau negeri. Jadi produk regional merupakan produk yang ditimbulkan oleh faktor produksi yang dimiliki presiden.

### **2.11.7 Tingkat Pengangguran Terbuka (X)**

Tingkat pengangguran terbuka (TPT) adalah presentase jumlah pengangguran terhadap jumlah angkatan kerja dengan usia 15 tahun ke atas. TPT yang tinggi menunjukkan bahwa banyaknya angkatan kerja yang tidak terserap pada pasar kerja.

### **2.11.8 Tingkat Partisipasi Angkatan Kerja (X)**

Tingkat partisipasi angkatan kerja (TPAK) adalah ukuran proporsi penduduk usia kerja dengan usia 15 tahun ke atas disuatu daerah yang bergerak aktif di pasar tenaga kerja dan menjadi faktor penting dalam menggerakkan pembangunan.

#### **2.11.9 Presentasi Pengeluaran Perkapita Non - Makanan (X)**

Pengeluaran perkapita non makanan adalah biaya yang dikeluarkan untuk konsumsi non makanan bagi anggota rumah tangga yang dijadikan sebagai tolak ukur dalam kesejahteraan ekonomi penduduk. Semakin besar proporsi pengeluaran non-makanan maka semakin meningkatnya kesejahteraan masyarakat. Sebaliknya semakin kecil pengeluaran non-makanan maka kesejahteraan masyarakat semakin menurun.

#### **2.11.10 Status Kepemilikan Rumah Sendiri (X)**

Status Kepemilikan Rumah Milik Sendiri adalah kepemilikan rumah atau bangunan tempat tinggal milik sendiri menurut jenis bukti kepemilikan tanah tempat tinggal milik sendiri dikali dengan 100(persen), dibagi dengan jumlah rumah tangga dengan status kepemilikan rumah atau bangunan milik sendiri.

#### **2.11.11 Presentase Penduduk Miskin (X)**

Presentase penduduk miskin (headcount index/P0) adalah penduduk miskin yang berada dibawah garis kemiskinan. Headcount Index secara sederhana mengukur proporsi yang dikategorikan miskin. Angka yang ditunjukkan oleh headcount index menunjukkan proporsi penduduk miskin disuatu wilayah. Presentase penduduk miskin yang tinggi menunjukkan bahwa tingkat kemiskinan disuatu wilayah juga tinggi

