

BAB II

LANDASAN TEORI

Beberapa teori yang diperlukan untuk mendukung pembahasan diantaranya adalah regresi linear berganda, pengujian asumsi analisis regresi, metode kuadrat terkecil (MKT), *outlier*, regresi *robust*, koefisien determinasi, breakdown point.

A. Regresi Linear Berganda

Analisis regresi secara konseptual merupakan metode sederhana untuk memeriksa hubungan antara variabel (Chatterjee & Hadi, 1986). Hubungan antara variabel yang dimaksudkan tersebut digambarkan dalam bentuk persamaan atau model yang menghubungkan antara variabel dependen (Y) dan satu atau lebih variabel independen (X).

Variabel dependen dinotasikan dengan Y dan himpunan dari variabel independen dinotasikan dengan $X_1, X_2, \dots, X_k$, dimana k merupakan jumlah variabel independen. Model regresi linear yang terdiri dari satu variabel dependen dan satu variabel independen disebut dengan regresi linear sederhana, sedangkan model regresi linear yang terdiri dari beberapa variabel independen dan satu variabel dependen merupakan regresi linear berganda. Model regresi linear berganda (Faraway, 2002):

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_k X_{ik} + \varepsilon_i \quad (2.1)$$

dengan Y_i merupakan nilai variabel dependen dalam observasi ke- i , $X_{i1}, X_{i2}, \dots, X_{ik}$ merupakan variabel independen pada observasi ke- i dan parameter

ke- k , dan $\beta_0, \beta_1, \beta_2 \dots, \beta_k$ merupakan parameter regresi yang tidak diketahui nilainya dan akan dicari nilai estimasinya, ε_i merupakan galat yang berdistribusi normal dengan *mean*-nya nol dan variansinya σ^2 atau $\varepsilon_i \sim N(0, \sigma^2)$.

B. Pengujian Asumsi Analisis Regresi

Menurut Imam Ghazali (2011), uji asumsi klasik terhadap model regresi linier yang digunakan dilakukan agar dapat diketahui apakah model regresi baik atau tidak. Tujuan pengujian asumsi klasik adalah untuk memberikan kepastian bahwa persamaan regresi yang diperoleh memiliki ketepatan dalam estimasi, tidak bias, dan konsisten. Sebelum melakukan analisis regresi terlebih dahulu dilakukan pengujian asumsi. Asumsi-asumsi yang harus dipenuhi dalam analisis regresi antara lain: normalitas, homoskedastisitas, non autokorelasi, non multikolinieritas, dan linearitas.

1. Uji Normalitas

Analisis regresi linier mengasumsikan bahwa sisaan (ε_i) berdistribusi normal. Uji normalitas dapat dilakukan dengan normal P-P Plot dan uji *Kolmogorov-Smirnov*. Normal P-P plot, uji normalitasnya dapat dilihat dari penyebaran data (titik) pada sumbu diagonal grafik atau normal dengan $\varepsilon_i \sim N(0, \sigma^2)$ (Gujarati, 2004:109). Dasar pengambilan keputusannya, jika data menyebar di sekitar garis diagonal dan mengikuti arah garis diagonal atau grafik histogramnya menunjukkan pola distribusi normal, maka model regresi memenuhi asumsi normalitas.

Cara lain untuk menguji asumsi kenormalan adalah dengan uji *Kolmogorov-Smirnov*. Menurut Sidney Siegel (1986: 59), uji *Kolmogorov-Smirnov* didasarkan pada nilai D atau deviasi maksimum, yaitu:

$$D = \max |F_0(X_i) - S_n(X_i)|, i = 1, 2, \dots, n \quad (2.2)$$

dengan $F_0(X_i)$ adalah fungsi distribusi frekuensi kumulatif relatif dari distribusi teoritis di bawah H_0 . Kemudian $S_n(X_i)$ adalah distribusi frekuensi kumulatif pengamatan sebanyak sampel. Hipotesis nol (H_0) adalah sisaan berdistribusi normal. Kriteria keputusan uji *Kolmogorov-Smirnov* adalah jika nilai $D < D_{tabel}$ atau $p - value$ pada *output* SPSS lebih dari nilai taraf nyata (α) maka asumsi normalitas dipenuhi.

2. Uji Homoskedastisitas

Salah satu asumsi klasik adalah homoskedastisitas atau non heteroskedastisitas yaitu asumsi yang menyatakan bahwa varian setiap sisaan (e_i) masih tetap sama baik untuk nilai-nilai pada variabel independen yang kecil maupun besar. Asumsi ini dapat ditulis sebagai berikut:

$$Var(e_i) = \sigma^2, \quad i = 1, 2, \dots, n$$

untuk n menunjukkan jumlah observasi. Salah satu cara menguji kesamaan variansi yaitu dengan melihat pola tebaran sisaan (e_i) terhadap nilai estimasi Y . Jika tebaran sisaan bersifat acak (tidak membentuk pola tertentu), maka dikatakan bahwa variansi sisaan homogen.

Menurut Gujarati (2004:406) salah satu cara untuk mendeteksi homoskedastisitas adalah menggunakan uji korelasi *rank Spearman* yang didefinisikan sebagai berikut:

$$r_s = 1 - 6 \left[\frac{\sum d_i^2}{n(n^2 - 1)} \right]$$

dengan d_i adalah *rank* variabel dependen dikurangi *rank* variabel independen ke-i, dan n adalah banyaknya individual yang *diranking*. Adapun tahapannya adalah sebagai berikut:

- Menentukan *ranking* untuk masing-masing variabel X dan variabel Y , mulai dari 1 hingga n .
- Menentukan harga $d_i = X_i - Y_i$ dan mengkuadratkan tiap-tiap harga d_i . Kemudian menjumlahkannya sehingga diperoleh $\sum_{i=1}^n d_i^2$.
- Menghitung koefisien korelasi *rank Spearman* yang telah diberikan sebelumnya.
- Dengan $n \geq 10$, signifikansi dari r_s yang disampel dapat diuji dengan pengujian t sebagai berikut:

$$t = \frac{r_s \sqrt{n-2}}{\sqrt{1-r_s^2}}$$

Jika nilai *rank t* yang dihitung melebihi nilai t kritis dengan derajat bebas $n - 2$ maka H_0 ditolak, artinya asumsi homoskedastisitas tidak terpenuhi.. Selain itu, dapat pula menggunakan bantuan *software* SPSS, yaitu dilihat dari nilai signifikansi dan α , apabila nilai sig. $> \alpha$ maka tidak terjadi heteroskedastisitas.

3. Uji Non Autokorelasi

Salah satu asumsi penting dari regresi linear adalah bahwa tidak ada autokorelasi antara serangkaian pengamatan yang diurutkan menurut waktu. Adanya kebebasan antar sisaan dapat dideteksi secara grafis dan empiris.

Pendeteksian autokorelasi secara grafis yaitu dengan melihat pola tebaran sisaan terhadap urutan waktu tidak membentuk suatu pola tertentu atau bersifat acak maka dapat disimpulkan tidak ada autokorelasi antar sisaan (Draper & Smith, 1998: 68).

Menurut Gujarati (2004: 467), pengujian secara empiris dilakukan dengan menggunakan statistik uji Durbin Watson. Hipotesis yang diuji adalah:

H_0 : Tidak terdapat autokorelasi antar sisaan

H_1 : Terdapat autokorelasi antar sisaan

Mekanisme uji *Durbin Watson* adalah:

- a. Mengestimasi model regresi dengan metode kuadrat terkecil untuk memperoleh nilai $\hat{\varepsilon}_i$.
- b. Mencari nilai d yang diperoleh dengan rumus:

$$d = \frac{\sum_{i=2}^n (\hat{\varepsilon}_i - \hat{\varepsilon}_{i-1})^2}{\sum_{i=1}^n \hat{\varepsilon}_i^2}$$

- c. Untuk ukuran sampel dan banyaknya variabel tertentu dapat dilihat pada tabel *Durbin Watson* mengenai pasangan nilai kritis d_L dan d_U .
- d. Kriteria keputusan dalam Uji *Durbin Watson* adalah:
 - 1) Jika $d < d_L$ atau $d > 4 - d_L$, maka H_0 ditolak artinya terjadi autokorelasi.
 - 2) Jika $d_U < d < 4 - d_U$, maka H_0 diterima artinya tidak terdapat autokorelasi.

- 3) Jika $d_L \leq d \leq d_U$ atau $4 - d_U \leq d \leq 4 - d_L$, maka tidak dapat diputuskan apakah H_0 diterima atau ditolak, sehingga tidak dapat disimpulkan ada tidaknya autokorelasi.

Selain menggunakan pengujian diatas, dapat pula menggunakan uji *runs test* dengan menggunakan bantuan *software SPSS*, yaitu dilihat dari nilai *Asymp.Sig*, apabila nilai *Asymp.Sig* $> \alpha$ artinya H_0 diterima sehingga dapat disimpulkan bahwa model regresi tidak terdapat autokorelasi.

4. Uji Non Multikolinieritas

Menurut Montgomery, Peck, & Vining (1992: 111), kolinearitas terjadi karena terdapat korelasi yang cukup tinggi di antara variabel independen *VIF (Variance Inflation Factor)* merupakan salah satu cara untuk mengukur besar kolinieritas dan didefinisikan sebagai berikut:

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

dengan $j = 1, 2, \dots, k$ dan k adalah banyaknya variabel independen, sedangkan R_j^2 adalah koefisien determinasi yang dihasilkan dari regresi variabel independen X_j dengan variabel independen lain. Hipotesis nol (H_0) pengujian multikolinieritas adalah tidak terdapat multikolinieritas, dengan kriteria keputusan jika nilai $VIF < 10$ maka H_0 diterima artinya tidak terdapat multikolinieritas.

5. Uji Linearitas

Salah satu asumsi dari analisis regresi adalah linieritas. Maksudnya apakah garis regresi antara X dan Y membentuk garis linear atau tidak. Kalau tidak maka analisis regresi tidak dapat dilanjutkan (Sugiyono, 2013 : 265).

Ada beberapa uji yang dapat dilakukan yaitu salah satunya dengan menggunakan uji Durbin Watson yaitu untuk melihat ada tidaknya autokorelasi dalam suatu model regresi. Pengujian Durbin Watson dilihat dengan membandingkan nilai Durbin Watson (DW) dan nilai dL dalam tabel Durbin Watson dengan taraf signifikansi 5%. Kriteria keputusannya apabila $DW > dL$ maka data berbentuk linear dan apabila $DW < dL$ maka data tidak berbentuk linear.

Uji kelinieran juga dapat dilakukan dengan terlebih dahulu menghitung jumlah kuadrat-kuadrat, disingkat JK, untuk berbagai sumber variasi. Sumber-sumber variasi yang JK-nya perlu dihitung adalah sumber-sumber variasi untuk jumlah kuadrat total, jumlah kuadrat (a), jumlah kuadrat (b|a), jumlah kuadrat sisa, jumlah kuadrat tuna cocok (F hitung) dan jumlah kuadrat galat (*error*) yang dapat dihitung dengan menggunakan rumus-rumus berikut:

$$JK(T) = \sum Y^2$$

$$JK(A) = \frac{(\sum Y)^2}{n}$$

$$JK(b|a) = b \left\{ \sum XY - \frac{(\sum X)(\sum Y)}{n} \right\}$$

$$= \frac{[n \sum XY - (\sum X)(\sum Y)]^2}{n[n \sum X^2 - (\sum X)^2]}$$

$$JK(S) = JK(T) - JK(a) - JK(b|a)$$

$$JK(TC) = \sum_{xi} \left\{ \sum Y - \frac{(\sum Y)^2}{n_i} \right\}$$

Dimana:

JK(T) : Jumlah Kuadrat Total

JK(a) : Jumlah Kuadrat koefisien a

JK(b|a) : Jumlah Kuadrat Regresi (b|a)

JK(S) : Jumlah Kuadrat Sisa

JK(TC) : Jumlah Kuadrat Tuna Cocok

JK(G) : Jumlah Kuadrat Galat

C. Metode Kuadrat Terkecil

Menurut Montgomery & Peck (1992:112), metode kuadrat terkecil digunakan untuk mengestimasi koefisien $\beta_0, \beta_1, \beta_2, \dots, \beta_k$ yaitu dengan meminimumkan jumlah kuadrat galat. Fungsi yang meminimumkan adalah:

$$\begin{aligned} S(\beta_0, \beta_1, \beta_2, \dots, \beta_k) &= \sum_{i=1}^n e_i^2 \\ &= \sum_{i=1}^n (y_i - \beta_0 - \sum_{j=1}^k \beta_j x_{ij})^2 \end{aligned} \quad (2.3)$$

Fungsi S akan diminimumkan dengan menentukan turunannya terhadap $\beta_0, \beta_1, \beta_2, \dots, \beta_k$, harus memenuhi

$$\left. \frac{\partial S}{\partial \beta} \right|_{\beta_0, \beta_1, \beta_2, \dots, \beta_k} = -2 \sum_{i=1}^n (y_i - \beta_0 - \sum_{j=1}^k \beta_j x_{ij}) = 0$$

Pada umumnya Y adalah matriks berukuran $(n \times 1)$, sedangkan X adalah matriks berukuran $(n \times k)$, β berukuran $(k \times 1)$, dan e adalah matriks berukuran $(n \times 1)$. *Error* dapat diturunkan dari persamaan di atas sehingga diperoleh:

$$e = Y - X\beta$$

Menurut Montgomery & Peck (1992:121), untuk menentukan estimator-estimator kuadrat terkecil, $\hat{\beta}$ yang meminimumkan $S(\beta_j)$ adalah:

$$\begin{aligned} S(\beta) &= \sum_{i=1}^n e_i^2 = e^T e \\ &= (Y - X\beta)^T (Y - X\beta) \\ &= Y^T Y - Y^T X\beta - \beta^T X^T Y + \beta^T X^T X\beta \\ &= Y^T Y - 2\beta^T X^T Y + \beta^T X^T X\beta \end{aligned} \quad (2.7)$$

Matriks $\beta^T X^T Y$ adalah matriks berukuran (1×1) , atau sebuah skalar, dan transpose $\beta^T X^T Y = Y^T X\beta$ yang merupakan skalar.

Kemudian akan ditentukan turunan parsial fungsi $S(\beta)$ terhadap β untuk menentukan estimator kuadrat terkecil.

$$\begin{aligned} \left. \frac{\partial S}{\partial \beta} \right|_{\beta} &= \frac{\partial (Y^T Y - 2\beta^T X^T Y + \beta^T X^T X\beta)}{\partial \beta} \\ &= \frac{\partial (Y^T Y)}{\partial \beta} - 2 \frac{\partial (\beta^T X^T Y)}{\partial \beta} + \frac{\partial (\beta^T X^T X\beta)}{\partial \beta} \\ &= 0 - 2X^T Y + 2X^T X\beta \\ &= -2X^T Y + 2X^T X\beta \end{aligned}$$

sehingga,

$$\left. \frac{\partial S}{\partial \beta} \right|_{\beta} = \frac{\partial (Y^T Y - 2\beta^T X^T Y + \beta^T X^T X\beta)}{\partial \beta}$$

$$= -2X^T Y + 2X^T X \beta \quad (2.8)$$

Agar diperoleh estimator-estimator kuadrat terkecil, maka harus meminimalkan turunan parsial fungsi $S(\beta)$ terhadap β dan memenuhi

$$\frac{\partial S}{\partial \beta} = 0$$

Dengan menyelesaikan persamaan (2.8), akan diperoleh estimator untuk β yaitu:

$$\begin{aligned} \frac{\partial S}{\partial \beta} &= 0 \\ -2X^T Y + 2X^T X \beta &= 0 \\ 2X^T X \beta &= 2X^T Y \\ X^T X \beta &= X^T Y \end{aligned} \quad (2.9)$$

Apabila kedua ruas dikalikan invers dari matriks $(X^T X)$, maka estimasi kuadrat terkecil dari β , yaitu:

$$\begin{aligned} (X^T X)^{-1} X^T X \beta &= (X^T X)^{-1} X^T Y \\ \beta &= (X^T X)^{-1} X^T Y \end{aligned} \quad (2.10)$$

Diasumsikan bahwa invers matriks $(X^T X)^{-1}$ ada. Diperoleh matriks dari matriks persamaan normal (2.9) yang identik dengan bentuk skalar pada persamaan (2.6). Dari persamaan (2.9) diperoleh:

$$\begin{bmatrix} n & \sum_{i=1}^n x_{i1} & \sum_{i=1}^n x_{i2} & \cdots & \sum_{i=1}^n x_{ik} \\ \sum_{i=1}^n x_{i1} & \sum_{i=1}^n x_{i1}^2 & \sum_{i=1}^n x_{i1}x_{i2} & \cdots & \sum_{i=1}^n x_{i1}x_{ik} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \sum_{i=1}^n x_{ik} & \sum_{i=1}^n x_{ik}x_{i1} & \sum_{i=1}^n x_{ik}x_{i2} & \cdots & \sum_{i=1}^n x_{ik}^2 \end{bmatrix} \begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \\ \vdots \\ \hat{\beta}_k \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^n y_i \\ \sum_{i=1}^n x_{i1}y_i \\ \vdots \\ \sum_{i=1}^n x_{ik}y_i \end{bmatrix}$$

Matriks $X^T X$ adalah matrik persegi berukuran $k \times k$ dan $X^T Y$ adalah vektor $k \times 1$. Diagonal elemen matriks $X^T X$ merupakan jumlah kuadrat dari kolom-kolom X , dan elemen-elemen selain diagonalnya merupakan perkalian elem dalam kolom X . Sedangkan elemen-elemen matriks $X^T Y$ adalah jumlah perkalian anantara kolom X dan observasi y_i .

Model regresi dengan variabel independen $x^T = [1, x_1, \dots, x_k]$, diperoleh:

$$\hat{y} = x^T \hat{\beta} = [1, x_1, \dots, x_k] \begin{bmatrix} \hat{\beta}_0 \\ \hat{\beta}_1 \\ \vdots \\ \hat{\beta}_k \end{bmatrix}$$

sehingga

$$\hat{y} = x^T \hat{\beta} = \hat{\beta}_0 + \sum_{j=1}^k \hat{\beta}_j x_j$$

Dengan penjabaran $x^T = \begin{bmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1k} \\ 1 & x_{21} & x_{22} & \cdots & x_{2k} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \cdots & x_{nk} \end{bmatrix} = X$, maka dapat dituliskan

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

dengan matriks persegi yang disebut matriks *hat*

$$H = X(X^T X)^{-1}X^T \quad (2.11)$$

D. Pencilan (*Outlier*)

Dalam deteksi pencilan (*outlier*) terdapat beberapa metode untuk menentukan batasan *outlier* dalam sebuah analisis, yaitu:

1. *Scatter plot*

Dalam *scatter plot* untuk mengetahui apakah suatu data terdapat *outlier*, dapat dilakukan dengan membentuk diagram pencar (*scatter plot*) dari data. Jika terdapat satu atau beberapa data yang terletak jauh dari pola kumpulan data maka hal tersebut mengindikasikan adanya *outlier*.

2. *Standardized Residual*

Pendeteksian *outlier* menggunakan metode ini yaitu dengan memeriksa residual. Rumus residual ke-*i* adalah sebagai berikut:

$$\varepsilon_i = y_i - \hat{y}_i \quad (2.12)$$

Sesuai dengan residual ke-*i* di atas, dapat didefinisikan *standardized residual* ke-*i* sebagai berikut:

$$\varepsilon_{is} = \frac{\varepsilon_i}{\sqrt{MSE}} \quad (2.13)$$

dengan $MSE = \frac{\sum_{l=1}^N \varepsilon_l^2}{n-k}$

n : banyaknya data

k : banyaknya variabel independen

Mean Squared Error (MSE) adalah rata-rata residual kuadrat dan akar dari *MSE* disebut standar error. Standar error merupakan ukuran kebaikan model regresi. Standar error mengukur besarnya variansi model regresi, semakin kecil nilainya semakin baik model regresinya. Untuk melakukan identifikasi *outlier*, diperhatikan nilai-nilai dari *standardized residual*. Jika nilai dari *standardized*

residual lebih dari 3,5 atau kurang dari -3,5 maka data tersebut dikatakan sebagai *outlier* (Yaffe, 2002: 35)

E. Regresi *Robust*

Regresi *robust* diperkenalkan oleh Andrews (1972) merupakan metode regresi yang sering digunakan ketika terdapat beberapa *outlier* yang berpengaruh pada model dan tanpa menghapus data yang teridentifikasi adanya *outlier*. Metode ini merupakan metode untuk menganalisis data yang dipengaruhi oleh *outlier* sehingga dihasilkan model yang *robust* atau *resistance* terhadap *outlier*. Suatu estimator yang *robust* adalah relatif tidak berpengaruh oleh adanya perubahan besar pada bagian kecil data atau perubahan kecil pada bagian besar data (Widodo, Guritno, & Haryatmi, 2013).

Menurut (Chen, 2002) metode-metode estimasi dalam regresi *robust* diantaranya adalah:

1. Estimasi-M (*Maximum likelihood type*) yang diperkenalkan oleh Huber (1973) merupakan metode yang sederhana baik dalam perhitungan maupun secara teoritis.
2. Estimasi-LMS (*Least Median Squares*) merupakan metode yang diperkenalkan oleh Hampel (1975). Metode ini memiliki nilai *breakdown point* hingga 50%, namun memiliki efisiensi yang sangat rendah. *Breakdown point* merupakan ukuran umum dari data *outlier* yang dapat ditangani sebelum observasi mempengaruhi model prediksi (Rousseeuw, 1984).
3. Estimasi-LTS (*Least Trimmed Squares*) merupakan metode yang memiliki nilai *breakdown point* tinggi yang diperkenalkan oleh Rousseeuw (1984).

4. Estimasi-S (*Scale*) juga merupakan metode dengan memiliki nilai *breakdown point* tinggi yang diperkenalkan oleh Rousseeuw dan Yohai (1984). Meski memiliki nilai *breakdown point* yang sama dengan estimasi LTS, namun estimasi-S memiliki efisiensi yang lebih tinggi dibanding estimasi-LTS.
5. Estimasi-MM (*Method of Moment*) merupakan metode yang diperkenalkan oleh Yohai (1987). Metode ini merupakan metode yang menggabungkan estimasi-S (estimasi yang memiliki *breakdown point* tinggi) dan estimasi-M.

F. Koefisien Determinasi

Koefisien determinasi atau biasa disebut *Adj.R-Square* merupakan salah satu ukuran yang sederhana dan sering digunakan untuk menguji kualitas suatu persamaan garis regresi (Gujarati, 2004). Nilai koefisien determinasi memberikan gambaran tentang kesesuaian variabel independen dalam memprediksi variabel dependen. Semakin besar nilai *Adj.R-Square*, maka semakin besar variasi variabel dependen (Y) yang dijelaskan oleh variasi variabel-variabel independen (X). Sebaliknya, semakin kecil nilai *Adj.R-Square*, maka semakin kecil variasi variabel dependen yang dapat dijelaskan oleh variasi variabel independen.

Sifat dari koefisien determinasi adalah (Gujarati, 2004):

1. *Adj.R-Square* merupakan besaran yang non negatif
2. Batasnya adalah $0 \leq \text{Adj.} R - \text{Square} \leq 1$

Apabila nilai koefisien determinasi semakin besar atau mendekati 1, menunjukkan adanya hubungan yang sempurna. Sedangkan apabila nilai koefisien determinasinya adalah 0 menunjukkan bahwa tidak terdapat hubungan antara variabel independen dengan variabel dependen.

G. Breakdown Point

Breakdown point merupakan fraksi terkecil dari data yang terkontaminasi *outlier* yang dapat menyebabkan estimator tidak berfungsi (Montgomery, Peck, & Vining 2006).

Breakdown point adalah jumlah observasi minimal yang dapat menggantikan sejumlah observasi awal yang berakibat pada nilai estimator yang dihasilkan sangat berbeda dari estimator sebenarnya. Dengan kata lain, *breakdown point* sebagai suatu ukuran kerobustan dari suatu estimator. *Breakdown point* merupakan ukuran umum proporsi dari *outlier* yang dapat ditangani sebelum observasi tersebut mempengaruhi model prediksi. Semakin besar nilai persentase dari *breakdown point* pada suatu estimator, maka estimator tersebut semakin *robust* (Sahari, 2012). Regresi *robust* yang mempunyai *breakdown point* adalah regresi *robust* dengan metode estimasi-S, LTS, LMS, dan MM. Estimasi-S dapat digunakan untuk mengatasi masalah *outlier* dengan proporsi hingga 50% serta digunakan ketika variabel dependen dan variabel independen terdapat *outlier*.