

**PENDUGAAN PARAMETER PARTIAL LEAST SQUARE
REGRESSION (PLSR) MENGGUNAKAN NONLINIER
ITERATIVE PARTIAL LEAST SQUARE (NIPALS) PADA
REGRESI LOGISTIK ORDINAL**

SKRIPSI

oleh:
Yeni Purwanti
105090507111014



**PROGRAM STUDI STATISTIKA
JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS BRAWIJAYA
MALANG
2014**

PENDUGAAN PARAMETER *PARTIAL LEAST SQUARE REGRESSION* (PLSR) MENGGUNAKAN *NONLINIER ITERTIVE PARTIAL LEAST SQUARE* (NIPALS) PADA REGRESI LOGISTIK ORDINAL

SKRIPSI

Sebagai salah satu syarat untuk memperoleh gelar Sarjana Sains dalam bidang Statistika

oleh:
YENI PURWANTI
105090507111014



**PROGRAM STUDI STATISTIKA
JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS BRAWIJAYA
MALANG
2014**

LEMBAR PENGESAHAN SKRIPSI

PENDUGAAN PARAMETER *PARTIAL LEAST SQUARE REGRESSION* (PLSR) MENGGUNAKAN *NONLINIER ITERTIVE PARTIAL LEAST SQUARE* (NIPALS) PADA REGRESI LOGISTIK ORDINAL

oleh:

YENI PURWANTI

105090507111014

Setelah dipertahankan di depan Majelis Penguji pada tanggal 23 Juni 2014 dan dinyatakan syarat untuk memperoleh gelar Sarjana Sains dalam bidang Statistika

Dosen Pembimbing

Eni Sumarminingsih S.Si., MM.

NIP. 197705152002122009

Mengetahui

Ketua Jurusan Matematika

Fakultas MIPA Universitas Brawijaya

Dr. Abdul Rouf Alghofari, M.Sc.

NIP. 196709071992031001

LEMBAR PERNYATAAN

Saya yang bertanda tangan di bawah ini :

Nama : YENI PURWANTI
NIM : 105090507111014
Program Studi : STATISTIKA
Penulis Skripsi Berjudul :

PENDUGAAN PARAMETER *PARTIAL LEAST SQUARE REGRESSION (PLSR)* MENGGUNAKAN *NONLINIER ITERATIVE PARTIAL LEAST SQUARE (NIPALS)* PADA REGRESI LOGISTIK ORDINAL

Dengan ini menyatakan bahwa :

1. Isi dari Skripsi yang saya buat adalah benar-benar karya sendiri dan tidak menjiplak karya orang lain, selain nama-nama yang termaktub di isi dan tertulis di daftar pustaka dalam Skripsi ini.
2. Apabila di kemudian hari ternyata Skripsi yang saya tulis terbukti hasil jiplakan, maka saya akan bersedia menanggung resiko yang akan saya terima.

Demikian pernyataan ini dibuat dengan segala kesadaran.

Malang, 23 Juni 2014

Yang menyatakan,

YENI PURWANTI
NIM. 105090507111014

PENDUGAAN PARAMETER *PARTIAL LEAST SQUARE REGRESSION* (PLSR) MENGGUNAKAN *NONLINIER ITERATIVE PARTIAL LEAST SQUARE* (NIPALS) PADA REGRESI LOGISTIK ORDINAL

ABSTRAK

Regresi logistik adalah pemodelan matematik yang dapat digunakan untuk menggambarkan hubungan beberapa peubah prediktor dengan peubah respon yang berupa kategori. Regresi logistik yang melibatkan peubah respon dengan kategori lebih dari dua disebut sebagai regresi logistik ordinal. Pada analisis regresi logistik, asumsi yang harus terpenuhi yaitu tidak adanya multikolinieritas. Jika terdapat multikolinieritas, maka perlu dilakukan pendugaan parameter menggunakan *Partial Least Square Regression* (PLSR) agar tidak menghasilkan interpretasi model ataupun koefisien regresi yang tidak tepat. PLSR merupakan model yang menghubungkan peubah respon numerik dengan peubah prediktor numerik maupun kategorik. Metode PLSR dilakukan dengan pembentukan komponen yang ortogonal. Salah satu metode pembentukan komponen yang dapat digunakan yaitu dengan *Nonlinier Iterative Partial Least Square* (NIPALS). Dalam penelitian ini bertujuan untuk melakukan pendugaan parameter menggunakan pedekatan PLSR dengan NIPALS pada regresi logistik ordinal yang melanggar asumsi non-multikolinieritas dan akan dilakukan pemodelan pada data sifat hujan di Kota Pacitan Tahun 2001-2010. Hasil analisis menunjukkan bahwa semakin meningkatnya peubah prediktor suhu permukaan laut pada grid 29, grid 30, grid 31, NINO 3.4, anomali pada NINO 3.4, SOI akan meningkatkan sifat hujan di Kota Pacitan menjadi diatas normal.

Kata Kunci : Regresi Logistik Ordinal, *Partial Least Square Regression* (PLSR), *Non linier Iterative Partial Least Square* (NIPALS)

ESTIMATION PARAMETER PARTIAL LEAST SQUARE REGRESSION (PLSR) USING NONLINEAR ITERATIVE PARTIAL LEAST SQUARE (NIPALS) ON ORDINAL LOGISTIC REGRESSION

ABSTRACT

Logistic regression is a mathematical modeling that can be used to describe the relationship of multiple predictor variables with a categories response variable. Logistic regression involving a response variable with more than two categories referred to as the ordinal logistic regression. In logistic regression analysis, there is one assumption that must be fulfill which is no multicollinearity. If there is multicollinearity, Partial Least Square Regression (PLSR) so it will not produce inappropriate model or interpretation of the regression coefficients. PLSR is a model that links numerical response variable with numerical and categorical predictor variables. PLSR method is created by forming orthogonal components. One method of formation of the components that can be used is by Nonlinear Iterative Partial Least Square (NIPALS). The purpose of this study is to estimate parameter using Partial PLSR with NIPALS on ordinal logistic regression that is not fulfiil the assumption of non-multicollinearity that will be applied to the data nature of rainfall at the pacitan city in 2001-2010. The analysis showed that increasing sea surface temperature as the predictor variables on grid 29, grid 30, grid 31, NINO 3.4, anomalies in the NINO 3.4, SOI will increase the properties of rain in the Pacitan city to became above normal.

Keywords: Ordinal Logistic Regression, Partial Least Square Regression (PLSR), Non-linear Iterative Partial Least Square (NIPALS)

KATA PENGANTAR

Puji syukur kehadirat Allah SWT, atas segala rahmat dan hidayah-Nya sehingga penulis dapat menyelesaikan skripsi berjudul “Pendugaan Parameter *Partial Least Square Regression* (PLSR) Menggunakan *Nonlinier Itertive Partial Least Square* (NIPALS) Pada Regresi Logistik Ordinal” sebagai salah satu syarat untuk memperoleh gelar Sarjana Sains dalam bidang Statistika. Oleh karena itu penulis ingin mengucapkan terima kasih kepada :

1. Ibu Eni Sumarminingsih, S.Si., M.M. selaku Dosen Pembimbing yang telah memberikan pengarahan dan masukan dengan sabar kepada penulis selama penyusunan skripsi ini.
2. Ibu Dr. Ir. Atiek Iriany, M.S. dan ibu Dr. Ir. Ni Wayan Surya W., M.S. selaku Dosen Penguji 1 dan dosen penguji 2 yang telah memberikan pengarahan dan masukan dengan sabar kepada penulis selama penyusunan skripsi ini.
3. Bapak Dr. Abdul Rouf Alghofari, M.Sc selaku Ketua Jurusan Matematika Fakultas MIPA Universitas Brawijaya.
4. Bapak ibu Dosen Statistika atas ilmu yang diberikan selama kuliah.
5. Ibu, Bapak, Mas Arif, dek alex, dan keluarga tercinta untuk kasih sayang, semangat, dukungan serta doa restu yang selalu diberikan.
6. Semua sahabat terbaikku Fira, Dian, Arista, Ayu, Sasha, Piping, Afrian dan semua teman-teman Statsistika 2010, Keluargaku Tamborin Lufi, Ricca, Meita, Kuro, Azmi, Silvy, Novia, Serta sahabatku Delate Ricca, Ilma, Wanti, Tika, Sanggah, Yogie terimakasih atas doa, semangat dan dukungannya selama ini.
7. Semua pihak yang telah membantu penulisan skripsi ini yang tidak dapat penulis sebutkan satu-persatu.

Penulis menyadari bahwa skripsi ini masih jauh dari kesempurnaan mengingat keterbatasan kemampuan penulis, oleh karena itu kritik dan saran yang bersifat membangun sangat diharapkan demi tersusunnya penulisan yang lebih baik. Semoga penulisan Skripsi ini dapat memberikan manfaat bagi pembaca.

Malang, Juni 2014

Penulis

DAFTAR ISI

HALAMAN JUDUL	i
LEMBAR PENGESAHAN.....	ii
LEMBAR PERNYATAAN	iii
ABSTRAK	iv
ABSTRACT	v
KATA PENGANTAR	vi
DAFTAR ISI	vii
DAFTAR TABEL	ix
DAFTAR GAMBAR	x
DAFTAR LAMPIRAN.....	xi
BAB I PENDAHULUAN	
1.1 .Latar belakang	1
1.2. Rumusan Masalah	3
1.3. Batasan Masalah.....	3
1.4. Tujuan Penelitian	3
1.5. Manfaat Penelitian	3
BAB II TINJAUAN PUSTAKA	
2.1. Regresi Logistik Ordinal.....	5
2.1.1. Pendugaan Parameter	6
2.1.2. Pengujian Signifikansi Parameter.....	8
2.1.3. Pengujian Kesesuaian Model.....	9
2.1.4. Interpretasi Regresi Logistik Ordinal	10
2.2. Multikolinieritas.....	11
2.3. <i>Partial Least Square Regression (PLSR)</i>	12
2.4. <i>Nonlinier Iterative Partial Least Square (NIPALS)</i> ..	15
2.5. Keortogonalan Matriks Komponen Menggunakan <i>Nonlinier Iterative Partial Least Square (NIPALS)</i> ..	22
2.6. Tinjauan Non Statistik	23
BAB III METODE PENELITIAN	
3.1.Sumber Data	27
3.2.Metode Analisis	29

BAB IV HASIL DAN PEMBAHASAN

4.1. Deskriptif	31
4.2. Pendekripsi Multikolinieritas.....	33
4.3. Pendugaan Parameter <i>Partial Least Square Regression</i> (PLSR) dengan Pembentukan <i>Komponen Nonlinier Iterative Partial Least Square</i> (NIPALS)	35

BAB V KESIMPULAN DAN SARAN

5.1 Kesimpulan	41
5.2 Saran	42

DAFTAR PUSTAKA	43
LAMPIRAN	45



DAFTAR TABEL

Tabel 3.1.	Peubah Peubah yang Digunakan Pada Penelitian	27
Tabel 4.1.	Nilai Rata-rata Setiap Faktor yang Mempengaruhi Sifat Hujan	31
Tabel 4.2.	Selang Nilai Setiap Faktor yang Mempengaruhi Sifat Hujan	32
Tabel 4.3.	Pendugaan Awal Parameter Regresi Logistik Ordinal	34
Tabel 4.4.	Nilai VIF Masing-masing Peubah Prediktor	34
Tabel 4.5.	Bobot W untuk Masing-masing Peubah Prediktor ...	36
Tabel 4.6.	Nilai Komponen T yang Terbentuk Berdasarkan Bobot W	37
Tabel 4.7.	Nilai Loading P.....	37
Tabel 4.8.	Regresi Logistik Ordinal \hat{y} dengan Komponen T	38
Tabel 4.9.	Uji Kesesuaian Model PLSR.....	39
Tabel 4.10.	Nilai <i>Odds Ratio</i>	40

DAFTAR GAMBAR

Gambar 3.1.	Diagram Alir PLSR dengan Pembentukan Komponen NIPALS.....	30
Gambar 4.1.	<i>Presentase Sifat Hujan di Kota Pacitan Tahun 2001-2010.....</i>	31



DAFTAR LAMPIRAN

Lampiran 1	Data Sifat Hujan dan Faktor yang Mempengaruhi di Kota Pacitan Tahun 2001-2010	45
Lampiran 2	Pendugaan Awal Parameter Regresi Logistik Ordinal Menggunakan <i>Software SPSS 17.0</i>	53
Lampiran 3	Pendeteksian Multikolinieritas Menggunakan MINITAB 14	55
Lampiran 4	Syntax NIPALS Pada MATLAB 2010	59
Lampiran 5	Data Terpusat.....	60
Lampiran 6	Nilai Bobot W.....	68
Lampiran 7	Nilai Komponen T	69
Lampiran 8	Nilai Loading P.....	77
Lampiran 9	Regresi Logistik Ordinal \hat{y} dengan Komponen T Menggunakan SPSS 17.0	78
Lampiran 10	Perhitungan Nilai β Hasil Transformasi dari Komponen T	80
Lampiran 11	Perhitungan Nilai β Hasil Transformasi dari Data Terpusat	81
Lampiran 11	Perhitungan Nilai <i>Odds Ratio</i>	82

BAB I

PENDAHULUAN

1.1 Latar Belakang

Regresi logistik adalah pemodelan matematik yang dapat digunakan untuk menggambarkan hubungan beberapa peubah prediktor dengan peubah respon yang berupa kategori. Regresi logistik yang melibatkan peubah respon dengan kategori lebih dari dua dengan skala ordinal disebut sebagai regresi logistik ordinal. Persamaan model regresi logistik menghasilkan peluang kejadian yang digunakan sebagai ukuran untuk klasifikasi pengamatan.

Pada analisis regresi, Hubungan antar peubah prediktor merupakan indikasi adanya pelanggaran asumsi non-multikolinieritas. Jika terdapat multikolinieritas, penduga dari metode kuadrat terkecil dapat diperoleh tetapi nilai baku akan cenderung membesar seiring dengan tingkat kolinieritas antar variabel prediktor yang juga meningkat. Sehingga perlu dilakukan pendekatan lain agar tidak menghasilkan interpretasi model ataupun koefisien regresi yang tidak tepat dan mungkin dapat terjadi kesalahan dalam pengambilan keputusan. Dalam mengatasi multikolinieritas, pada umumnya akan dilakukan pengambilan tindakan membuang peubah yang saling berkorelasi cukup tinggi, padahal kenyataannya peubah tersebut cukup berpengaruh terhadap peubah respon, sehingga tidak ada jaminan bahwa tanpa menggunakan peubah prediktor yang dibuang akan menghasilkan model yang lebih baik. Berdasarkan hal tersebut, maka perlu dilakukan pendekatan dengan metode lain yaitu pendugaan parameter *Partial Least Square Regression* (PLSR).

Partial Least Square Regression (PLSR) diperkenalkan oleh Herman Wold (1975) yang dikembangkan pada regresi dengan peubah respon numerik. PLSR merupakan metode yang dapat digunakan untuk membentuk model ketika asumsi non-multikolinieritas tidak terpenuhi. *Partial Least Square Regression* (PLSR) merupakan model yang menghubungkan peubah respon numerik dengan peubah prediktor numerik maupun kategorik. Metode PLSR dilakukan dengan pembentukan komponen yang ortogonal. Salah satu metode pembentukan komponen yang dapat digunakan yaitu dengan NIPALS (*Nonlinier Iterative Partial Least Square*) yang dapat menjelaskan variasi dari peubah prediktor dan memprediksi peubah respon dengan baik.

Berdasarkan penelitian terdahulu (Lestari, 2013) yang melakukan pembentukan komponen PLSR dengan algoritma PLS-OLR dan penelitian lain (Pawestri, 2012) yang melakukan pendugaan PLSR dengan pembentukan komponen NIPALS pada regresi linier, maka pada penelitian ini akan dilakukan pembentukan komponen PLSR menggunakan algoritma NIPALS (*Nonlinier Iterative Partial Least Square*) pada regresi logistik ordinal yang akan dilakukan pada data sifat hujan di Kota Pacitan Tahun 2001-2010.

Indonesia merupakan negara agraris yang kaya akan pertanian khususnya pada tanaman pangan. Dalam berproduksi, pada umumnya tanaman pangan sangat berkaitan erat dengan iklim yang sedang terjadi di Indonesia. Salah satu faktor yang sangat mempengaruhi iklim di indonesia adalah curah hujan. Berdasarkan curah hujan, sifat hujan dibagi menjadi 3 yaitu diatas normal, normal, dan dibawah normal. Pada kasus ini, jika untuk mengetahui pengaruh faktor-faktor tersebut terhadap sifat hujan yang terjadi di indonesia, maka dapat dilakukan dengan analisis regresi logistik ordinal.

Indonesia merupakan negara yang berada diantara dua samudra dan dua benua. Posisi ini yang menyebabkan curah hujan di indonesia sangat dipengaruhi oleh angin barat dan angin timur, di mana angin barat dan angin timur dipengaruhi oleh suhu permukaan laut, perubahan suhu permukaan laut yang terjadi di wilayah samudra pasifik, dan indeks osilasi selatan yang menunjukkan perbedaan tekana udara permukaan antara Tahiti di kepulauan Polenesia-Prancis dengan tekanan udara di Darwin-Australia. Suhu permukaan laut yang mempengaruhi curah hujan di Indonesia yaitu pada wilayah Samudra Hindia dan Samudra pasifik. Pada samudra pasifik, suhu permukaan laut diamati pada wilayah Nino 3.4. Sedangkan suhu permukaan laut yang terjadi di Samudra Hindia diamati berdasarkan wilayah yaitu pada grid 28, grid 29, grid 30, dan grid 31. Berdasarkan lokasi grid 28, grid 29, grid 30, grid 31 yang berdekatan dengan luas masing-masing sebesar 110 km x 110, maka dapat mengakibatkan adanya hubungan antar faktor-faktor tersebut atau dapat teridentifikasi adanya multikolinieritas. Sehingga pada kasus ini dapat dilakukan pendugaan parameter *Partial Least Square Regression* (PLSR) dengan pembentukan komponen *Nonlinier Iterative Partial Least Square* (NIPALS) untuk mengatasi multikolinieritas.

1.2 Rumusan Masalah

Berdasarkan latar belakang diidentifikasi masalah Bagaimana model regresi logistik ordinal yang terbentuk menggunakan pendekatan PLSR dengan pembentukan komponen NIPALS?

1.3 Batasan Masalah

Pada penelitian ini, permasalahan dibatasi pada data yang melanggar asumsi non-multikolinieritas pada regresi logistik ordinal dan dilakukan pendekatan PLSR dengan pembentukan komponen NIPALS.

1.4 Tujuan Penelitian

Penelitian ini bertujuan untuk melakukan pendugaan parameter menggunakan pendekatan *Partial Least Square* (PLS) dengan *Nonlinier Iterative Partial Least Square* (NIPALS) pada regresi logistik yang melanggar asumsi non- multikolinieritas.

1.5 Manfaat Penelitian

Manfaat dari penelitian ini untuk mengatasi pelanggaran asumsi non-multikolinieritas sehingga menghasilkan interpretasi model ataupun koefisien regresi logistik yang tepat dan tidak mengalami kesalahan dalam pengambilan keputusan.

UNIVERSITAS BRAWIJAYA



BAB II

TINJAUAN PUSTAKA

2.1 Regresi Logistik Ordinal

Regresi logistik ordinal adalah regresi dengan peubah respon kategorik yang polikotomus. Jika peubah respon Y adalah peubah dengan skala ordinal dan memiliki c kategori kemudian $P(Y \leq j)$ adalah peluang Y berada pada kategori j atau kategori di bawahnya (yaitu kategori 1,2, ..., j), maka peluang tersebut disebut sebagai peluang kumulatif yang dinyatakan (Hosmer dan Lemeshow, 2000):

$$P(Y \leq j|x_i) = \frac{\exp(\theta_j + \sum_{k=1}^p \beta_k x_{ik})}{1 + \exp(\theta_j + \sum_{k=1}^p \beta_k x_{ik})} \quad (2.1)$$

Pengembangan model logistik ordinal disebut *Proportional Odds Model*. *Proportional Odds* adalah besaran odd peubah respon pada kategori ke-j atau dibawahnya. Sehingga dapat dinyatakan:

$$\text{odds}(Y \leq j) = \frac{P(Y \leq j)}{P(Y > j)} \quad (2.2)$$

Model untuk peubah respon berskala ordinal menggunakan logit dari peluang kumulatif.

$$\text{logit}[P(Y \leq j)] = \log[\text{odds}(Y \leq j)] \quad (2.3)$$

Logit didapatkan dengan mensubstitusikan persamaan (2.1) terhadap persamaan (2.2), sehingga:

$$\text{logit}[P(Y \leq j|x_i)] = \log \left[\frac{P(Y \leq j|x_i)}{P(Y > j|x_i)} \right], j = 1, 2, \dots, c-1 \quad (2.4)$$

di mana

$$\begin{aligned} P(Y > j|x_i) &= 1 - P(Y \leq j|x_i) \\ &= 1 - \left(\frac{\exp(\theta_j + \sum_{k=1}^p \beta_k x_{ik})}{1 + \exp(\theta_j + \sum_{k=1}^p \beta_k x_{ik})} \right) \\ &= \frac{1}{1 + \exp(\theta_j + \sum_{k=1}^p \beta_k x_{ik})} \end{aligned} \quad (2.5)$$

Dengan mensubstitusikan persamaan (2.5) pada persamaan (2.4) maka diperoleh persamaan sebagai berikut:

$$\text{logit } [P(Y \leq j|x_i)] = \log \left(\frac{\frac{\exp(\theta_j + \sum_{k=1}^p \beta_k x_{ik})}{1+\exp(\theta_j + \sum_{k=1}^p \beta_k x_{ik})}}{\frac{1}{1+\exp(\theta_j + \sum_{k=1}^p \beta_k x_{ik})}} \right)$$

$$\text{logit } [P(Y \leq j|x_i)] = \theta_j + \sum_{k=1}^p \beta_k x_{ik} \quad (2.6)$$

Bila terdapat j kategori peubah respon, maka akan terbentuk $j-1$ fungsi pembeda. Klasifikasi fungsi pembeda didapatkan dari *cumulative logit model*. Peluang kumulatif pada peubah prediktor $P(Y \leq j|x_i)$ merupakan penjumlahan dari peluang kategori respon setiap j pada p peubah prediktor $\pi_j(x_i)$ yang dinyatakan dengan persamaan sebagai berikut:

$$P(Y \leq j|x_i) = \sum_{k=1}^j \pi_j(x_i)$$

Di mana

$$\begin{aligned} \pi_j(x_i) &= P(Y = j|x_i) \\ &= P(Y \leq j) - P(Y \leq j-1) \\ &= \frac{\exp(\theta_j + \sum_{k=1}^p \beta_k x_{ik})}{1+\exp(\theta_j + \sum_{k=1}^p \beta_k x_{ik})} - \frac{\exp(\theta_{j-1} + \sum_{k=1}^p \beta_k x_{ik})}{1+\exp(\theta_{j-1} + \sum_{k=1}^p \beta_k x_{ik})} \end{aligned} \quad (2.7)$$

2.1.1 Pendugaan Parameter

Pendugaan parameter pada analisis regresi logistik ordinal menggunakan pendekatan *maximum likelihood*. *Maximum likelihood* menghasilkan nilai yang memaksimalkan peluang dari data sejumlah observasi ((Hosmer dan Lemeshow, 2000)).

Dalam mengaplikasikan metode *maximum likelihood*, maka harus membentuk suatu fungsi yang dapat menunjukkan peluang data yang diobservasi sebagai fungsi dari parameter yang diestimasi. Fungsi tersebut adalah *log likelihood function* (Agresti, 2002):

$$\begin{aligned} L(\beta) &= \prod_{i=1}^n \prod_{j=0}^{j-1} P(Y = j | X^{y_{ij}}) \\ L(\beta) &= \prod_{j=1}^n (\pi_1(x_i))^{y_{1i}} \dots (\pi_{j-1}(x_i))^{y_{(j-1)i}} \\ \log(L(\beta)) &= \log(\prod_{j=1}^n (\pi_1(x_i))^{y_{1i}} \dots (\pi_j(x_i))^{y_{ji}}) \\ \log(L(\beta)) &= \sum_{i=1}^n \{ y_{1i} \log(\pi_1(x_i)) + \dots + y_{ji} \log(\pi_j(x_i)) \} \end{aligned} \quad (2.8)$$

Peluang kategori respon setiap j pada p peubah prediktor $\pi_1(x_i)$ dapat digunakan rumus pada persamaan (2.7), maka persamaan *log likelihood* didapatkan dengan mensubtitusikan persamaan (2.7) pada persamaan (2.8):

$$\begin{aligned} \log(L(\beta)) = \sum_{i=1}^n \{ y_{1i} \log \left(\frac{\exp(\theta_1 + \sum_{k=1}^p \beta_k x_{ik})}{1 + \exp(\theta_1 + \sum_{k=1}^p \beta_k x_{ik})} \right) + \dots \\ + y_{(j-1)} \log \left(\frac{\exp(\theta_j + \sum_{k=1}^p \beta_k x_{ik})}{1 + \exp(\theta_j + \sum_{k=1}^p \beta_k x_{ik})} \right) \\ - \frac{\exp(\theta_{j+1} + \sum_{k=1}^p \beta_k x_{ik})}{1 + \exp(\theta_{j+1} + \sum_{k=1}^p \beta_k x_{ik})} \} \end{aligned} \quad (2.9)$$

Dengan mendiferensikan fungsi *log likelihood* terhadap parameter yang diduga dan menyamakan dengan nol, maka akan diketahui parameter θ dan β .

$$\begin{aligned} \frac{\partial \log(L(\beta))}{\partial \theta_1} = \sum_{i=1}^n \left\{ 1 - \frac{\exp(\theta_1 + \sum_{k=1}^p \beta_k x_{ik})}{1 + \exp(\theta_1 + \sum_{k=1}^p \beta_k x_{ik})} \right. \\ \left. + y_{2i} \left(-\frac{\exp(\theta_1)}{\exp(\theta_2 - \theta_1)} - \frac{\exp(\theta_1 + \sum_{k=1}^p \beta_k x_{ik})}{1 + \exp(\theta_1 + \sum_{k=1}^p \beta_k x_{ik})} \right) \right\} = 0 \end{aligned} \quad (2.10)$$

Persamaan *log likelihood* pada persamaan diatas bukan merupakan fungsi linier dalam β sehingga nilai dugaan β dicari menggunakan metode numerik. Metode yang digunakan adalah metode iterasi *Newton-Raphson*. Prosedur iterasi *Newton Raphson* untuk mencari pendugaan β adalah (Hosmer dan Lemeshow, 2000):

1. Mecari pendugaan awal β^t pada iterasi ke-t ($t=1, 2, \dots, n$)
2. Pada setiap iterasi ke ($t+1$) dihitung pendugaan baru dengan persamaan:

$$\beta^{t+1} = \beta^t - [H^{(t)}]^{-1} q^{(t)} \quad (2.11)$$

$H^{(t)}$ merupakan matriks turunan parsial ke-2 dari fungsi *log likelihood* terhadap parameter yang diduga dan $q^{(t)}$ merupakan matriks turunan parsial pertama dari fungsi *log likelihood* terhadap parameter yang diduga. Rumus tersebut dapat dinyatakan sebagai berikut:

$$H^{(t)} = \frac{\partial^2 L(\beta)}{\partial \beta_{jk} \partial \beta_{jk'}} = X' V^t X \quad (2.12)$$

$$q^{(t)} = \frac{\partial L(\beta)}{\partial \beta_{jk}} = X' (Y - \pi^t) \quad (2.13)$$

Di mana

$$\mathbf{X} = \begin{pmatrix} 1 & x_{11} & \dots & x_{1p} \\ 1 & x_{21} & \dots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & \dots & x_{np} \end{pmatrix}$$

Dan

$$\mathbf{Y} = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}$$

sedangkan

$$\mathbf{V} = \begin{pmatrix} \pi^{(t)}_1(1 - \pi^{(t)}_1) & 0 & 0 & 0 \\ 0 & \pi^{(t)}_1(1 - \pi^{(t)}_1) & 0 & 0 \\ 0 & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \pi^{(t)}_1(1 - \pi^{(t)}_1) \end{pmatrix}$$

Matriks \mathbf{X} berukuran $n \times (p+1)$ memiliki elemen-elemen dari peubah prediktor dan matriks \mathbf{V} dengan diagonal utama $[\pi_i(1 - \pi_i)]$.

3. Iterasi berlanjut hingga diperoleh $\beta^{t+1} \approx \beta^t$ atau dapat dikatakan konvergen maka β^{t+1} merupakan pendugaan parameter β .

2.1.2 Pengujian Signifikansi Parameter

Pengujian signifikansi dari parameter dapat dilakukan setelah memperoleh model logit kumulatif. Uji signifikansi dapat dilakukan dengan dua cara yaitu uji secara simultan dan parsial (Hosmer & Lemeshow, 2000).

a. Uji Secara Simultan

Pengujian terhadap parameter model dilakukan untuk memeriksa peranan peubah-peubah prefaktor dalam model. Statistik uji-G adalah uji rasio kemungkinan maksimum (*likelihood ratio test*) yang digunakan untuk menguji peranan peubah prediktor di dalam model secara serempak dengan hipotesis yang diuji adalah:

$$H_0: \beta_1 = \beta_2 = \dots = \beta_p = 0$$

$$H_1: \text{paling sedikit ada satu } \beta_j \neq 0$$

Statistik uji-G didefinisikan sebagai:

$$G = -2 \ln \left[\frac{L_0}{L_p} \right] \quad (2.14)$$

Dengan:

L_0 = likelihood tanpa peubah prediktor

L_p = likelihood dengan p peubah prediktor

Statistik uji-G ini mengikuti sebaran χ^2 dengan derajat bebas p.

Hipotesis nol ditolak jika $G > \chi^2_{p(a)}$ (Hosmer & Lmeshow, 2000).

b. Uji Secara Parsial

Pengujian parameter satu persatu atau secara parsial, dapat dilakukan dengan uji *Wald* dengan hipotesis yang diuji adalah:

$$H_0 : \beta_k = 0$$

$$H_1 : \beta_k \neq 0, k = 1, 2, \dots, p \quad (p \text{ adalah jumlah peubah prediktor})$$

Di mana statistik uji yang digunakan adalah

$$w = \frac{\hat{\beta}}{SE[\hat{\beta}_j]} \quad (2.15)$$

Statistik uji-Wald ini mengikuti sebaran normal baku. Hipotesis nol ditolak jika $|W| > Z_{\alpha/2}$ dan dapat dikatakan bahwa peubah prediktor berpengaruh secara signifikan (Hosmer & Lameshow, 2000).

2.1.3 Pengujian Kesesuaian Model

Pengujian kecocokan model pada analisis regresi logistik menggunakan uji *Pearson* dan uji *Deviance* (Kutner dkk, 2005).

a. Uji Pearson

Pengujian kecocokan model menggunakan uji *Pearson* dilakukan dengan hipotesis yang diuji:

$$H_0: \text{model sesuai}$$

$$H_1: \text{model tidak sesuai}$$

Dengan statistik uji :

$$\chi^2_{pearson} = \sum_{a=1}^h \chi_p^2(y_a \cdot \hat{\pi}_a) \quad (2.16)$$

Di mana

$$\chi_p^2(y_a \cdot \hat{\pi}_a) = \sum_{b=1}^g \frac{(y_{ab} - n_a \hat{\pi}_{ab})^2}{n_a \hat{\pi}_{ab}} \quad (2.17)$$

Dengan

$\hat{\pi}_{ab}$ = peluang kejadian Y pada kategori ke-b dan X ke-a

y_{ab} = banyaknya pengamatan Y pada kategori ke-b dan X ke-a

p = banyaknya parameter yang diduga dalam model

- h = banyaknya kategori pada peubah prediktor X
 g = banyaknya kategori pada peubah prediktor Y
 n_a = banyaknya sampel pada kelompok a ($a=1,2, \dots, h$)

Uji Pearson menyebar mengikuti *chi-square*. Keputusan tolak H_0 jika $\chi^2_{pearson} > \chi^2_{(h(g-1)-p)}$ sehingga dapat disimpulkan bahwa model tidak sesuai untuk data.

b. Uji Deviance

Pengujian kecocokan model menggunakan uji *Deviance* dilakukan dengan hipotesis yang diuji

$$H_0: \text{model sesuai}$$

$$H_1: \text{model tidak sesuai}$$

Dengan Statistik uji:

$$D = 2 \sum_{a=1}^h d(y_a, \hat{\pi}_a)^2 \quad (2.18)$$

Di mana

$$d(y_a, \hat{\pi}_a) = \sum_{b=1}^g y_{ab} \ln \left[\frac{y_{ab}}{n_a \hat{\pi}_{ab}} \right] \quad (2.19)$$

Dengan

$\hat{\pi}_{ab}$ = peluang kejadian Y pada kategori ke-b dan X ke-a

y_{ab} = banyaknya pengamatan Y pada kategori ke-b dan X ke-a

p = banyaknya parameter yang diduga dalam model

h = banyaknya kategori pada peubah prediktor X

g = banyaknya kategori pada peubah respon Y

n_a = banyaknya sampel pada kelompok a ($a=1,2, \dots, h$)

Uji *Deviance* menyebar mengikuti *chi-square*. Keputusan tolak H_0 jika $D > \chi^2_{(h(g-1)-p)}$ sehingga dapat disimpulkan bahwa model tidak sesuai untuk data.

2.1.4 Interpretasi Regresi Logistik Ordinal

Interpretasi model regresi logistik dilakukan saat model yang didapatkan sudah sesuai. Interpretasi model dapat dilakukan dengan menjelaskan tiga hal yaitu hubungan fungsional antara peubah respon dengan peubah prediktor, unit perubahan setiap peubah prediktor serta nilai rasio peluang peubah prediktor. Rasio peluang (*Odd Ratio*) peubah prediktor dapat diinterpretasikan berdasarkan rumus sebagai berikut:

$$\Psi_j = OR(a.b) = \frac{P(Y \leq j|x=a)/P(Y > j|x=a)}{P(Y \leq j|x=b)/P(Y > j|x=b)}, j = 2,3 \quad (2.20)$$

Nilai rasio peluang (*Odd Ratio*) digunakan untuk menunjukkan kecenderungan hubungan antara peubah prediktor terhadap peubah respon. Jika $1 < \Psi < \infty$ menyatakan bahwa $x=a$ mempunyai resiko lebih tinggi Ψ kali dibandingkan dengan $x=b$ untuk meghasilan $Y=j$. Sebaliknya untuk $0 < \Psi < 1$ berarti menyatakan bahwa $x=a$ mempunyai resiko lebih tinggi $1/\Psi$ kali dibandingkan dengan $x=b$ untuk meghasilan $Y=j$ (Kleinbaum dan Klein, 2007).

2.2 Multikolinieritas

Multikolinieritas menunjukkan adanya hubungan linier di antara peubah-peubah prediktor dalam model regresi. Penggunaan kata multikolinieritas untuk menunjukkan adanya derajat kolinieritas yang tinggi di antara peubah-peubah prediktor. Adanya multikolinieritas dapat mengakibat hasil interpretasi koefisien yang tidak tepat dan mungkin akan terjadi kesalahan dalam pengambilan keputusan. Hal tersebut terjadi karena saat terjadi korelasi yang tinggi pada peubah prediktor, kemungkinan terdapat salah satu peubah akan dibuang, sedangkan pada kenyataannya peubah tersebut berpengaruh secara signifikan(Sumodiningrat, 2012).

Metode yang digunakan untuk mendeteksi adanya multikolinieritas berdasarkan nilai koefisien determinasi (R^2), koefisien korelasi partial, dan salah baku dari parameter-parameter regresi. Multikolinieritas dapat diduga saat R^2 tinggi namun peubah prediktor mungkin tidak berpengaruh secara signifikan. Koefisien yang tinggi antar peubah prediktor juga memungkinkan terjadinya multikolinieritas tetapi belum tentu berlaku untuk kasus tertentu. Artinya tingginya nilai koefisien korelasi sederhana merupakan syarat cukup(*sufficient*) akan tetapi bukan syarat yang perlu (*necessary*) untuk terjadinya kolinieritas dalam model regresi dan salah baku yang tak terhingga juga merupakan salah satu akibat dari adanya multikolinieritas (Sumodiningrat, 2012).

Metode untuk mengidentifikasi adanya multikolinieritas adalah dengan VIF (*Varian Inflation Factor*).

$$VIF_j = \frac{1}{1-R_j^2} \quad (2.21)$$

di mana

R_j^2 = koefisien determinasi yang didapat dari regresi antara X_j dengan peubah prediktor lainnya

Apabila nilai $VIF > 10$, maka dapat dikatakan bahwa terdapat hubungan linier antara peubah prediktor j dengan peubah prediktor lainnya. Dengan demikian dapat disimpulkan bahwa jika R^2 tinggi maka nilai VIF juga semakin tinggi sehingga terdapat kemungkinan adanya multikolinieritas (Gujarati, 2004).

Semakin tinggi nilai R^2 semakin besar juga nilai varian dan kovarian dari $\hat{\beta}$. Hal tersebut juga akan mengakibatkan membesarnya galat pendugaan regresi ($\hat{\beta}$). Penjabaran rumus dapat dituliskan sebagai berikut:

$$Var(\hat{\beta}_j) = \frac{\sigma^2}{\sum x_i^2(1-R_j^2)} \quad (2.22)$$

$$Se(\hat{\beta}_j) = \sqrt{Var(\hat{\beta}_j)} \quad (2.23)$$

Semakin besar nilai $Se(\hat{\beta}_j)$, maka multikolinieritas mengakibatkan presisi penduga koefisien regresi semakin kecil. Hal tersebut dapat menunjukkan bahwa semakin tinggi nilai $Se(\hat{\beta}_j)$ maka nilai W pada uji Wald dalam pengujian koefisien akan semakin kecil. Semakin kecil nilai W maka semakin kecil pula peluang untuk menolak H_0 yaitu semakin kecil peluang peubah prediktor berpengaruh terhadap peubah respon (Hosmer dan Lameshow, 2000).

2.3 Partial Least Square Regression (PLSR)

Dasar dari metode PLSR adalah menemukan beberapa kombinasi linier dari peubah-peubah prediktor data asli dan menggunakan kombinasi linier tersebut dalam persamaan regresi. PLSR dapat mengatasi masalah multikolinieritas. Dalam memprediksi Y digunakan regresi standar karena *orthogonality* dari bentuk tunggal vektor menghilangkan masalah multikolonieritas (Bastien, 2004).

Matriks dan vektor data yang digunakan dalam *partial least square* dinotasikan dengan X dan y , matriks X dan vektor y keduanya diasumsikan matriks dan vektor data terpusat. Data terpusat dapat diperoleh dengan tiga cara yaitu menggunakan rata-rata, median dan modus. Pemusatan data dengan rata-rata dapat dilakukan sesuai matriks berikut:

$$\tilde{X} = \begin{bmatrix} x_{11} - \bar{x}_1 & \cdots & x_{1k} - \bar{x}_k \\ \vdots & \ddots & \vdots \\ x_{n1} - \bar{x}_1 & \cdots & x_{nk} - \bar{x}_k \end{bmatrix}$$

Sedangkan pemusatan data dengan modus dapat dilakukan sesuai vektor berikut:

$$\tilde{y} = \begin{bmatrix} y_1 - \text{modus} \\ \vdots \\ y_k - \text{modus} \end{bmatrix}$$

Struktur model untuk metode PLS dinyatakan dalam dua persamaan yang sering disebut model bilinier, yaitu:

$$\begin{aligned} \tilde{\mathbf{X}} &= \mathbf{T}\mathbf{P}^T + \mathbf{E} \\ \begin{bmatrix} x_{11} - \bar{x}_1 & x_{12} - \bar{x}_2 & \cdots & x_{1k} - \bar{x}_k \\ x_{21} - \bar{x}_1 & x_{22} - \bar{x}_2 & \cdots & x_{2k} - \bar{x}_k \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} - \bar{x}_1 & x_{2n} - \bar{x}_2 & \cdots & x_{nk} - \bar{x}_k \end{bmatrix} &= \begin{bmatrix} t_{11} & t_{12} & \cdots & t_{1m} \\ t_{21} & t_{22} & \cdots & t_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ t_{n1} & t_{n2} & \cdots & t_{nm} \end{bmatrix} \begin{bmatrix} p_{11} & p_{21} & \cdots & p_{k1} \\ p_{12} & p_{22} & \cdots & p_{k2} \\ \vdots & \vdots & \ddots & \vdots \\ p_{1m} & p_{2m} & \cdots & p_{km} \end{bmatrix} \\ &\quad + \begin{bmatrix} e_{11} & e_{12} & \cdots & e_{1k} \\ e_{21} & e_{22} & \cdots & e_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ e_{n1} & e_{n2} & \cdots & e_{nk} \end{bmatrix} \\ [\tilde{X}_1 & \tilde{X}_2 \cdots \tilde{X}_k] = [t_1 & t_2 \cdots t_m] \begin{bmatrix} p_1^T \\ p_2^T \\ \vdots \\ p_m^T \end{bmatrix} + E \\ &= t_2 p_1^T + t_2 p_2^T + \cdots + t_m p_m^T + E \\ &= \sum_{j=1}^m t_j p_1^T + E \end{aligned} \tag{2.24}$$

Dimana

\mathbf{X} = matriks peubah prediktor

$\mathbf{P}_{n \times m}$ = matriks koefisien PLS

$\mathbf{E}_{n \times k}$ = matriks residual x

$\mathbf{T}_{n \times m}$ = matriks komponen PLS

Komponen-komponen yang terbentuk digunakan sebagai prediktor baru untuk menduga parameter yang kemudian digunakan untuk memprediksi peubah respon Y. Menggunakan bentuk terpusat, maka model regresi dapat dinyatakan sebagai:

$$\begin{aligned}
 \tilde{\mathbf{y}} &= \mathbf{Tc} + \mathbf{F} \\
 \begin{bmatrix} \tilde{y}_1 \\ \tilde{y}_2 \\ \vdots \\ \tilde{y}_n \end{bmatrix} &= \begin{bmatrix} t_{11} & t_{12} & \cdots & t_{1m} \\ t_{21} & t_{22} & \cdots & t_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ t_{n1} & t_{n2} & \cdots & t_{nm} \end{bmatrix} \begin{bmatrix} c_1 \\ c_2 \\ \vdots \\ c_m \end{bmatrix} + \begin{bmatrix} f_1 \\ f_2 \\ \vdots \\ f_n \end{bmatrix} \\
 &= [\mathbf{t}_1 \ \mathbf{t}_2 \ \cdots \ \mathbf{t}_m] \begin{bmatrix} c_1 \\ c_2 \\ \vdots \\ c_m \end{bmatrix} + \begin{bmatrix} f_1 \\ f_2 \\ \vdots \\ f_n \end{bmatrix} \\
 &= \mathbf{t}_1 c_1 + \mathbf{t}_2 c_2 + \cdots + \mathbf{t}_m c_m + \mathbf{F} \\
 &= \sum_{j=1}^m t_j c_j + F
 \end{aligned} \tag{2.25}$$

Di mana

$\tilde{\mathbf{y}}$ = vektor terpusat peubah y

$\mathbf{T}_{n \times m}$ = matriks komponen PLS

$\mathbf{C}_{n \times 1}$ = vektor parameter

\mathbf{F} = vektor residual y

Vektor *error* F menyatakan seberapa besar $\tilde{\mathbf{y}}$ yang tidak dijelaskan oleh matriks komponen T.

Pada model PLSR, vektor komponen yang dibentuk merupakan kombinasi linier berbobot dari peubah-peubah prediktor, maka dalam notasi matriks dapat dinyatakan nsebagai:

$$\mathbf{T} = \tilde{\mathbf{X}}\mathbf{W} \tag{2.26}$$

Dimana W adalah matriks berukuran k x m yaitu:

$$\mathbf{W} = \begin{bmatrix} w_{11} & w_{12} & \cdots & w_{1m} \\ w_{21} & w_{22} & \cdots & w_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ w_{k1} & w_{k2} & \cdots & w_{km} \end{bmatrix} = [\mathbf{w}_1 \ \mathbf{w}_2 \ \cdots \ \mathbf{w}_m]$$

Bobot yang dipilih pada pembentukan komponen PLSR pada persamaan $T = \tilde{\mathbf{X}}\mathbf{W}$ adalah bobot yang dapat menjelaskan variasi pada $\tilde{\mathbf{X}}$ sekaligus variasi pada $\tilde{\mathbf{y}}$ yaitu melalui fungsi kovarian antara setiap peubah prediktor dengan peubah respon. Hal tersebut dibutuhkan agar komponen yang terbentuk tidak hanya baik dalam menjelaskan variasi dari $\tilde{\mathbf{X}}$ tetapi juga relevan dan baik dalam memprediksi $\tilde{\mathbf{y}}$.

2.4 Nonlinier Iterative Partial Least Square (NIPALS)

NIPALS adalah metode pembentukan matriks komponen yang dapat menjelaskan variansi dari \tilde{X} dan memprediksi \tilde{y} dengan baik. Hal tersebut dapat ditunjukkan dengan algoritma yang membentuk iteratif, sehingga akan dibentuk terlebih dahulu vektor komponen pertama. Kemudian jika diperlukan, maka algoritma ini akan beriterasi untuk membentuk vektor komponen berikutnya (Phatak dan Jong, 1996).

Pembentukan vektor komponen dengan menggunakan algoritma NIPALS yaitu dengan asumsi $X_1 = \tilde{X}$ dan $y_1 = \tilde{y}$, dan pembentukan vektor komponen dapat dilakukan dengan langkah-langkah sebagai berikut:

1. Pembentukan vektor komponen pertama (t_1) merupakan komponen linier dengan setiap peubah prediktor, untuk vektor komponen pertama (t_1) dapat dituliskan sebagai berikut:

$$t_1 = X_1 w_1 \quad (2.27)$$

Di mana w_1 adalah bobot yang merupakan penjumlahan fungsi kovariansi antara setiap peubah prediktor ($\tilde{x}_1, \dots, \tilde{x}_1$) dalam matriks X_1 dan vektor respon y_1 yang dibagi dengan akar dari kuadrat fungsi kovariansi itu sendiri, dengan demikian w_1 dapat dituliskan sebagai:

$$w_1 = \frac{\sum_{l=1}^k cov(\tilde{x}_l, \tilde{y})}{\sqrt{\sum_{l=1}^k cov(\tilde{x}_l, \tilde{y})^2}}, \quad l = 1, \dots, k$$

Berdasarkan matriks kovariansi:

$$cov(\tilde{x}_l, \tilde{y}) = \frac{\sum_{i=1}^n (x_{il} - \bar{x}_l)(y_i - \bar{y})}{n-1}$$

Sehingga w_1 dapat dijabarkan menjadi :

$$\begin{aligned} w_1 &= \frac{\sum_{l=1}^k cov(\tilde{x}_l, \tilde{y})}{\sqrt{\sum_{l=1}^k cov(\tilde{x}_l, \tilde{y})^2}} \\ w_1 &= \frac{\sum_{l=1}^k \left(\frac{\sum_{i=1}^n (x_{il} - \bar{x}_l)(y_i - \bar{y})}{n-1} \right)}{\sqrt{\sum_{l=1}^k \left(\frac{\sum_{i=1}^n (x_{il} - \bar{x}_l)(y_i - \bar{y})}{n-1} \right)^2}} \\ w_1 &= \frac{\frac{1}{n-1} \sum_{l=1}^k (\sum_{i=1}^n (x_{il} - \bar{x}_l)(y_i - \bar{y}))}{\frac{1}{n-1} \sqrt{\sum_{l=1}^k (\sum_{i=1}^n (x_{il} - \bar{x}_l)(y_i - \bar{y}))^2}} \end{aligned}$$

$$w_1 = \frac{\sum_{l=1}^k (\sum_{i=1}^n (x_{il} - \bar{x}_l)(y_i - \bar{y}))}{\sqrt{\sum_{l=1}^k (\sum_{i=1}^n (x_{il} - \bar{x}_l)(y_i - \bar{y}))^2}} \quad (2.28)$$

Di mana $\sum_{i=1}^n (x_{il} - \bar{x}_l)(y_i - \bar{y})$ dapat dijabarkan menjadi:

$$\begin{aligned} \sum_{i=1}^n (x_{il} - \bar{x}_l)(y_i - \bar{y}) &= \sum_{i=1}^n (x_{il}y_i - x_{il}\bar{y} - \bar{x}_l y_i + \bar{x}_l \bar{y}) \\ &= \sum_{i=1}^n x_{il}y_i - \bar{y} \sum_{i=1}^n x_{il} \\ &\quad - \bar{x}_l \sum_{i=1}^n y_i + \sum_{i=1}^n \bar{x}_l \bar{y} \\ &= \sum_{i=1}^n x_{il}y_i - n\bar{x}_l \bar{y} - \bar{n}\bar{x}_l \bar{y} + n\bar{x}_l \bar{y} \\ &= \sum_{i=1}^n x_{il}y_i - n\bar{x}_l \bar{y} \end{aligned} \quad (2.29)$$

Berdasarkan persamaan (2.29) dan (2.28), maka w_1 dapat dijabarkan menjadi :

$$\begin{aligned} w_1 &= \frac{\sum_{l=1}^k (\sum_{i=1}^n x_{il}y_i - n\bar{x}_l \bar{y})}{\sqrt{\sum_{l=1}^k (\sum_{i=1}^n x_{il}y_i - n\bar{x}_l \bar{y})^2}} \\ w_1 &= \frac{(\sum_{i=1}^n x_{i1}y_i - n\bar{x}_1 \bar{y} + \dots + \sum_{i=1}^n x_{ik}y_i - n\bar{x}_k \bar{y})}{\sqrt{(\sum_{i=1}^n x_{i1}y_i - n\bar{x}_1 \bar{y})^2 + \dots + (\sum_{i=1}^n x_{ik}y_i - n\bar{x}_k \bar{y})^2}} \\ w_1 &= \frac{\tilde{x}_1^T \tilde{y} + \dots + \tilde{x}_k^T \tilde{y}}{\sqrt{(\tilde{x}_1^T \tilde{y})^2 + \dots + (\tilde{x}_k^T \tilde{y})^2}} \\ w_1 &= \frac{\mathbf{x}_1^T \mathbf{y}_1}{\|\mathbf{x}_1^T \mathbf{y}_1\|} \end{aligned} \quad (2.30)$$

Berdasarkan persamaan (2.30), maka komponen t_1 dapat dinyatakan sebagai berikut:

$$\begin{aligned} t_1 &= \mathbf{X}_1 \mathbf{w}_1 \\ t_1 &= \frac{\mathbf{x}_1 \mathbf{x}_1^T \mathbf{y}_1}{\|\mathbf{x}_1^T \mathbf{y}_1\|} \end{aligned} \quad (2.31)$$

2. Setelah mendapatkan komponen pertama t_1 , maka untuk dekomposisi \tilde{X} perlu dilakukan pembentukan vektor *loading* pertama p_1 dengan meregresikan antara peubah-peubah pada matriks X_1 yang berperan sebagai peubah respon dan vektor komponen t_1 sebagai peubah prediktor dalam bentuk sebagai berikut:

$$\mathbf{X}_1 = \mathbf{t}_1 \mathbf{p}_1^T + \mathbf{e}_1 \quad (2.32)$$

Di mana

X_1 = vektor berukuran $n \times k$ dari \tilde{X}

t_1 = vektor berukuran $n \times 1$ dari komponen utama

p_1 = vektor berukuran $k \times 1$ dari loading pertama yang berperan sebagai parameter regresi

e_1 = vektor error berukuran $n \times k$

Menurut Recher, 2002 menyatakan bahwa dengan menggunakan metode *Least Square*. Metode *Least Square* adalah metode yang meminimumkan jumlah kuadrat *residual* untuk mendapatkan pendugaan p_1 yang dapat dijabarkan dengan rumus sebagai berikut:

$$\begin{aligned} tr(\sum_{i=1}^k e_{il}^2) &= tr(e_1^T e_1) = tr(X_1 - t_1 p_1^T)^T (X_1 - t_1 p_1^T) \\ S(p_{11}, \dots, p_{k1}) &= tr(X_1 - t_1 p_1^T)^T (X_1 - t_1 p_1^T) \\ S(p_{11}, \dots, p_{k1}) &= tr(X_1^T X_1 - X_1^T t_1 p_1^T - p_1 t_1^T X_1 + p_1 t_1^T t_1 p_1^T) \end{aligned} \quad (2.33)$$

Di mana $(X_1^T t_1 p_1^T)^T = p_1 t_1^T X_1$ karena kedua matriks berukuran $k \times k$, maka fungsi *least square* dapat ditulis sebagai berikut:

$$S(p_{11}, \dots, p_{k1}) = tr(X_1^T X_1 - 2X_1^T t_1 p_1^T + p_1 t_1^T t_1 p_1^T) \quad (2.34)$$

Sehingga untuk pendugaan parameter p_1 , fungsi *least square* diturunkan terhadap p_1 :

$$\frac{\partial tr(X_1^T X_1 - 2X_1^T t_1 p_1^T + p_1 t_1^T t_1 p_1^T)}{\partial p_1} = -2X_1^T t_1 + 2p_1 t_1^T t_1 = 0$$

Sehingga vektor *loading* pertama p_1 didapatkan dengan:

$$-2X_1^T t_1 + 2p_1 t_1^T t_1 = 0$$

$$p_1 = \frac{x_1^T t_1}{t_1^T t_1}$$

$$p_1 = (t_1^T t_1)^{-1} X_1^T t_1 \quad (2.35)$$

3. Selanjutnya, untuk menentukan apakah perlu dibentuk komponen T dan loading P berikutnya maka dilakukan dengan meregresikan atau mencari hubungan antara tiap peubah prediktor pada matriks X_1 yang telah di dekomposisi menjadi vektor komponen utama t_1 yang dapat diketahui melalui matriks variansi kovariansi sampel X_1 . Sehingga dalam notasi matriks X_1 dapat dituliskan sebagai:

$$X_1 = \tilde{X} = t_1 p_1^T$$

$$\begin{bmatrix} x_{11} - \bar{x}_1 & \dots & x_{1k} - \bar{x}_k \\ \vdots & \ddots & \vdots \\ x_{n1} - \bar{x}_1 & \dots & x_{nk} - \bar{x}_k \end{bmatrix} = \begin{bmatrix} t_{11}p_{11} & \dots & t_{11}p_{11} \\ \vdots & \ddots & \vdots \\ t_{11}p_{11} & \dots & t_{11}p_{11} \end{bmatrix} = \begin{bmatrix} \tilde{\bar{X}}_{11} & \dots & \tilde{\bar{X}}_{1k} \\ \vdots & \ddots & \vdots \\ \tilde{\bar{X}}_{n1} & \dots & \tilde{\bar{X}}_{1k} \end{bmatrix} \quad (2.36)$$

Di mana matriks variansi kovariansi dapat dituliskan sebagai:

$$S = S_{lq} = \begin{bmatrix} s_{11} & \dots & s_{1k} \\ \vdots & \ddots & \vdots \\ s_{k1} & \dots & s_{kk} \end{bmatrix} \quad (2.37)$$

Maka, matriks variansi kovariansi sampel untuk setiap prediktor pada matriks X_1 adalah

$$s_{ll} = s_l^2 = \frac{\sum_{i=1}^n (x_{il} - \bar{x}_l)^2}{n-1} = \frac{\sum_{i=1}^n (\tilde{\bar{X}}_{il})^2}{n-1} \quad (2.38)$$

Dan kovariansi antara prediktor ke-l dan ke-q pada X_1 adalah

$$s_{lq} = \frac{\sum_{i=1}^n (x_{il} - \bar{x}_l)(x_{iq} - \bar{x}_q)}{n-1} = \frac{\sum_{i=1}^n (\tilde{\bar{X}}_{il})(\tilde{\bar{X}}_{iq})}{n-1}, l, q = 1, \dots, k, l \neq q \quad (2.39)$$

Maka matriks variansi kovariansi X_1 , dinotasikan sebagai S_1^* sebagai berikut:

$$S_1^* = \frac{\tilde{\bar{X}}_1^T \tilde{\bar{X}}_1}{n-1} = \frac{p_1 t_1^T t_1 p_1^T}{n-1} \quad (2.40)$$

Nilai S_1^* menjelaskan seberapa besar variasi atau informasi dari X_1 yang dijelaskan oleh vektor komponen t_1 atau dengan kata lain untuk mengukur variabilitas dari X_1 yang dijelaskan oleh vektor komponen t_1 . Untuk mengukur variabilitas dilakukan dengan membandingkan nilai S_1^* dengan S matriks variansi kovariansi sampel X yang disebut proporsi variasi total X_1 yang dijelaskan oleh komponen utama. Jika nilai proporsi variansi kecil, maka vektor komponen pertama t_1 tidak cukup dalam menjelaskan variasi X_1 sehingga dibutuhkan vektor komponen berikutnya. Akan tetapi jika nilainya besar misalkan 80% maka hanya dengan vektor pertama, t_1 sudah cukup menjelaskan variasi X_1 (Jorgensen, 2007). Kriteria lain dalam menentukan keputusan untuk pembentukan komponen selanjutnya yaitu dengan menentukan apakah vektor residual merupakan vektor nol. Hal tersebut dapat dijabarkan sebagai berikut:

$$X_1 = \tilde{X} = t_1 p_1^T + t_2 p_2^T + \cdots + t_m p_m^T + E \quad (2.41)$$

Di mana $\tilde{X}_1 = t_1 p_1^T$, maka

$$X_1 = \tilde{X} = \tilde{X}_1 + X_2 \quad (2.42)$$

Berdasarkan uraian tersebut, maka matriks X_2 merupakan matriks *residual* yang dapat dinyatakan sebagai berikut:

$$\begin{aligned} X_2 &= X_1 - \tilde{X}_1 \\ X_2 &= X_1 - t_1 p_1^T \end{aligned} \quad (2.43)$$

Matriks *residual* tersebut menjelaskan seberapa besar X_1 yang tidak dijelaskan di dalam vektor komponen t_1 . Jika X_2 bukan merupakan matriks nol, maka untuk menjelaskan \tilde{X} dibutuhkan komponen kedua. Bedasarkan y_1 pada pembentukan vektor komponen pertama t_1 , maka vektor residual untuk regresi logistik ordinal antara y_1 dengan komponen t_1 adalah:

$$\begin{aligned} y_2 &= y_1 - \hat{y}_1 \\ y_2 &= y_1 - \mathbf{n} \hat{\pi}_b \end{aligned} \quad (2.44)$$

Vektor y_2 merupakan vektor *residual* seberapa besar y_1 yang tidak dijelaskan di dalam vektor komponen t_1 . Jika y_2 bukan merupakan vektor nol, maka untuk menjelaskan \hat{y} dibutuhkan komponen kedua.

- Pembentukan vektor komponen kedua (t_2) kurang lebih sama dengan pembentukan vektor komponen pertama (t_1) yaitu merupakan komponen linier dengan setiap peubah prediktor, untuk vektor komponen kedua (t_2) dapat dituliskan sebagai berikut:

$$t_2 = X_2 w_2 \quad (2.45)$$

Di mana w_1 adalah bobot yang merupakan penjumlahan fungsi kovariansi antara setiap variabel prediktor ($\tilde{x}_1, \dots, \tilde{x}_1$) dalam matriks X_1 dan vektor respon y_1 yang dibagi dengan akar dari kuadrat fungsi kovariansi itu sendiri, dengan demikian w_1 dapat dituliskan sebagai:

$$w_2 = \frac{\sum_{l=1}^k cov(\tilde{x}_{l(2)}, \tilde{y}_{(2)})}{\sqrt{\sum_{l=1}^k cov(\tilde{x}_{l(2)}, \tilde{y}_{(2)})^2}}, l = 1, \dots, k \quad (2.46)$$

Berdasarkan penjabaran sebelumnya, di dapatkan

$$w_2 = \frac{x_2^T y_2}{\|x_2^T y_2\|} \quad (2.47)$$

Sehingga vektor komponen kedua (t_2) adalah

$$\begin{aligned} t_2 &= X_2 w_2 \\ t_2 &= \frac{X_2 x_2^T y_2}{\|X_2^T y_2\|} \end{aligned} \quad (2.48)$$

5. Setelah mendapatkan komponen kedua t_2 , maka untuk dekomposisi \tilde{X} perlu dilakukan pembentukan vektor *loading* kedua p_2 dengan meregresikan antara peubah-peubah pada matriks X_2 yang berperan sebagai peubah respon dan vektor komponen t_2 :

$$X_2 = t_2 p_2^T + e_2 \quad (2.49)$$

Sehingga untuk pendugaan parameter p_2 , fungsi *least square* diturunkan terhadap p_2 dan didapatkan sebagai berikut:

$$p_2 = (t_2^T t_2)^{-1} X_2^T t_2 \quad (2.50)$$

Sesuai langkah dalam memutuskan untuk melanjutkan komponen, jika matriks *residual* X_3 merupakan matriks bukan nol maka untuk menjelaskan \tilde{X} dibutuhkan komponen selanjutnya.

6. Berdasarkan penjabaran sebelumnya maka w_j didapatkan dengan rumus sebagai berikut:

$$w_j = \frac{x_j^T y_j}{\|x_j^T y_j\|} \quad (2.51)$$

7. Pembentukan vektor komponen selanjutnya (t_j) dapat dilakukan dengan cara yang sama sebagai berikut:

$$\begin{aligned} t_j &= X_j w_j \\ t_j &= \frac{x_j x_j^T y_j}{\|x_j^T y_j\|} \end{aligned} \quad (2.52)$$

8. Setelah mendapatkan komponen kedua t_j , maka untuk dekomposisi \tilde{X} perlu dilakukan pembentukan vektor *loading* kedua p_j dengan meregresikan antara peubah-peubah pada matriks X_2 yang berperan sebagai peubah respon dan vektor komponen t_j sebagai peubah prediktor:

$$X_j = t_j p_j^T + e_j \quad (2.53)$$

Sehingga untuk pendugaan parameter p_2 , fungsi *least square* diturunkan terhadap p_2 dan didapatkan sebagai berikut:

$$p_j = (t_j^T t_j)^{-1} X_j^T t_j \quad (2.54)$$

Sesuai langkah dalam memutuskan untuk melanjutkan komponen, jika trace S_j^* lebih besar dari trace S_{j-1}^* dan matriks *residual* X_j merupakan matriks nol maka pembentukan komponen berhenti. Di mana

$$S_j^* = \frac{p_1 t_1^T t_1 p_1}{n-1} \quad (2.55)$$

dan matriks residual X_j

$$X_j = X_{j-1} - t_{j-1} p_{j-1}^T \quad (2.56)$$

Berdasarkan matriks variansi kovariansi, maka untuk mengetahui variansi \tilde{X} yang dapat dijelaskan oleh komponen $j=\{1, \dots, m\}$ dapat dinyatakan sebagai:

$$\frac{t_j^T t_j p_j^T p_j}{n-1} \quad (2.57)$$

Dan kumulatif proporsi variansi \tilde{X} yang dijelaskan oleh komponen j dapat dihitung dengan

$$\frac{\sum_{j=1}^m t_j^T t_j p_j^T p_j}{tr(\tilde{X}^T \tilde{X})} \quad (2.58)$$

9. Selanjutnya, jika telah terbentuk komponen t_j maka dilakukan regresi logistik ordinal antara y sebagai peubah respon dan t_j sebagai peubah prediktor dalam bentuk sebagai berikut:

$$\begin{aligned} \text{logit } [P(Y \leq j|1)] &= \theta_1 + \sum_{j=1}^h c_h \left(\sum_{j=1}^p w_{jh} x_j \right) \\ \text{logit } [P(Y \leq j|2)] &= \theta_2 + \sum_{j=1}^h c_j \left(\sum_{j=1}^p w_{jh} x_j \right) \\ &\vdots \\ \text{logit } [P(Y \leq j|j-1)] &= \theta_{j-1} + \sum_{j=1}^h c_j \left(\sum_{j=1}^p w_{jh} x_j \right) \end{aligned} \quad (2.59)$$

Berdasarkan persamaan (2.57), maka dilakukan transformasi model dalam bentuk peubah prediktor asal. Hasil transformasi dapat dituliskan sebagai berikut:

$$\begin{aligned} \text{logit } [P(Y \leq j|1)] &= \theta_1 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_j x_j \\ \text{logit } [P(Y \leq j|2)] &= \theta_2 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_j x_j \\ &\vdots \\ \text{logit } [P(Y \leq j|j-1)] &= \theta_{j-1} + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_j x_j \end{aligned} \quad (2.60)$$

Di mana β_m adalah koefisien PLSR untuk x_m yang diperoleh dari:

$$\begin{aligned} \beta_1 &= c_1 w_{11} + c_1 w_{12} + \cdots + c_m w_{1m} \\ \beta_1 &= c_1 w_{21} + c_1 w_{22} + \cdots + c_m w_{2m} \\ &\vdots \\ \beta_j &= c_1 w_{p1} + c_1 w_{p2} + \cdots + c_m w_{pm} \end{aligned} \quad (2.61)$$

2.5 Keortogonalan Matriks Komponen Menggunakan NIPALS

Pada algoritma NIPALS, untuk mendapatkan komponen diperlukan matriks *residual* sehingga komponen tersebut dapat ortogonal yaitu $t_i^T t_j = 0$. Dengan demikian dapat dibuktikan sebagai berikut:

$$t_i^T t_j = t_i^T X_j w_j \quad (2.62)$$

Di mana dengan matiks residual dapat dinyatakan:

$$X_j = \left(I - \frac{t_{j-1} t_{j-1}^T}{c} \right) \cdots \left(I - \frac{t_l t_l^T}{c} \right) \cdots \left(I - \frac{t_1 t_1^T}{c} \right) X_1$$

Maka

$$\begin{aligned} t_i^T t_j &= t_i^T X_j w_j \\ t_i^T t_j &= t_i^T \left(I - \frac{t_{j-1} t_{j-1}^T}{c} \right) \dots \left(I - \frac{t_i t_i^T}{c} \right) \dots \left(I - \frac{t_1 t_1^T}{c} \right) X_1 w_j \\ t_i^T t_j &= \left(I - \frac{t_{j-1} t_{j-1}^T}{c} \right) \dots \left(t_i^T - \frac{t_i t_i^T}{c} \right) \dots \left(I - \frac{t_1 t_1^T}{c} \right) X_1 w_j \\ t_i^T t_j &= 0 \end{aligned} \quad (2.63)$$

Jika komponen t_j ortogonal, maka dapat dibuktikan juga w_j ortogonal $w_i^T w_j = 0$ sebagai berikut:

$$\begin{aligned} w_i^T w_j &= w_i^T X_j^T y_j \\ w_i^T w_j &= w_i^T X_j^T \left(I - \frac{t_{j-1} t_{j-1}^T}{c} \right) \dots \left(I - \frac{t_i t_i^T}{c} \right) y_j \\ w_i^T w_j &= t_i^T \left(I - \frac{t_{j-1} t_{j-1}^T}{c} \right) \dots \left(I - \frac{t_i t_i^T}{c} \right) y_j \\ w_i^T w_j &= \left(I - \frac{t_{j-1} t_{j-1}^T}{c} \right) \dots \left(t_i^T - \frac{t_i t_i^T}{c} \right) y_j \\ w_i^T w_j &= 0 \end{aligned} \quad (2.64)$$

Berdasarkan pembuktian tersebut, dapat disimpulkan bahwa pembentukan komponen T dan matriks bobot W yang diperoleh dengan algoritma NIPALS adalah ortogonal.

2.6 Tinjauan Non Statistik

Negara Indonesia dilewati oleh garis katulistiwa serta dikelilingi oleh dua samudra dan dua benua. Posisi ini menjadikan Indonesia sebagai daerah pertemuan sirkulasi meridional (Utara-Selatan) dikenal sebagai Sirkulasi Hadley dan sirkulasi zonal (Timur-Barat) dikenal sebagai Sirkulasi Walker yang sangat mempengaruhi keragaman iklim di Indonesia. Sirkulasi angin di Indonesia ditentukan oleh pola perbedaan tekanan udara di Australia dan Asia. Pola angin barat terjadi karena adanya tekanan tinggi di Asia yang berkaitan dengan berlangsungnya musim hujan di Indonesia. Pola angin timur atau tenggara terjadi karena adanya tekanan tinggi di Australia yang berkaitan dengan berlangsungnya musim kemarau di Indonesia (BMKG, 2013).

Menurut penelitian (BMKG, 2013), pengaruh iklim terhadap pertanian di Indonesia sangat kuat khususnya curah hujan. Penurunan curah hujan yang cukup besar pada musim kemarau dapat membawa dampak terhadap produksi tanaman pangan. Salah satu iklim yang

sangat berpengaruh adalah sifat hujan. Sifat hujan adalah Perbandingan antara jumlah curah hujan yang terjadi selama satu bulan dengan nilai rata-rata atau normal dari bulan tersebut di suatu tempat. Sifat hujan dibagi menjadi 3 (tiga) kriteria, yaitu:

1. Di atas normal (A), jika nilai perbandingan antara jumlah curah hujan yang terjadi selama satu bulan dengan nilai rata-rata bulan tersebut lebih besar dari 115 %.
2. Normal (N), jika nilai perbandingan antara jumlah curah hujan yang terjadi selama satu bulan dengan nilai rata-rata bulan tersebut antara 85 % - 115 %.
3. Di bawah normal (B), jika nilai antara jumlah curah hujan yang terjadi selama satu bulan dengan nilai rata-rata bulan tersebut kurang dari 85%.

Salah satu faktor yang berpengaruh terhadap kondisi curah hujan adalah SST (*Sea Surface Temperature*) dalam satuan derajat.. Laut merupakan sumber uap air utama untuk segala proses yang terjadi di atmosfer. Semakin hangat SST maka akan makin banyak juga uap air yang didistribusikan ke atmosfer sehingga akan semakin besar juga kemungkinan terjadinya hujan. Terdapat korelasi yang kuat antara curah hujan dengan SST (SST local dan pasifik) untuk wilayah Indonesia. Meningkatnya SST akan mempengaruhi besarnya penguapan disuatu wilayah, ditambah dengan perubahan tekanan yang mengakibatkan adanya pergerakan angin sehingga curah hujan yang terjadi akan meningkat dari biasanya. Di mana curah hujan di wilayah indonesia disebabkan oleh pengaruh SST di Samudra hindia yang berada pada SST grid 28, SST grid 29, SST grid 30, SST grid 31 dan di samudra pasifik pada SST Nino 3.4. Dimana luas dari 1 grid sekitar 110 km x 110 km (Tresnawati, 2010).

Faktor lain yang mempengaruhi curah hujan adalah terjadinya El Nino dan La Nina. Di mana *Southern Oscillation Index* (SOI) digunakan untuk mengetahui terjadinya El Nino dan La Nina. SOI atau yang dapat disebut Indeks Osilasi Selatan adalah anomali perbedaan tekanan udara permukaan antara Tahiti di kepulauan Polinesia-Prancis dengan tekanan udara permukaan di Darwin-Australia. Adapun persamaan untuk menghitung nilai SOI adalah sebagai berikut:

$$SOI = 10 \frac{[P_{diff} - P_{diff\ avg}]}{SD(P_{diff})} \quad (2.65)$$

Dengan

Pdiff	: selisih antara rata-rata MSLP Tahiti per bulan dengan rata-rata MSLP Darwin per bulan.
Pdiffav	: suhu rata-rata Pdif pada bulan yang dicari.
SD (Pdiff)	: standart deviasi Pdiff pada bulan yang dicari.

Jika SOI bernilai negatif, telah terjadi fase El Nino. Namun, jika SOI bernilai positif, telah terjadi fase La Nina. Pada saat fenomena El-Nino berlangsung, hujan pada sebagian besar wilayah Indonesia umumnya di bawah normal. (BOM, 2002).

Curah hujan merupakan salah satu unsur iklim yang sangat penting, namun keberadaannya secara spasial dan temporal masih sulit diprediksi. Selain sifatnya yang dinamis, proses fisis yang terlibat juga sangat kompleks. Ketidakpastian hujan ini semakin besar ketika terjadi anomali (perubahan suhu muka laut)iklim berupa El Nino dan La Nina. El-Nino merupakan pemanasan yang tidak biasa di wilayah Samudera Pasifik ekuator yang terjadi secara tidak teratur dengan interval sekitar 3-6 tahun sebagai tanggapan terhadap pelemahan angin skala besar (angin pasat) yang biasanya bertiup dari selatan Benua Amerika ke Asia. Pada umumnya, angin yang bertiup itu menghasilkan permukaan air dingin di Pasifik timur, melalui penguapan air yang lebih dingin di bawah permukaan. Akibatnya, air menjadi relatif hangat di seluruh Pasifik, Papua New Guinea, Amerika Selatan. Sedangkan La- Nina merupakan kebalikan dari El-Nino ditandai dengan anomali suhu muka laut negatif (lebih dingin dari rata-ratanya) di Ekuator Pasifik Tengah yaitu Nino 3.4 (BMKG, 2013).



UNIVERSITAS BRAWIJAYA



BAB III

METODOLOGI

3.1 Sumber Data

Data dalam penelitian ini adalah data sekunder yang diambil dari data BMKG (Badan Meteorologi Klimatologi dan Geofisika). Data tersebut merupakan pengamatan yang dilakukan oleh BMKG. Pada data tersebut, diketahui faktor yang mempengaruhi sifat curah hujan di Kota Pacitan pada tahun 2001-2010 yang diamati setiap bulan. Sifat curah hujan dibagi menjadi 3 yaitu di atas normal, normal, dan di bawah normal. Sifat curah hujan dibagi berdasarkan perbandingan antara jumlah curah hujan yang terjadi selama satu bulan dengan nilai rata-rata dari bulan tersebut dalam satuan persen. Sifat curah hujan sangat mempengaruhi hasil produksi tanaman pangan di Kota Pacitan.

Beberapa faktor yang mempengaruhi sifat curah hujan antara lain SST(*Sea Surface Temperature*) atau suhu permukaan laut pada kawasan Samudra Hindia pada GRID 28, GRID 29, GRID 30, GRID 31, dan pada kawasan Samudra Pasifik pada NINO 3.4 sedangkan faktor lainnya yaitu Anomali suhu permukaan laut pada kawasan NINO 3.4, dan SOI (*Southern Oscillation Index*). Data SST tersebut diunduh dari <http://iridl.ldeo.columbia.edu/SOURCES/.NOAA/.NCDC/.OISST/.version2/.AVHRR/.sst/T/3165./VALUE/lon/80./160./RANGEEDGES/lat/-20/20/ RANGEEDGES/ngridtable+table+skipanyNaN+3+table+.html>. Dalam pemodelan dengan metode PLSR menggunakan NIPALS ingin diketahui berapa peluang tingkat curah hujan di atas normal, curah hujan normal, dan curah hujan di bawah normal. Rincian dari peubah-peubah tersebut adalah sebagai berikut.

Tabel 3.1 Peubah-peubah yang Digunakan pada Penelitian

Peubah	Kriteria	Keterangan
Respon (sifat curah hujan)	$Y = 1$ (diatas Normal)	nilai perbandingan curah hujan (mm) dengan rata-rata curah hujan pada bulan tersebut (mm) lebih besar dari 115 %.

Tabel 3.1 Lanjutan

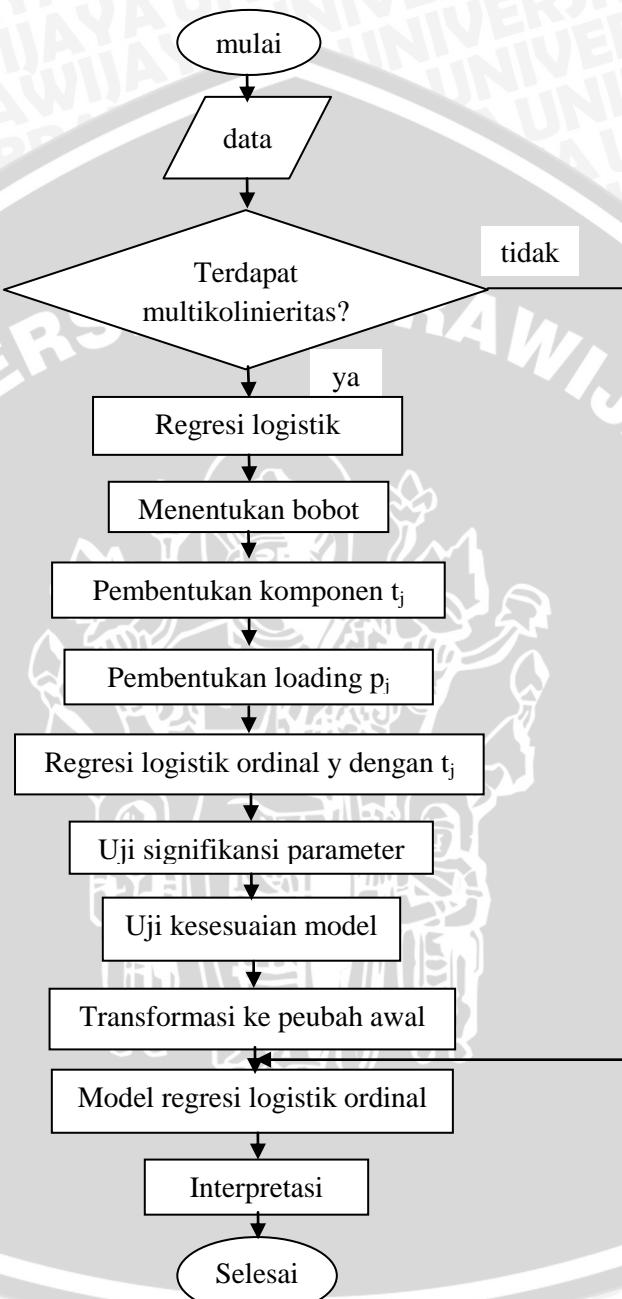
Peubah	Kriteria	Keterangan
	$Y = 2$ (normal)	nilai perbandingan curah hujan (mm) dengan rata-tara curah hujan pada bulan tersebut (mm) antara 85 % - 115 %.
	$Y = 3$ (di bawah normal)	nilai perbandingan curah hujan (mm) dengan rata-tara curah hujan pada bulan tersebut (mm) di bawah 85 %
Prediktor	$X_1 = \text{SST GRID } 28$	Suhu permukaan laut ($^{\circ}\text{C}$) di Samudra Hindia pada grid 28
	$X_2 = \text{SST GRID } 29$	Suhu permukaan laut ($^{\circ}\text{C}$) di Samudra Hindia pada grid 29
	$X_3 = \text{SST GRID } 30$	Suhu permukaan laut ($^{\circ}\text{C}$) di Samudra Hindia pada grid 30
	$X_4 = \text{SST GRID } 31$	Suhu permukaan laut ($^{\circ}\text{C}$) di Samudra Hindia pada grid 31
	$X_5 = \text{NINO } 3.4$	Suhu permukaan laut ($^{\circ}\text{C}$) di Samudra Pasifik pada wilayah NINO 3.4
	$X_6 = \text{ANO NINO } 3.4$	Perubahan suhu muka laut ($^{\circ}\text{C}$) pada Samudra Pasifik pada wilayah NINO 3.4
	$X_7 = \text{SOI}$	Indeks Osilasi Selatan yang dihitung berdasarkan persamaan (2.60)

3.2 Metode Analisis

Dalam penelitian ini, metode yang digunakan dalam analisis data adalah *Partial Least Square* (PLS) dengan pembentukan komponen menggunakan NIPALS (*Nonlinier iterative Partial Least Squares*). Analisis data dilakukan dengan langkah sebagai berikut:

1. Mendeteksi adanya multikolinieritas sesuai dengan persamaan (2.22). Jika terdapat multikolinieritas maka dapat dilakukan langkah selanjutnya, tetapi jika tidak terdapat multikolinieritas maka dilanjutkan langkah ke 12.
2. Membentuk model regresi logistik ordinal antara peubah respon Y dengan peubah prediktor X sesuai dengan persamaan (2.6)
3. Membentuk komponen PLS dengan NIPALS dimulai dengan inisialisasi $j=1$ di mana $j=1,\dots,m$.
4. Menentukan bobot w_j sesuai dengan persamaan (2.51)
5. Berdasarkan bobot yang sudah ditentukan, maka dilakukan pembentukan komponen t_j sesuai dengan persamaan (2.52)
6. Pembentukan loading p_j sesuai dengan persamaan (2.54)
7. Pembentuk matriks variansi kovariansi X_j dengan notasi S_j^* sesuai dengan persamaan (2.55)
8. Membentuk model regresi logistik ordinal antara peubah respon Y dengan komponen t_j sesuai dengan persamaan (2.57)
9. Menghitung koefisien regresi logistik komponen PLSR t_j terhadap peubah respon y sesuai dengan persamaan (2.59)
10. Pengujian signifikansi model regresi logistik ordinal secara parsial menggunakan uji *Wald* sesuai dengan persamaan (2.15)
11. Pengujian kesesuaian model regresi logistik menggunakan uji *pearson* sesuai dengan persamaan (2.16)

Diagram alir penelitian ini disajikan pada Gambar 3.1.



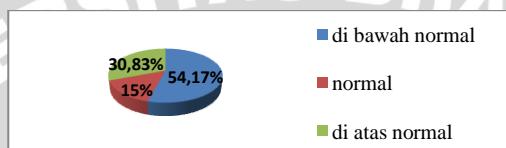
Gambar 3.1. Diagram Alir PLSR dengan Pembentukan Komponen NIPALS

BAB IV

HASIL DAN PEMBAHASAN

4.1 Deskriptif

Analisis deskriptif dilakukan untuk meringkas data hasil penelitian. Data yang digunakan dalam penelitian ini adalah data pengamatan BMKG tentang sifat hujan yang terjadi di Kota Pacitan Tahun 2001-2010. Presentase sifat hujan yang terjadi di Kota Pacitan dapat dilihat pada Gambar 4.1.



Gambar 4.1 *Presentase Sifat Hujan di Kota Pacitan Tahun 2001-2010*

Gambar 4.1 menunjukkan bahwa 54,17% hujan di Kota Pacitan Tahun 2001-2010 bersifat di atas normal, 15% bersifat normal, dan 30,83% bersifat di bawah normal. Dalam kasus ini, sifat hujan dipengaruhi oleh beberapa faktor suhu permukaan laut pada grid 28, grid 29, grid 30, grid 31, dan pada nino 3.4. sedangkan faktor lainnya yaitu anomali suhu permukaan laut pada nino 3.4 dan SOI. Rata-rata masing faktor yang mempengaruhi sifat hujan dapat dilihat pada Tabel 4.1.

Tabel 4.1 Nilai Rata-rata Setiap Faktor yang Mempengaruhi Sifat Hujan

Peubah Prediktor	Sifat Hujan		
	Di bawah normal	Normal	Di atas normal
SST GRID 28	27.15	27.81	28.03
SST GRID 29	28.14	29.07	28.99
SST GRID 30	27.67	29.06	28.78
SST GRID 31	26.76	27.81	27.88
SST NINO 3.4	27.17	26.95	26.89
ANO NINO 3.4	0.20	-0.03	-0.29
SOI	-2.15	-2.07	5.49

Tabel 4.1 menunjukkan bahwa nilai rata-rata suhu permukaan laut pada grid 28 jika sifat hujan di atas normal adalah 27.15°C , jika sifat hujan normal adalah 27.81°C , sedangkan jika sifat hujan di bawah normal adalah 28.03°C . Nilai rata-rata suhu permukaan laut pada grid 29 jika sifat hujan di atas normal adalah 28.14°C , jika sifat hujan normal adalah 29.07°C , sedangkan jika sifat hujan di bawah normal adalah 28.99°C . Nilai rata-rata suhu permukaan laut pada grid 30 jika sifat hujan di atas normal adalah 27.67°C , jika sifat hujan normal adalah 29.06°C , sedangkan jika sifat hujan di bawah normal adalah 28.78°C . Nilai rata-rata suhu permukaan laut pada grid 31 jika sifat hujan di atas normal adalah 26.76°C , jika sifat hujan normal adalah 27.81°C , sedangkan jika sifat hujan di bawah normal adalah 27.88°C . Nilai rata-rata suhu permukaan laut pada nino 3.4 jika sifat hujan di atas normal adalah 27.17°C , jika sifat hujan normal adalah 26.95°C , sedangkan jika sifat hujan di bawah normal adalah 26.89°C . Nilai rata-rata anomali suhu permukaan laut pada nino 3.4 jika sifat hujan di atas normal adalah 0.20°C , jika sifat hujan normal adalah -0.03°C , sedangkan jika sifat hujan di bawah normal adalah -0.29°C . Nilai rata-rata SOI jika sifat hujan di atas normal adalah -2.15 , jika sifat hujan normal adalah -2.07 , sedangkan jika sifat hujan di bawah normal adalah 5.49 . Sedangkan rentang nilai untuk setiap faktor yang mempengaruhi sifat hujan dapat dilihat pada Tabel 4.2.

Tabel 4.2 Selang Nilai Setiap Faktor yang Mempengaruhi Sifat Hujan

Peubah Prediktor	Sifat Hujan		
	Di bawah normal	Normal	Di bawah normal
SST GRID 28	25.08 - 29.61	26.27 - 29.46	26.18 - 29.79
SST GRID 29	25.49 - 30.82	26.63 - 30.38	26.97 - 30.69
SST GRID 30	24.31 - 31.08	25.65- 30.26	25.81 - 31.16
SST GRID 31	24.45 - 28.43	25.44 - 28.07	25.55- 28.36
SST NINO 3.4	24.95 - 29.91	24.71 - 29.46	28.83 - 29.58
ANO NINO 3.4	24.95 - 1.72	24.71 - 0.94	24.83 - 1.08
SOI	-29.1 - 27.1	-14.7 - 14.1	-14.5 - 25

Tabel 4.2 menunjukkan bahwa selang nilai suhu permukaan laut pada grid 28 jika sifat hujan di atas normal adalah 25.08°C sampai 29.61°C , jika sifat hujan normal adalah 26.27°C sampai 29.46°C , sedangkan jika sifat hujan di bawah normal adalah 26.18°C sampai 29.79°C . Untuk selang nilai suhu permukaan laut pada grid 29 jika sifat hujan di atas normal adalah 25.49°C sampai 30.82°C , jika sifat hujan normal adalah 26.63°C sampai 30.38°C , sedangkan jika sifat hujan di bawah normal adalah 26.97°C sampai 30.69°C . Untuk selang nilai suhu permukaan laut pada grid 30 jika sifat hujan di atas normal adalah 24.31°C sampai 31.08°C , jika sifat hujan normal adalah 25.65°C sampai 30.26°C , sedangkan jika sifat hujan di bawah normal adalah 25.81°C sampai 31.16°C . Untuk selang nilai suhu permukaan laut pada grid 31 jika sifat hujan di atas normal adalah 24.45°C sampai 28.43°C , jika sifat hujan normal adalah 25.44°C sampai 28.07°C , sedangkan jika sifat hujan di bawah normal adalah 25.55°C sampai 28.36°C derajat celcius. Selang nilai suhu permukaan laut pada nino 3.4 jika sifat hujan di atas normal adalah 24.95°C sampai 29.91°C , jika sifat hujan normal adalah 24.71°C sampai 29.46°C , sedangkan jika sifat hujan di bawah normal adalah 24.83°C sampai 29.58°C . Untuk selang nilai anomali suhu permukaan laut pada nino 3.4 jika sifat hujan di atas normal adalah -1.62°C sampai 1.72°C , jika sifat hujan normal adalah -1.86°C sampai 0.94°C , sedangkan jika sifat hujan di bawah normal adalah -1.89°C sampai 1.08°C . Untuk selang nilai SOI jika sifat hujan di atas normal adalah -29.1 sampai 27.1 , jika sifat hujan normal adalah -14.7 sampai 14.1 , sedangkan jika sifat hujan di bawah normal adalah -14.5 sampai 25 .

4.2 Pendekripsi Multikolinieritas

Regresi logistik ordinal adalah regresi dengan peubah respon adalah kategori yang terdapat tingkatan. Dalam regresi logistik ordinal terdapat asumsi yang harus dipenuhi yaitu tidak terdapat multikolinieritas atau hubungan linier antar peubah prediktor. Berdasarkan pendugaan awal dapat dilakukan uji asumsi multikolinieritas. Pendugaan awal regresi logistik ordinal dapat dilihat pada Tabel 4.3.

Tabel 4.3 Pendugaan Awal Parameter Regresi Logistik Ordinal

Peubah	B	Wald	Nilai P
[SIFAT_HUJAN = 1]	80.178	17.540	0.000
[SIFAT_HUJAN = 2]	81.034	17.857	0.000
SST_28	-1.328	4.647	0.031
SST_29	0.895	1.124	0.289
SST_30	-0.289	0.167	0.683
SST_31	1.118	4.424	0.035
SST_NINO3.4	2.538	12.418	0.000
ANO_NINO3.4	-2.700	12.404	0.000
SOI	0.068	5.258	0.022

Berdasarkan pendugaan awal dapat diketahui terdapat peubah prediktor yang tidak berpengaruh signifikan. Hal tersebut dapat disebabkan oleh tidak terpenuhinya asumsi non-multikolinieritas. Uji asumsi non-multikolinieritas terhadap peubah-peubah prediktor dapat diketahui hubungan antar peubah prediktor dengan nilai VIF (*variation Inflation Factor*). Nilai VIF dapat dilihat pada Tabel 4.5.

Tabel 4.4 Nilai VIF Masing-masing Peubah Prediktor

Peubah Prediktor	VIF
SST GRID 28	16.33
SST GRID 29	35.51
SST GRID 30	46.33
SST GRID 31	20.08
SST NINO 3.4	9.14
ANO NINO 3.4	8.32
SOI	1.98

Berdasarkan Tabel 4.4 menunjukkan bahwa terdapat empat peubah prediktor yang memiliki nilai VIF lebih dari 10 yaitu pada peubah SST GRID 28, SST GRID 29, SST GRID 30, dan SST GRID 31. Nilai VIF lebih dari 10 menunjukkan bahwa terdapat multikolinieritas atau terdapat hubungan linier antar peubah prediktor tersebut.

4.3 Pendugaan Partial Least Square Regression (PLSR) dengan Pembentukan Komponen Nonlinier Iterative Partial Least Square (NIPALS)

Partial Least Square Regression (PLSR) merupakan pendekatan yang dapat digunakan jika terdapat multikolinieritas. Dalam penerapan metode PLSR dilakukan pembentukan komponen di mana salah satu pembentukan yang dapat dilakukan dengan NIPALS. Dalam pembentukan komponen NIPALS diasumsikan matriks X dan vektor y terpusat. Dalam kasus ini, pemusatan data dilakukan dengan dua cara yaitu untuk peubah respon dilakukan pemusatan dengan nilai modus karena untuk peubah respon pada regresi logistik ordinal berupa kategori. Sedangkan untuk pemusatan pada peubah prediktor dilakukan dengan rata-rata, sehingga dalam pembentukan komponen dilakukan dengan data yang sudah terpusat yaitu matriks \tilde{X} dan vektor \tilde{y} . Langkah berikutnya dalam pembentukan komponen NIPLS yaitu dengan menentukan matriks komponen T dan *loading* P , di mana matriks T dan *loading* P ditentukan berdasarkan pembobotan dengan matriks W . Matriks W adalah bobot dari masing-masing peubah prediktor yang terbentuk sesuai banyaknya komponen. Penentuan banyaknya komponen dilakukan sedemikian hingga matriks X_j menjadi matriks nol, sehingga secara otomatis *software* memilih banyaknya komponen yang terbentuk. Dalam kasus ini, komponen yang terbentuk sebanyak tujuh komponen matriks $T=\{t_1, t_2, \dots, t_7\}$ dan tujuh loading $P=\{p_1, p_2, \dots, p_7\}$. Komponen T terbentuk berdasarkan bobot W , di mana W adalah bobot yang merupakan penjumlahan fungsi kovariansi antara semua peubah prediktor dalam matriks \tilde{X} dan vektor respon \tilde{y} yang dibagi dengan akar dari kuadrat fungsi kovariansi itu sendiri. Berikut ini hasil bobot yang terbentuk:

Tabel 4.5 Bobot W untuk Masing-masing Peubah Prediktor

peubah prediktor	w_1	w_2	w_3	w_4	w_5	w_6	w_7
SST GRID 28	0.12	0.44	0.37	-0.53	-0.57	-0.09	-0.21
SST GRID 29	0.12	0.43	-0.11	-0.06	0.19	0.87	0.04
SST GRID 30	0.15	0.53	-0.40	0.21	0.26	-0.35	-0.55
SST GRID 31	0.15	0.50	0.02	0.21	-0.01	-0.29	0.77

SST NINO 3.4	-0.04	0.10	0.70	-0.12	0.68	-0.11	-0.08
ANO NINO 3.4	-0.06	-0.05	-0.45	-0.78	0.33	-0.16	0.22
SOI	0.96	-0.27	0.03	-0.05	0.06	-0.01	0.00

Tabel 4.5 menunjukkan terdapat tujuh bobot yang terbentuk. Bobot W bersifat ortonormal yang ditunjukkan oleh matriks $W^T W = I$. Hal ini dapat dibuktikan dari hasil perkalian matriks berikut:

$$\begin{array}{ll} w_1^T w_1 = 1.000049 \approx 1 & w_1^T w_2 = -0.000034 \approx 0 \\ w_2^T w_2 = 0.999901 \approx 1 & w_1^T w_3 = -0.000036 \approx 0 \\ \vdots & \vdots \\ w_7^T w_7 = 0.999958 \approx 1 & w_6^T w_7 = 0.000073 \approx 0 \end{array}$$

Berdasarkan bobot yang terbentuk, persamaan komponen T dapat dinyatakan sebagai berikut:

$$\begin{aligned} t_1 &= 0.12\tilde{X}_1 + 0.12\tilde{X}_2 + 0.15\tilde{X}_3 + 0.15\tilde{X}_4 - 0.04\tilde{X}_5 - 0.06\tilde{X}_6 + 0.96\tilde{X}_7 \\ t_2 &= 0.44\tilde{X}_1 + 0.43\tilde{X}_2 + 0.53\tilde{X}_3 + 0.5\tilde{X}_4 + 0.1\tilde{X}_5 - 0.05\tilde{X}_6 - 0.27\tilde{X}_7 \\ t_3 &= 0.37\tilde{X}_1 - 0.11\tilde{X}_2 - 0.4\tilde{X}_3 + 0.02\tilde{X}_4 + 0.7\tilde{X}_5 - 0.45\tilde{X}_6 + 0.03\tilde{X}_7 \\ t_4 &= 0.12\tilde{X}_1 + 0.12\tilde{X}_2 + 0.15\tilde{X}_3 + 0.15\tilde{X}_4 - 0.04\tilde{X}_5 - 0.06\tilde{X}_6 + 0.96\tilde{X}_7 \\ t_5 &= -0.53\tilde{X}_1 + 0.19\tilde{X}_2 + 0.26\tilde{X}_3 - 0.01\tilde{X}_4 + 0.68\tilde{X}_5 + 0.33\tilde{X}_6 + 0.06\tilde{X}_7 \\ t_6 &= -0.09\tilde{X}_1 + 0.87\tilde{X}_2 - 0.35\tilde{X}_3 - 0.29\tilde{X}_4 - 0.11\tilde{X}_5 - 0.16\tilde{X}_6 + 0.01\tilde{X}_7 \\ t_7 &= -0.21\tilde{X}_1 + 0.04\tilde{X}_2 - 0.55\tilde{X}_3 + 0.77\tilde{X}_4 - 0.08\tilde{X}_5 + 0.22\tilde{X}_6 \end{aligned}$$

berdasarkan persamaan tersebut, maka nilai komponen t_j dapat dilihat pada Tabel 4.6.

Tabel 4.6 Nilai Komponen T yang Terbentuk Berdasarkan Bobot W

observation	t_1	t_2	t_3	t_4	t_5	t_6	t_7
1	9.15	2.00	-0.17	0.15	-0.68	0.03	0.30
2	11.87	1.34	-0.15	0.08	-0.06	-0.24	0.18
3	6.86	1.81	0.33	0.32	0.32	-0.41	0.20
.
.
.
119	16.39	1.43	-0.29	0.28	-0.73	0.27	-0.11
120	27.18	2.61	-0.14	0.08	-0.38	0.11	0.28

Berdasarkan nilai komponen T yang telah diperoleh menunjukkan bahwa matriks tersebut bersifat ortogonal. Hal tersebut dapat dibuktikan dari hasil perkalian matriks berikut:

$$t_1^T t_2 = -0.00335041 \approx 0$$

$$t_1^T t_3 = 0.00227711 \approx 0$$

⋮

$$t_6^T t_7 = 8.49E-06 \approx 0$$

Langkah berikutnya yaitu pembentukan vektor loading P. Pembentukan vektor loading P perlu dilakukan untuk dekomposisi \tilde{X} , di mana pembentukannya dilakukan dengan meregresikan antara peubah x_i dengan komponen t_j . Berikut ini hasil loading p_j yang terbentuk:

Tabel 4.7 Nilai Loading P

peubah prediktor	p_1	p_2	p_3	p_4	p_5	p_6	p_7
SST GRID 28	0.02	0.39	0.73	0.14	-0.55	0.090	-0.21
SST GRID 29	0.03	0.44	-0.07	-0.28	0.02	0.83	0.04
SST GRID 30	0.04	0.59	-0.54	-0.10	0.32	0.12	-0.55
SST GRID 31	0.04	0.50	-0.13	0.23	0.04	-0.94	0.77
SST NINO 3.4	-0.06	0.01	0.78	-0.91	0.70	-0.04	-0.08
ANO NINO 3.4	-0.05	0.012	0.08	-1.17	0.36	-0.34	0.22
SOI	1.02	-0.27	0.06	-0.12	0.06	-0.01	-0.001

Langkah berikutnya adalah meregresikan \tilde{y} dengan komponen T dan didapatkan pendugaan parameter regresi c yaitu \hat{c} yang dapat dilihat pada tabel 4.9.

Tabel 4.8 Regresi Logistik Ordinal \tilde{y} dengan Komponen T

peubah	\hat{c}	Nilai P
[$y = 0$]	0.212	0.329
[$y = 1$]	1.068	0.000
t_1	0.89	0.000
t_2	0.234	0.002
t_3	0.753	0.026
t_4	0.698	0.106
t_5	1.511	0.008
t_6	0.353	0.545
t_7	0.549	0.494

Berdasarkan pendugaan awal dapat diketahui terdapat peubah prediktor yang tidak berpengaruh signifikan. Hal tersebut dapat disebabkan oleh tidak terpenuhinya asumsi non-multikolinieritas.

Berdasarkan hasil regresi \tilde{y} dengan komponen T dilakukan uji signifikansi parameter dengan menggunakan uji *wald* yaitu membandingkan nilai dengan $\alpha=0.05$, jika nilai $P < \alpha$ maka dapat dikatakan komponen tersebut berpengaruh secara signifikan. Hasil uji signifikansi menyatakan bahwa komponen yang berpengaruh adalah t_1 , t_2 , t_3 , t_5 . Model regresi logistik ordinal antara \tilde{y} dengan komponen T yang terbentuk adalah sebagai berikut:

$$\text{Logit } (Y \leq 0) = 0.212 + 0.89t_1 + 0.234t_2 + 0.753t_3 + 1.511 t_5$$

$$\text{Logit } (Y \leq 1) = 1.068 + 0.89t_1 + 0.234t_2 + 0.753t_3 + 1.511 t_5$$

Pengujian kesesuaian model dengan menggunakan uji *pearson* dan *deviance* yang dapat dilihat pada Tabel 4.9 dengan hipotesis:

$$H_0 : \text{Model sesuai}$$

$$H_1 : \text{Model tidak sesuai}$$

Tabel 4.9 Uji Kesesuaian Model PLSR

	Khi-Kuadrat	db	Nilai P
Pearson	226.554	231	0.570
Deviance	195.042	231	0.959

Hasil uji kesesuaian model yang terdapat pada Tabel 4.9 berdasarkan statistik uji χ^2 Pearson dan deviance didapatkan nilai P lebih besar dari $\alpha=0.05$ maka dapat diputuskan bahwa terima H_0 dan dapat disimpulkan bahwa model regresi logistik ordinal dengan peubah prediktor komponen t_1, t_2, t_3, t_5 sesuai digunakan.

PLSR merupakan pendugaan parameter yang bertujuan untuk mengetahui bentuk hubungan antara peubah prediktor X dengan peubah respon Y, maka persamaan regresi antara Y dan komponen t_1, t_2, t_3, t_5 ditransformasi ke bentuk awal dan didapatkan persamaan sebagai berikut:

$$\text{Logit } (\tilde{y} \leq 0) = 0.212 - 0.37\tilde{X}_1 + 0.41\tilde{X}_2 + 0.35\tilde{X}_3 + 0.25\tilde{X}_4 + 1.54\tilde{X}_5 - 0.09\tilde{X}_6 + 0.5\tilde{X}_7$$

$$\text{Logit } (\tilde{y} \leq 1) = 1.068 + 0.37\tilde{X}_1 + 0.41\tilde{X}_2 + 0.35\tilde{X}_3 + 0.25\tilde{X}_4 + 1.54\tilde{X}_5 - 0.09\tilde{X}_6 + 0.5\tilde{X}_7$$

Model regresi logistik ordinal yang telah terbentuk merupakan persamaan yang memiliki peubah respon dan peubah prediktor dalam bentuk terpusat. Jika dikembalikan ke bentuk original maka didapatkan persamaan sebagai berikut:

$$\begin{aligned} \text{Logit } (Y \leq 1) &= 60.212 - 0.37 \text{ SSTGRID28} + 0.41 \text{ SSTGRID29} + 0.35 \\ &\quad \text{SSTGRID30} + 0.25 \text{ SSTGRID31} - 1.54 \text{ SSTNINO3.4} \\ &\quad - 0.09 \text{ ANININO3.4} + 0.5 \text{ SOI} \end{aligned}$$

$$\begin{aligned} \text{Logit } (Y \leq 2) &= 61.28 - 0.37 \text{ SSTGRID28} + 0.41 \text{ SSTGRID29} + 0.35 \\ &\quad \text{SSTGRID30} + 0.25 \text{ SSTGRID31} - 1.54 \text{ SSTNINO3.4} \\ &\quad - 0.09 \text{ ANININO3.4} + 0.5 \text{ SOI} \end{aligned}$$

Berdasarkan persamaan regresi logistik ordinal, maka terbentuk nilai odds ratio yang terdapat pada tabel 4.11.

Tabel 4.10 Nilai *Odds Ratio*

Peubah Prediktor	<i>Odds Ratio</i>
SST GRID 28	0.69
SST GRID 29	1.51
SST GRID 30	1.42
SST GRID 31	1.28
SST NINO 3.4	4.66
ANO NINO 3.4	1.09
SOI	1.65

Berdasarkan model tersebut dapat diinterpretasikan bahwa setiap bertambahnya 1°C suhu permukaan laut pada grid 28 akan menurunkan peluang sifat hujan di Kota Pacitan menjadi di atas normal sebesar $e^{-0.37} = 0.69$ kali dari saat suhu permukaan laut di grid 28 sebelumnya. Setiap bertambahnya 1°C suhu permukaan laut pada grid 29 akan meningkatkan peluang sifat hujan di Kota Pacitan menjadi di atas normal sebesar $e^{0.41} = 1.51$ kali dari saat suhu permukaan laut di grid 29 sebelumnya. Setiap bertambahnya 1°C suhu permukaan laut pada grid 30 akan meningkatkan peluang sifat hujan di Kota Pacitan menjadi di atas normal sebesar $e^{0.35} = 1.42$ kali dari saat suhu permukaan laut di grid 30 sebelumnya. setiap bertambahnya 1°C suhu permukaan laut pada grid 31 akan meningkatkan peluang sifat hujan di Kota Pacitan menjadi di atas normal sebesar $e^{0.25} = 1.28$ kali dari saat suhu permukaan laut di grid 31 sebelumnya. setiap bertambahnya 1°C suhu permukaan laut pada NINO3.4 (Samudra Pasifik) akan meningkatkan peluang sifat hujan di Kota Pacitan menjadi di atas normal sebesar $e^{-1.54} = 4.66$ kali dari suhu permukaan laut di NINO 3.4 (Samudra Pasifik) sebelumnya. Setiap bertambahnya 1°C perubahan suhu permukaan laut NINO 3.4 (Samudra Pasifik) akan meningkatkan peluang sifat hujan di Kota Pacitan menjadi di atas normal sebesar $e^{-0.09} = 1.09$ kali dari saat perubahan suhu permukaan laut di NINO 3.4 (Samudra Pasifik) sebelumnya. Setiap bertambahnya 1 satuan *Southern Oscillation Index* akan meningkatkan peluang sifat hujan di Kota Pacitan menjadi di atas normal sebesar $e^{0.5} = 1.65$ kali dari saat nilai *Southern Oscillation Index* sebelumnya.

BAB V

KESIMPULAN DAN SARAN

5.1 Kesimpulan

Berdasarkan hasil dari penelitian dapat disimpulkan bahwa persamaan regresi logistik ordinal yang terbentuk dengan pendugaan parameter PLSR dengan pembentukan komponen NIPALS adalah sebagai berikut:

$$\begin{aligned}\text{Logit } (Y \leq 1) = & 60.212 - 0.37 \text{ SSTGRID28} + 0.41 \text{ SSTGRID29} + 0.35 \\ & \text{ SSTGRID30} + 0.25 \text{ SSTGRID31} - 1.54 \text{ SSTDNINO3.4} \\ & - 0.09 \text{ ANININO3.4} + 0.5 \text{ SOI}\end{aligned}$$

$$\begin{aligned}\text{Logit } (Y \leq 2) = & 61.28 - 0.37 \text{ SSTGRID28} + 0.41 \text{ SSTGRID29} + 0.35 \\ & \text{ SSTGRID30} + 0.25 \text{ SSTGRID31} - 1.54 \text{ SSTDNINO3.4} \\ & - 0.09 \text{ ANININO3.4} + 0.5 \text{ SOI}\end{aligned}$$

Berdasarkan model dapat diinterpretasikan bahwa setiap kenaikan suhu permukaan laut pada grid 29, grid 30, grid 31, NINO 3.4, anomali pada NINO 3.4, SOI akan meningkatkan peluang sifat hujan di Kota Pacitan menjadi diatas normal sedangkan setiap kenaikan suhu permukaan laut pada grid 28 akan menurunkan peluang sifat hujan di Kota Pacitan menjadi di atas normal.

5.2 Saran

Berdasarkan hasil penelitian dengan peningkatan peluang paling tinggi, maka disarankan kepada BMKG lebih memperhatikan suhu permukaan laut yang terjadi di Samudra Pasifik saat memprediksi sifat hujan di Kota Pacitan. Untuk peneliti selanjutkan, disarankan membandingkan *Nonlinier Iterative Partial Least Square* (NIPALS) dengan pembentukan komponen lain seperti *Simple Partial Least Square* (SIMPLS) dalam pembentukan komponen pada PLSR.

UNIVERSITAS BRAWIJAYA



DAFTAR PUSTAKA

- Abdi, H. 2007. Partial Least Square Regression. In: NeilSakind (Ed), Encyclopedia of Meauserement and Statistics, Thousand Oaks: Sage, The University of Texas at Dallas, USA.
- Agresti, A. 2002. *Categorical Data Analysis Second Edition*. Canada: John Wiley & Sons. Inc.
- BMKG. 2013. *Buletin Meterologi*.
www.bmkg.bptbatam.go.id/buletin/nov13. Diakses pada tanggal 5 Januari 2014
- BOM. 2002. *Southernern Oscilation Index*. www. bom.gov.au. Diakses pada tanggal 5 Januari 2014
- Bastien, P., V.E. Vinzi and M. Tenenhaus. 2004. *Partial Least Square Generalized Linear Regression*. Jakarta: Computational Statistics & Data Analysis.
- Gujarati, D. N. 2004. *Basic Econometrics Fourth Edition*. New York: Mc Graw-Hill Company, Inc.
- Hosmer, D. W., and S. Lemeshow. 2000. *Applied Logistic Regression Second Edition*. Canada: John Wiley & Sons. Inc.
- Jorgensen, B., and G. Yuri. 2007. Modul 7: *Partial Least Square Regression 1*. Departement of Statistics. Multivariate Data Analysis and chemometrics. Department of Satatistic.
- Kleinbaum, D.G., and M. Klein. 2010. *Logistic Regression A Self Learning Text Third Edition*. London: Springer.
- Kutner, M. H., C. J. Nachtsheim, J. Neter dan W. Li. 2005. Applied Linier Regression Models. Fifth edition. New York: The McGraw-Hill Company, Inc.
- Lestari, K. A. 2013. *Pendekatan Partial Least Square Regression untuk Mengatasi Multikolinieritas dalam Regresi Logistik*

Ordinal. Skripsi S1 Program Studi Statistika Jurusan Matematika Fakultas MIPA Universitas Brawijaya Malang. Tidak dipublikasikan.

- Pawestri, P. A. 2012. *Penaksiran Parameter Univariate Partial Least Squares Regression Menggunakan Algoritma NIPALS (Nonlinier Iterative Partial Least Squares)*. Skripsi S1 Program Studi Matematika Jurusan Matematika Fakultas MIPA Universitas Indonesia Depok.
- Phatak, A, and D. Jong. 1996. *The Geometry of Partial Least Square*. Journal of Chemometrics, vol 11, 311-338.
- Recher. 2002. *Methods of Multivariate Analysis*. New York: John Wiley & Sons. Inc.
- Sumodiningrat G. 2012. *Ekonometrika Pengantar*. Yogyakarta: BPFE.
- Tongkukut, S. H. J. 2011. *El-Nino dan Pengaruhnya Terhadap Curah Hujan Di Manado Sulawesi Utara*. Jurnal Ilmiah Sains Vol. 11 No.1.
- Tresnowati, R, T. A. Nuraini., W. Hanggoro. 2010. *Prediksi Curah Hujan Bulanan Menggunakan Metode Kalman Filter dengan Prediktor SST NINO 3.4 Diprediksi*. Jurnal BMKG dokumen 133 volume 11 nomor 2.

Lampiran 1. Data Sifat Hujan dan Faktor yang Mempengaruhi di Kota Pacitan Tahun 2001-2010

No. Obs.	Sifat Hujan (Y)	SST GRID 28 (X ₁)	SST GRID 29 (X ₂)	SST GRID 30 (X ₃)	SST GRID 31 (X ₄)	SST NINO 3.4 (X ₅)	ANO NINO 3.4 (X ₆)	SOI (X ₇)
1	3	28.7262	29.655	29.4749	28.892	25.74	-0.83	8.9
2	3	28.1968	29.231	29.4166	28.857	26.11	-0.61	11.9
3	3	28.4163	29.086	29.3086	29.055	26.84	-0.38	6.7
4	3	28.4753	29.11	28.7387	28.006	27.52	-0.26	0.3
5	1	28.0588	28.678	28.0283	27.244	27.6	-0.25	-9
6	3	26.8084	27.509	26.6876	26.116	27.68	0.03	1.8
7	1	26.166	26.406	25.5066	25.157	27.32	0.1	-3
8	1	26.0603	26.364	24.9366	24.59	26.87	0.05	-8.9
9	1	26.0585	27.317	26.2248	25.395	26.55	-0.17	1.4
10	3	26.6426	28.567	28.1816	26.409	26.59	-0.1	-1.9
11	3	27.1811	29.169	29.8404	27.752	26.45	-0.2	7.2
12	2	27.2371	29.193	30.2563	29.015	26.17	-0.4	-9.1
13	3	28.1655	29.416	29.8305	29.583	26.5	-0.07	2.7
14	3	28.4287	28.839	29.4257	29.044	26.95	0.23	7.7
15	1	29.1957	29.946	29.9887	28.884	27.32	0.1	-5.2

Lampiran 1. Lanjutan

No. Obs.	Sifat Hujan (Y)	SST GRID 28 (X ₁)	SST GRID 29 (X ₂)	SST GRID 30 (X ₃)	SST GRID 31 (X ₄)	SST NINO 3.4 (X ₅)	ANO NINO 3.4 (X ₆)	SOI (X ₇)
16	2	29.245	30.38	29.713	28.345	27.94	0.16	-3.8
17	3	28.5811	29.596	28.6102	27.177	28.15	0.3	-14.5
18	1	27.2128	27.798	26.7755	26.398	28.43	0.78	-6.3
19	1	25.702	26.031	25.1146	25.041	27.98	0.76	-7.6
20	1	25.3387	25.991	25.1741	24.785	27.79	0.97	-14.6
21	1	25.1691	26.48	26.3157	25.293	27.83	1.11	-7.6
22	1	26.3272	28.377	28.1903	26.459	28.05	1.36	-7.4
23	1	27.4817	29.991	29.487	27.251	28.27	1.62	-6
24	1	28.5584	30.815	31.0794	28.871	28.09	1.52	-10.6
25	1	28.7658	30.055	29.9831	29.152	27.76	1.19	-2
26	2	29.2934	30.176	30.2615	29.464	27.49	0.77	-7.4
27	1	28.9936	29.498	29.5142	29.021	27.81	0.59	-6.8
28	1	28.8117	29.903	29.6145	28.296	27.81	0.03	-5.5
29	1	28.2349	29.058	28.5408	27.197	27.37	-0.48	-7.4
30	1	27.2224	27.779	27.374	26.531	27.48	-0.17	-12
31	1	25.9757	26.731	26.0454	25.422	27.43	0.21	2.9

Lampiran 1. Lanjutan

No. Obs.	Sifat Hujan (Y)	SST GRID 28 (X ₁)	SST GRID 29 (X ₂)	SST GRID 30 (X ₃)	SST GRID 31 (X ₄)	SST NINO 3.4 (X ₅)	ANO NINO 3.4 (X ₆)	SOI (X ₇)
32	1	25.724	26.465	25.8642	24.947	26.85	0.03	-1.8
33	1	25.6125	27.025	27.0261	25.554	26.96	0.24	-2.2
34	2	26.4582	28.368	28.5108	26.537	27.19	0.5	-1.9
35	2	27.1895	29.391	29.5826	27.225	27.05	0.4	-3.4
36	3	27.7189	29.923	30.1198	28.665	26.89	0.32	9.8
37	1	27.9872	29.501	29.7161	29.482	26.74	0.17	-11.6
38	1	28.0947	28.953	29.3119	29.56	26.86	0.14	8.6
39	2	28.5807	29.171	29.8274	29.201	27.1	-0.12	0.2
40	1	28.6815	29.275	29.4977	27.784	27.84	0.06	-15.4
41	3	27.7577	28.638	28.1807	27.088	28.06	0.21	13.1
42	2	26.7443	27.542	26.2544	25.439	27.76	0.11	-14.4
43	1	25.8972	26.26	24.9731	24.808	27.69	0.47	-6.9
44	1	25.4533	26.142	24.8857	24.55	27.54	0.72	-7.6
45	1	25.2257	26.635	25.7743	24.933	27.47	0.75	-2.8
46	1	25.9614	27.96	27.6819	26.037	27.38	0.69	-3.7

Lampiran 1. Lanjutan

No. Obs.	Sifat Hujan (Y)	SST GRID 28 (X ₁)	SST GRID 29 (X ₂)	SST GRID 30 (X ₃)	SST GRID 31 (X ₄)	SST NINO 3.4 (X ₅)	ANO NINO 3.4 (X ₆)	SOI (X ₇)
47	3	27.4376	29.614	29.226	27.157	27.31	0.66	-9.3
48	3	28.1879	30.1	29.9097	28.396	27.31	0.74	-8
49	2	28.7287	29.678	30.035	29.079	27.1	0.53	1.8
50	1	29.0219	29.951	30.4972	29.414	26.96	0.24	-29.1
51	1	29.5492	30.265	30.4832	28.865	27.55	0.33	0.2
52	2	29.4583	30.106	29.8575	28.067	28.07	0.29	-11.2
53	1	28.9257	29.482	28.5033	27.09	28.2	0.35	-14.5
54	2	26.9628	27.585	26.8603	25.874	28.05	0.4	2.6
55	3	26.4605	27.009	25.9013	25.552	27.47	0.25	0.9
56	1	25.6489	26.33	25.7119	25.211	26.88	0.06	-6.9
57	1	25.8115	27.492	26.8649	25.438	26.63	-0.09	3.9
58	2	26.267	28.705	28.8315	26.971	26.75	0.06	10.9
59	2	27.2392	29.982	30.2638	28.09	26.34	-0.31	-2.7
60	3	27.8504	30.69	31.1604	29.572	25.89	-0.68	0.6
61	3	28.3244	29.534	30.3005	29.283	25.64	-0.93	12.7
62	2	28.6669	29.229	30.191	29.235	26.08	-0.64	0.1

Lampiran 1. Lanjutan

No. Obs.	Sifat Hujan (Y)	SST GRID 28 (X ₁)	SST GRID 29 (X ₂)	SST GRID 30 (X ₃)	SST GRID 31 (X ₄)	SST NINO 3.4 (X ₅)	ANO NINO 3.4 (X ₆)	SOI (X ₇)
63	3	28.6292	28.998	29.5309	28.745	26.57	-0.65	13.8
64	3	28.235	28.948	29.099	28.423	27.59	-0.19	15.2
65	3	28.0136	28.435	27.6314	26.903	27.91	0.06	-9.8
66	2	26.5499	26.635	25.646	25.93	27.85	0.2	-5.5
67	1	25.4178	25.654	24.8142	25.082	27.35	0.13	-8.9
68	1	25.083	25.577	24.8557	24.727	27.22	0.4	-15.9
69	1	25.5358	26.525	25.5977	24.85	27.34	0.62	-5.1
70	1	26.1612	27.656	26.5345	25.091	27.47	0.78	-15.3
71	1	27.5664	28.803	27.7287	26.485	27.73	1.08	-1.4
72	1	28.5429	30.252	29.6043	27.559	27.76	1.19	-3
73	1	28.2273	29.375	29.9251	29.076	27.26	0.69	-7.3
74	2	29.0421	29.566	29.3879	28.647	26.81	0.09	-2.7
75	3	28.5326	29.061	29.3262	28.725	27.18	-0.04	-1.4
76	3	28.4852	28.847	28.6893	27.516	27.78	0	-3
77	3	28.0475	28.729	28.4272	26.993	27.57	-0.28	-2.7

Lampiran 1. Lanjutan

No. Obs.	Sifat Hujan (Y)	SST GRID 28 (X ₁)	SST GRID 29 (X ₂)	SST GRID 30 (X ₃)	SST GRID 31 (X ₄)	SST NINO 3.4 (X ₅)	ANO NINO 3.4 (X ₆)	SOI (X ₇)
78	3	26.8036	27.237	26.2066	26.069	27.55	-0.1	5
79	1	26.058	26.032	24.3078	24.803	26.79	-0.43	-4.3
80	1	25.1247	25.487	24.5237	24.453	26.2	-0.62	2.7
81	1	25.8255	26.803	26.0093	24.972	25.77	-0.95	1.5
82	1	26.3499	27.878	28.0425	26.493	25.22	-1.47	5.4
83	2	27.6295	29.342	29.7872	27.615	25.06	-1.59	9.8
84	3	28.5918	30.298	30.7104	28.822	24.97	-1.6	14.4
85	2	28.626	29.441	29.945	29.135	24.71	-1.86	14.1
86	3	29.0602	29.454	30.2667	29.257	24.83	-1.89	21.3
87	3	29.0869	29.583	29.4425	28.389	26.07	-1.15	12.2
88	1	29.1661	29.62	29.136	27.577	26.83	-0.95	4.5
89	1	28.0876	28.619	27.7767	26.273	27.18	-0.67	-4.3
90	1	27.002	27.462	26.2272	25.474	27.17	-0.48	5
91	1	25.7632	26.002	25.0623	24.686	27.19	-0.03	2.2
92	1	25.2341	25.679	24.486	24.538	26.85	0.03	9.1
93	1	26.0893	27.177	26.2851	25.576	26.44	-0.28	14.1

Lampiran 1. Lanjutan

No. Obs.	Sifat Hujan (Y)	SST GRID 28 (X ₁)	SST GRID 29 (X ₂)	SST GRID 30 (X ₃)	SST GRID 31 (X ₄)	SST NINO 3.4 (X ₅)	ANO NINO 3.4 (X ₆)	SOI (X ₇)
94	1	27.219	28.612	28.2368	26.642	26.33	-0.36	13.4
95	1	27.5813	29.669	29.6992	28.255	26.3	-0.35	17.1
96	1	27.9007	29.767	30.5636	29.619	25.74	-0.83	13.3
97	1	28.6055	29.421	29.5629	29.459	25.54	-1.03	9.4
98	3	28.5098	29.061	29.3847	29.199	26.04	-0.68	14.8
99	1	29.2365	29.699	29.7727	28.746	26.67	-0.55	0.2
100	1	29.6053	30.317	29.6467	28.491	27.5	-0.27	8.6
101	3	28.1771	28.821	27.9247	27.207	28.03	0.18	-5.1
102	3	27.0923	27.643	26.6885	26.152	28.11	0.47	-2.3
103	1	26.6905	27.356	26.2478	25.894	27.94	0.72	1.6
104	1	25.8187	26.712	25.876	25.369	27.53	0.71	-5
105	1	25.8937	27.793	27.1862	25.943	27.47	0.75	3.9
106	2	26.7476	28.8	27.9399	26.626	27.63	0.94	-14.7
107	1	28.3139	29.995	29.3871	27.349	28.19	1.54	-6.7
108	1	28.4478	29.865	30.5764	28.909	28.3	1.72	-7

Lampiran 1. Lanjutan

No. Obs.	Sifat Hujan (Y)	SST GRID 28 (X ₁)	SST GRID 29 (X ₂)	SST GRID 30 (X ₃)	SST GRID 31 (X ₄)	SST NINO 3.4 (X ₅)	ANO NINO 3.4 (X ₆)	SOI (X ₇)
109	1	28.4945	29.339	29.9266	29.077	28.07	1.5	-10.1
110	1	28.7868	29.838	30.2246	29.503	27.94	1.22	-14.5
111	3	29.4138	30.19	29.8493	29.31	28.29	1.08	-10.6
112	3	29.7931	30.416	29.4906	28.707	28.36	0.59	15.2
113	3	28.8433	29.255	28.8224	27.6771	27.68	-0.17	10
114	3	27.7975	28.22	27.1953	26.765	27	-0.65	1.8
115	3	26.525	26.97	25.8117	25.83	26.09	-1.13	20.5
116	1	26.2487	26.991	25.7864	25.606	25.5	-1.32	18.8
117	3	26.178	27.759	27.3852	26.695	25.07	-1.65	25
118	3	27.8479	28.9	28.5853	27.409	25.01	-1.68	18.3
119	1	28.7399	29.736	29.7187	28.437	25.07	-1.58	16.4
120	1	29.241	30.472	30.6776	29.913	24.95	-1.62	27.1

Keterangan:

Peubah respon:

Y=1 Sifat hujan di atas normal

Y=2 Sifat hujan normal

Y=3 Sifat hujan di bawah normal

Satuan peubah prediktor:

SST : dalam derajat Celcius

ANO : dalam derajat Celcius

SOI : nilai indeks osilasi selatan

Lampiran 2. Pendugaan Awal Parameter Regresi Logistik Ordinal
Menggunakan SPSS 17.0

Case Processing Summary

		N	Marginal Percentage
SIFAT_HUJAN	DI ATAS NORMAL	65	54.2%
	NORMAL	18	15.0%
	DI BAWAH NORMAL	37	30.8%
Valid			120 100.0%
Missing			0
Total			120

Model Fitting Information

Model	-2 Log Likelihood	Chi-Square	df	Sig.
Intercept Only	235.066			
Final	195.042	40.024	7	.000

Link function: Logit.

Goodness-of-Fit

	Chi-Square	df	Sig.
Pearson	226.554	231	.570
Deviance	195.042	231	.959

Link function: Logit.

Lampiran 2. Lanjutan

Pseudo R-Square

Cox and Snell	.284
Nagelkerke	.330
McFadden	.170

Link function: Logit.

Parameter Estimates

	Estimate	Std. Error	Wald	df	Sig.	95% Confidence Interval	
						Lower Bound	Upper Bound
Threshold [SIFAT_HUJAN = 1,00]	80.178	19.144	17.540	1	.000	42.656	117.699
[SIFAT_HUJAN = 2,00]	81.034	19.176	17.857	1	.000	43.450	118.619
Location							
SST_28	-1.328	.616	4.647	1	.031	-2.535	-.121
SST_29	.895	.844	1.124	1	.289	-.760	2.550
SST_30	-.289	.709	.167	1	.683	-1.678	1.100
SST_31	1.118	.531	4.424	1	.035	.076	2.160
SST_NINO3.4	2.538	.720	12.418	1	.000	1.126	3.950
ANO_NINO3.4	-2.700	.767	12.404	1	.000	-4.202	-1.197
SOI	.068	.030	5.258	1	.022	.010	.126

Link function: Logit.

Lampiran 3. Pendekripsi Multikolinieritas Menggunakan MINITAB 14

Regression Analysis: X1 versus X2; X3; X4; X5; X6; X7

The regression equation is

$$X_1 = 0,0003 + 0,862 X_2 - 0,514 X_3 + 0,616 X_4 + 0,667 X_5 - 0,769 X_6 - 0,00558 X_7$$

Predictor	Coef	SE Coef	T	P
Constant	0,00031	0,02997	0,01	0,992
X2	0,86188	0,09939	8,67	0,000
X3	-0,51391	0,09892	-5,20	0,000
X4	0,61623	0,05956	10,35	0,000
X5	0,66691	0,07800	8,55	0,000
X6	-0,76895	0,08228	-9,35	0,000
X7	-0,005581	0,004142	-1,35	0,181

$$S = 0,328275 \quad R-Sq = 93,9\% \quad R-Sq(adj) = 93,5\%$$

Regression Analysis: X2 versus X1; X3; X4; X5; X6; X7

The regression equation is

$$X_2 = - 0,0000 + 0,464 X_1 + 0,752 X_3 - 0,366 X_4 - 0,0709 X_5 + 0,195 X_6 + 0,00603 X_7$$

Predictor	Coef	SE Coef	T	P
Constant	-0,00001	0,02198	-0,00	1,000
X1	0,46360	0,05346	8,67	0,000
X3	0,75228	0,03888	19,35	0,000
X4	-0,36633	0,05028	-7,29	0,000
X5	-0,07091	0,07311	-0,97	0,334
X6	0,19470	0,07823	2,49	0,014
X7	0,006032	0,003009	2,00	0,047

$$S = 0,240761 \quad R-Sq = 97,2\% \quad R-Sq(adj) = 97,0\%$$

Lampiran 3. Lanjutan

Regression Analysis: X3 versus X1; X2; X4; X5; X6; X7

The regression equation is

$$X3 = -0,0001 - 0,375 X1 + 1,02 X2 + 0,553 X4 - 0,0663 X5 - 0,0485 X6 - 0,00741 X7$$

Predictor	Coef	SE Coef	T	P
Constant	-0,00005	0,02561	-0,00	0,998
X1	-0,37519	0,07222	-5,20	0,000
X2	1,02104	0,05278	19,35	0,000
X4	0,55302	0,04834	11,44	0,000
X5	-0,06635	0,08530	-0,78	0,438
X6	-0,04846	0,09350	-0,52	0,605
X7	-0,007409	0,003499	-2,12	0,036

$$S = 0,280490 \quad R-Sq = 97,8\% \quad R-Sq(adj) = 97,7\%$$

Regression Analysis: X4 versus X1; X2; X3; X5; X6; X7

The regression equation is

$$X4 = -0,0002 + 0,789 X1 - 0,872 X2 + 0,970 X3 - 0,399 X5 + 0,473 X6 + 0,00909 X7$$

Predictor	Coef	SE Coef	T	P
Constant	-0,00018	0,03392	-0,01	0,996
X1	0,78942	0,07630	10,35	0,000
X2	-0,8724	0,1198	-7,29	0,000
X3	0,97038	0,08482	11,44	0,000
X5	-0,3993	0,1069	-3,74	0,000
X6	0,4733	0,1157	4,09	0,000
X7	0,009091	0,004648	1,96	0,053

$$S = 0,371552 \quad R-Sq = 95,0\% \quad R-Sq(adj) = 94,8\%$$

Lampiran 3. Lanjutan

Regression Analysis: X5 versus X1; X2; X3; X4; X6; X7

The regression equation is

$$X5 = -0,0005 + 0,589 X1 - 0,116 X2 - 0,080 X3 - 0,275 X4 + 0,953 X6 - 0,00488 X7$$

Predictor	Coef	SE Coef	T	P
Constant	-0,00048	0,02816	-0,02	0,987
X1	0,58904	0,06889	8,55	0,000
X2	-0,1164	0,1200	-0,97	0,334
X3	-0,0803	0,1032	-0,78	0,438
X4	-0,27531	0,07369	-3,74	0,000
X6	0,95270	0,05068	18,80	0,000
X7	-0,004883	0,003897	-1,25	0,213

$$S = 0,308515 \quad R-Sq = 89,1\% \quad R-Sq(adj) = 88,5\%$$

Regression Analysis: X6 versus X1; X2; X3; X4; X5; X7

The regression equation is

$$X6 = 0,0004 - 0,567 X1 + 0,267 X2 - 0,0489 X3 + 0,272 X4 + 0,795 X5 - 0,00862 X7$$

Predictor	Coef	SE Coef	T	P
Constant	0,00038	0,02573	0,01	0,988
X1	-0,56696	0,06067	-9,35	0,000
X2	0,2669	0,1072	2,49	0,014
X3	-0,04894	0,09443	-0,52	0,605
X4	0,27242	0,06661	4,09	0,000
X5	0,79531	0,04231	18,80	0,000
X7	-0,008617	0,003492	-2,47	0,015

$$S = 0,281881 \quad R-Sq = 88,0\% \quad R-Sq(adj) = 87,3\%$$

Lampiran 3. Lanjutan

Regression Analysis: X7 versus X1; X2; X3; X4; X5; X6

The regression equation is

$$X7 = -0,001 - 2,83 X1 + 5,69 X2 - 5,15 X3 + 3,60 X4 - 2,81 X5 - 5,93 X6$$

Predictor	Coef	SE Coef	T	P
Constant	-0,0013	0,6752	-0,00	0,998
X1	-2,833	2,103	-1,35	0,181
X2	5,693	2,840	2,00	0,047
X3	-5,152	2,433	-2,12	0,036
X4	3,603	1,842	1,96	0,053
X5	-2,807	2,240	-1,25	0,213
X6	-5,933	2,405	-2,47	0,015

$$S = 7,39646 \quad R-Sq = 49,5\% \quad R-Sq(\text{adj}) = 46,8\%$$

Lampiran 4. Syntax NIPALS Pada MATLAB

```
load('data.mat');
tol=0.05;
y=data(:,1);
x=data(:,2:8);

% cari mean center
[a b]=size(y);
ybar=mode(y);
vybar=y;
for i=1:a
    vybar(i,1)=vybar(i,1)-ybar;
end
% cari mean center x
[c d]=size(x);
xbar=zeros(d,d);
for i=1:d
    xbar(i,i)=sum(x(:,i))/c;
end
e=ones(c,d);
xbar=e*xbar;
vxbar=x-xbar;
dx=diag(vxbar'*vxbar,0);
tr_x=sum(dx);

y=vybar;
x=vxbar;
n=1;
while max(max(x))>tol
    disp(['iterasi ke ' num2str(n)]);
    w=(x'*y)./norm(x'*y)
    t=x*w
    p=(x'*t)./(t'*t)
    x=x-t*p'
    y=y-t*c
    var_x=((t'*t)*(p'*p))/tr_x
    var_y=1-(((vybar-t*c)'*(vybar-
    t*c))/(vybar'*vybar))
    n=n+1;
end
```

Lampiran 5. Data Terpusat

No. Obs.	Sifat Hujan (Y)	SST GRID 28 (X ₁)	SST GRID 29 (X ₂)	SST GRID 30 (X ₃)	SST GRID 31 (X ₄)	SST NINO 3.4 (X ₅)	ANO NINO 3.4 (X ₆)	SOI (X ₇)
1	2	1.204	1.114	1.253	1.630	-1.311	-0.843	8.683
2	2	0.675	0.690	1.195	1.594	-0.941	-0.623	11.683
3	2	0.894	0.545	1.087	1.792	-0.211	-0.393	6.483
4	2	0.953	0.569	0.517	0.744	0.469	-0.273	0.083
5	0	0.537	0.136	-0.194	-0.018	0.549	-0.263	-9.217
6	2	-0.714	-1.032	-1.534	-1.147	0.629	0.018	1.583
7	0	-1.356	-2.135	-2.715	-2.106	0.269	0.088	-3.217
8	0	-1.462	-2.178	-3.285	-2.673	-0.181	0.038	-9.117
9	0	-1.464	-1.224	-1.997	-1.867	-0.501	-0.183	1.183
10	2	-0.880	0.026	-0.040	-0.854	-0.461	-0.113	-2.117
11	2	-0.341	0.628	1.619	0.490	-0.601	-0.213	6.983
12	1	-0.285	0.652	2.034	1.752	-0.881	-0.413	-9.317
13	2	0.643	0.875	1.609	2.321	-0.551	-0.083	2.483
14	2	0.906	0.298	1.204	1.782	-0.101	0.218	7.483
15	0	1.673	1.405	1.767	1.621	0.269	0.088	-5.417

Lampiran 5. Lanjutan

No. Obs.	Sifat Hujan (Y)	SST GRID 28 (X ₁)	SST GRID 29 (X ₂)	SST GRID 30 (X ₃)	SST GRID 31 (X ₄)	SST NINO 3.4 (X ₅)	ANO NINO 3.4 (X ₆)	SOI (X ₇)
16	1	1.723	1.839	1.491	1.083	0.889	0.148	-4.017
17	2	1.059	1.055	0.388	-0.085	1.099	0.288	-14.717
18	0	-0.310	-0.743	-1.446	-0.865	1.379	0.768	-6.517
19	0	-1.820	-2.510	-3.107	-2.222	0.929	0.748	-7.817
20	0	-2.184	-2.551	-3.048	-2.477	0.739	0.958	-14.817
21	0	-2.353	-2.061	-1.906	-1.969	0.779	1.098	-7.817
22	0	-1.195	-0.164	-0.032	-0.803	0.999	1.348	-7.617
23	0	-0.041	1.450	1.265	-0.011	1.219	1.608	-6.217
24	0	1.036	2.274	2.858	1.609	1.039	1.508	-10.817
25	0	1.243	1.514	1.761	1.890	0.709	1.178	-2.217
26	1	1.771	1.635	2.040	2.201	0.439	0.758	-7.617
27	0	1.471	0.956	1.292	1.758	0.759	0.578	-7.017
28	0	1.289	1.361	1.393	1.033	0.759	0.018	-5.717
29	0	0.713	0.517	0.319	-0.065	0.319	-0.493	-7.617
30	0	-0.300	-0.763	-0.848	-0.731	0.429	-0.183	-12.217
31	0	-1.547	-1.810	-2.176	-1.841	0.379	0.198	2.683

Lampiran 5. Lanjutan

No. Obs.	Sifat Hujan (Y)	SST GRID 28 (X ₁)	SST GRID 29 (X ₂)	SST GRID 30 (X ₃)	SST GRID 31 (X ₄)	SST NINO 3.4 (X ₅)	ANO NINO 3.4 (X ₆)	SOI (X ₇)
32	0	-1.798	-2.076	-2.358	-2.315	-0.201	0.018	-2.017
33	0	-1.910	-1.516	-1.196	-1.708	-0.091	0.228	-2.417
34	1	-1.064	-0.173	0.289	-0.725	0.139	0.488	-2.117
35	1	-0.333	0.850	1.361	-0.038	-0.001	0.388	-3.617
36	2	0.197	1.381	1.898	1.403	-0.161	0.308	9.583
37	0	0.465	0.960	1.494	2.220	-0.311	0.158	-11.817
38	0	0.572	0.412	1.090	2.298	-0.191	0.128	8.383
39	1	1.058	0.630	1.606	1.938	0.049	-0.133	-0.017
40	0	1.159	0.734	1.276	-0.521	0.789	0.048	-15.617
41	2	0.235	0.097	-0.041	-0.175	1.009	0.198	12.883
42	1	-0.778	-0.999	-1.967	-1.824	0.709	0.098	-14.617
43	0	-1.625	-2.281	-3.249	-2.454	0.639	0.458	-7.117
44	0	-2.069	-2.399	-3.336	-2.712	0.489	0.708	-7.817
45	0	-2.297	-1.906	-2.448	-2.329	0.419	0.738	-3.017
46	0	-1.561	-0.581	-0.540	-1.225	0.329	0.678	-3.917

Lampiran 5. Lanjutan

No. Obs.	Sifat Hujan (Y)	SST GRID 28 (X ₁)	SST GRID 29 (X ₂)	SST GRID 30 (X ₃)	SST GRID 31 (X ₄)	SST NINO 3.4 (X ₅)	ANO NINO 3.4 (X ₆)	SOI (X ₇)
47	2	-0.085	1.073	1.004	-0.106	0.259	0.648	-9.517
48	2	0.666	1.559	1.688	1.134	0.259	0.728	-8.217
49	1	1.206	1.137	1.813	1.817	0.049	0.518	1.583
50	0	1.500	1.409	2.275	2.152	-0.091	0.228	-29.317
51	0	2.027	1.724	2.261	1.602	0.499	0.318	-0.017
52	1	1.936	1.565	1.636	0.805	1.019	0.278	-11.417
53	0	1.403	0.941	0.281	-0.173	1.149	0.338	-14.717
54	1	-0.560	-0.956	-1.362	-1.388	0.999	0.388	2.383
55	2	-1.062	-1.532	-2.321	-1.710	0.419	0.238	0.683
56	0	-1.873	-2.212	-2.510	-2.051	-0.171	0.048	-7.117
57	0	-1.711	-1.049	-1.357	-1.825	-0.421	-0.103	3.683
58	1	-1.255	0.164	0.610	-0.291	-0.301	0.048	10.683
59	1	-0.283	1.441	2.042	0.828	-0.711	-0.323	-2.917
60	2	0.328	2.149	2.938	2.309	-1.161	-0.693	0.383
61	2	0.802	0.993	2.079	2.021	-1.411	-0.943	12.483
62	1	1.145	0.688	1.969	1.973	-0.971	-0.653	-0.117

Lampiran 5. Lanjutan

No. Obs.	Sifat Hujan (Y)	SST GRID 28 (X ₁)	SST GRID 29 (X ₂)	SST GRID 30 (X ₃)	SST GRID 31 (X ₄)	SST NINO 3.4 (X ₅)	ANO NINO 3.4 (X ₆)	SOI (X ₇)
63	2	1.107	0.457	1.309	1.483	-0.481	-0.663	13.583
64	2	0.713	0.407	0.877	1.160	0.539	-0.203	14.983
65	2	0.491	-0.106	-0.590	-0.360	0.859	0.048	-10.017
66	1	-0.972	-1.906	-2.576	-1.332	0.799	0.188	-5.717
67	0	-2.104	-2.888	-3.408	-2.180	0.299	0.118	-9.117
68	0	-2.439	-2.964	-3.366	-2.535	0.169	0.388	-16.117
69	0	-1.986	-2.016	-2.624	-2.412	0.289	0.608	-5.317
70	0	-1.361	-0.885	-1.687	-2.171	0.419	0.768	-15.517
71	0	0.044	0.262	-0.493	-0.777	0.679	1.068	-1.617
72	0	1.021	1.711	1.382	0.297	0.709	1.178	-3.217
73	0	0.705	0.834	1.703	1.814	0.209	0.678	-7.517
74	1	1.520	1.025	1.166	1.384	-0.241	0.078	-2.917
75	2	1.010	0.520	1.104	1.462	0.129	-0.053	-1.617
76	2	0.963	0.306	0.467	0.254	0.729	-0.013	-3.217
77	2	0.525	0.188	0.205	-0.269	0.519	-0.293	-2.917

Lampiran 5. Lanjutan

No. Obs.	Sifat Hujan (Y)	SST GRID 28 (X ₁)	SST GRID 29 (X ₂)	SST GRID 30 (X ₃)	SST GRID 31 (X ₄)	SST NINO 3.4 (X ₅)	ANO NINO 3.4 (X ₆)	SOI (X ₇)
78	2	-0.719	-1.304	-2.015	-1.193	0.499	-0.113	4.783
79	0	-1.464	-2.509	-3.914	-2.459	-0.261	-0.443	-4.517
80	0	-2.398	-3.054	-3.698	-2.809	-0.851	-0.633	2.483
81	0	-1.697	-1.738	-2.213	-2.291	-1.281	-0.963	1.283
82	0	-1.172	-0.663	-0.179	-0.770	-1.831	-1.483	5.183
83	1	0.107	0.801	1.565	0.352	-1.991	-1.603	9.583
84	2	1.069	1.757	2.489	1.560	-2.081	-1.613	14.183
85	1	1.104	0.900	1.723	1.873	-2.341	-1.873	13.883
86	2	1.538	0.913	2.045	1.995	-2.221	-1.903	21.083
87	2	1.565	1.042	1.221	1.127	-0.981	-1.163	11.983
88	0	1.644	1.078	0.914	0.315	-0.221	-0.963	4.283
89	0	0.565	0.077	-0.445	-0.990	0.129	-0.683	-4.517
90	0	-0.520	-1.079	-1.995	-1.788	0.119	-0.493	4.783
91	0	-1.759	-2.539	-3.160	-2.577	0.139	-0.043	1.983
92	0	-2.288	-2.862	-3.736	-2.725	-0.201	0.018	8.883
93	0	-1.433	-1.364	-1.937	-1.686	-0.611	-0.293	13.883

Lampiran 5. Lanjutan

No. Obs.	Sifat Hujan (Y)	SST GRID 28 (X ₁)	SST GRID 29 (X ₂)	SST GRID 30 (X ₃)	SST GRID 31 (X ₄)	SST NINO 3.4 (X ₅)	ANO NINO 3.4 (X ₆)	SOI (X ₇)
94	0	-0.303	0.071	0.015	-0.620	-0.721	-0.373	13.183
95	0	0.059	1.128	1.477	0.993	-0.751	-0.363	16.883
96	0	0.378	1.226	2.342	2.356	-1.311	-0.843	13.083
97	0	1.083	0.880	1.341	2.196	-1.511	-1.043	9.183
98	2	0.988	0.519	1.163	1.937	-1.011	-0.693	14.583
99	0	1.714	1.158	1.551	1.484	-0.381	-0.563	-0.017
100	0	2.083	1.776	1.425	1.229	0.449	-0.283	8.383
101	2	0.655	0.280	-0.297	-0.055	0.979	0.168	-5.317
102	2	-0.430	-0.898	-1.533	-1.110	1.059	0.458	-2.517
103	0	-0.832	-1.185	-1.974	-1.368	0.889	0.708	1.383
104	0	-1.704	-1.829	-2.346	-1.893	0.479	0.698	-5.217
105	0	-1.629	-0.748	-1.036	-1.319	0.419	0.738	3.683
106	1	-0.775	0.258	-0.282	-0.636	0.579	0.928	-14.917
107	0	0.792	1.454	1.165	0.086	1.139	1.528	-6.917
108	0	0.926	1.324	2.355	1.647	1.249	1.708	-7.217

Lampiran 5. Lanjutan

No. Obs.	Sifat Hujan (Y)	SST GRID 28 (X ₁)	SST GRID 29 (X ₂)	SST GRID 30 (X ₃)	SST GRID 31 (X ₄)	SST NINO 3.4 (X ₅)	ANO NINO 3.4 (X ₆)	SOI (X ₇)
109	0	0.972	0.798	1.705	1.814	1.019	1.488	-10.317
110	0	1.265	1.297	2.003	2.240	0.889	1.208	-14.717
111	2	1.892	1.649	1.627	2.048	1.239	1.068	-10.817
112	2	2.271	1.875	1.269	1.445	1.309	0.578	14.983
113	2	1.321	0.714	0.601	0.415	0.629	-0.183	9.783
114	2	0.275	-0.321	-1.027	-0.497	-0.051	-0.663	1.583
115	2	-0.997	-1.571	-2.410	-1.432	-0.961	-1.143	20.283
116	0	-1.274	-1.550	-2.436	-1.656	-1.551	-1.333	18.583
117	2	-1.344	-0.782	-0.837	-0.568	-1.981	-1.663	24.783
118	2	0.326	0.359	0.363	0.147	-2.041	-1.693	18.083
119	0	1.218	1.195	1.497	1.175	-1.981	-1.593	16.183
120	0	1.719	1.931	2.456	2.651	-2.101	-1.633	26.883

Lampiran 6. Nilai Bobot W

peubah prediktor	w ₁	w ₂	w ₃	w ₄	w ₅	w ₆	w ₇
SST GRID 28	0.12	0.44	0.37	-0.53	-0.57	-0.09	-0.21
SST GRID 29	0.12	0.43	-0.11	-0.06	0.19	0.87	0.04
SST GRID 30	0.15	0.53	-0.40	0.21	0.26	-0.35	-0.55
SST GRID 31	0.15	0.50	0.02	0.21	-0.01	-0.29	0.77
SST NINO 3.4	-0.04	0.10	0.70	-0.12	0.68	-0.11	-0.08
ANO NINO 3.4	-0.06	-0.05	-0.45	-0.78	0.33	-0.16	0.22
SOI	0.96	-0.27	0.03	-0.05	0.06	-0.01	0.00

Lampiran 7. Nilai Komponden T

No. Obs.	t1	t2	t3	t4	t5	t6	t7
1	9.1455	2.0018	-0.1742	0.1468	-0.6823	0.033	0.2971
2	11.8692	1.3356	-0.1452	0.0822	-0.0575	-0.2376	0.1843
3	6.8605	1.8146	0.329	0.3208	0.3199	-0.4061	0.1984
4	0.4502	1.4483	0.7503	0.3904	0.3783	0.0756	0.0789
5	-8.7994	0.8681	0.6233	0.705	0.2634	0.2452	0.099
6	0.8784	-2.3259	0.5978	0.1142	0.4864	0.04	0.057
7	-4.249	-4.0287	0.2786	0.0894	-0.1673	-0.2282	-0.123
8	-10.0797	-4.3747	-0.0474	0.0848	-0.9144	0.0691	0.0544
9	0.2596	-3.4784	-0.3623	-0.0697	-0.305	0.319	0.1877
10	-2.2413	-0.7747	-0.7656	0.0053	0.0413	0.4527	-0.0524
11	7.0934	0.7998	-0.8496	-0.1199	0.4958	0.0073	-0.4143
12	-8.2544	2.8059	-1.2627	0.9577	0.6523	-0.2632	0.0795
13	3.1866	2.6363	-0.3726	0.1837	0.1411	-0.4437	0.4508
14	7.7658	1.6751	0.1276	-0.3275	-0.128	-0.8591	-0.1469
15	-4.3327	3.6588	0.2922	0.1206	-0.2036	-0.0521	-0.0607
16	-3.085	3.3977	0.7768	0.0345	0.2027	0.5578	0.165

Lampiran 7. Lanjutan

No. Obs.	t1	t2	t3	t4	t5	t6	t7
18	-6.8307	-1.2488	0.8003	-0.155	0.319	-0.0242	0.2101
19	-8.9054	-4.3741	0.2967	-0.09	0.1268	-0.4257	0.0154
20	-15.7032	-4.2352	-0.2654	-0.0987	-0.1181	-0.3782	-0.0332
21	-8.7079	-3.6405	-0.5807	-0.3838	0.4912	-0.4494	-0.2518
22	-7.7164	-0.5661	-0.6113	-0.7248	0.5011	0.0402	-0.0983
23	-5.7539	1.7718	-0.462	-1.1942	0.2357	0.53	0.0757
24	-9.439	4.7055	-0.5666	-0.8723	0.1325	0.1809	-0.0466
25	-1.3472	3.411	0.0106	-0.8606	-0.2492	-0.2457	0.2837
26	-6.324	4.3914	0.0662	-0.3467	-0.4837	-0.2811	0.1663
27	-6.0462	3.2877	0.4886	-0.038	-0.0752	-0.3896	0.1149
28	-4.8318	3.0052	0.572	0.327	0.4505	0.3258	0.0389
29	-7.1038	1.2747	0.4834	0.7134	0.2334	0.4368	-0.112
30	-12.0901	-0.499	0.2674	0.7786	0.2735	-0.0002	-0.1301
31	1.5387	-3.9082	0.1753	-0.135	0.3174	-0.1779	-0.1076
32	-3.0968	-4.237	-0.331	-0.0174	-0.2106	-0.1568	-0.305

Lampiran 7. Lanjutan

No. Obs.	t1	t2	t3	t4	t5	t6	t7
33	-3.174	-3.0294	-0.7439	-0.0581	0.3245	-0.1818	-0.4132
34	-2.277	-0.6762	-0.7718	-0.333	0.4035	0.0535	-0.3577
35	-3.229	1.1934	-0.8659	-0.3043	0.2679	0.321	-0.313
36	9.8701	1.8756	-0.5275	-0.5689	0.4856	0.1016	0.2116
37	-10.5994	3.4222	-0.6345	0.5754	0.1286	-0.239	0.6954
38	8.673	1.7209	0.0568	-0.0832	0.2948	-0.7414	0.4761
39	0.7303	2.7373	0.188	0.374	0.3342	-0.586	-0.1173
40	-14.5158	2.9732	0.3533	0.6356	0.2179	0.0068	-0.5496
41	12.3135	-0.727	0.9735	-0.4543	0.8174	0.0368	-0.1705
42	-14.8432	-1.8794	0.3577	0.5158	0.0661	0.4464	0.1559
43	-8.2117	-4.4394	0.3313	-0.0383	-0.169	-0.1126	0.1063
44	-9.0119	-4.8709	-0.0849	-0.2934	-0.3144	-0.1147	0.1097
45	-4.1802	-4.3705	-0.4265	-0.4319	0.2015	-0.0246	0.0694
46	-4.3329	-1.7037	-0.7323	-0.3738	0.4457	0.1485	-0.0893
47	-8.9256	1.5681	-0.7048	-0.3553	-0.0505	0.5529	0.0256
48	-7.2453	3.0967	-0.5192	-0.3789	-0.1515	0.2721	0.245

Lampiran 7. Lanjutan

No. Obs.	t1	t2	t3	t4	t5	t6	t7
49	2.3138	2.9414	-0.1135	-0.5127	-0.3321	-0.4366	-0.0678
50	-27.1152	5.6811	-0.673	0.9455	-0.5522	-0.2208	0.0377
51	0.9762	3.8893	0.4331	-0.3784	-0.2664	-0.0901	-0.413
52	-10.2236	3.7972	0.702	0.1228	-0.111	0.2944	-0.3854
53	-13.8909	2.2036	0.8472	0.1609	-0.2948	0.5219	-0.1082
54	1.6252	-2.2918	0.6957	-0.2956	0.3989	-0.0208	-0.2537
55	-0.2972	-3.4358	0.4023	-0.1883	-0.0791	-0.0372	0.1078
56	-8.0004	-3.9418	-0.373	0.2642	-0.1612	-0.2485	-0.0772
57	2.7465	-3.2913	-0.609	-0.1768	0.128	0.2972	-0.0816
58	10.1788	-1.0557	-0.8039	-0.3813	0.8703	0.2307	-0.066
59	-2.1737	2.2634	-1.1822	0.3474	0.6002	0.5892	0.1202
60	1.5502	3.9312	-1.1926	0.6478	0.7084	0.5132	0.556
61	12.9266	2.1828	-0.5242	0.276	-0.0047	-0.3118	-0.0858
62	0.7848	2.9695	-0.3884	0.5458	-0.281	-0.6017	-0.3553
63	13.701	1.3578	0.3885	0.1073	0.1176	-0.5135	-0.3462
64	14.808	0.7115	0.8791	-0.056	0.958	-0.3153	-0.0863

Lampiran 7. Lanjutan

No. Obs.	t1	t2	t3	t4	t5	t6	t7
65	-9.7452	0.3927	0.7765	0.4554	0.1218	0.1724	0.0366
66	-6.4633	-3.0448	0.748	0.3754	0.2723	-0.3057	0.2419
67	-10.2058	-4.76	0.1008	0.5296	0.1554	-0.4506	0.1477
68	-17.0284	-4.6856	-0.4352	0.4468	-0.1422	-0.4284	0.0118
69	-6.3897	-4.2732	-0.3174	-0.3345	-0.1868	-0.0825	-0.0338
70	-15.8025	-2.1373	-0.5498	-0.2574	-0.4341	0.44	0.0265
71	-1.8032	-0.4522	0.065	-1.0919	-0.6471	0.2671	0.0827
72	-2.6095	2.3956	-0.1396	-1.2236	-0.6482	0.4655	-0.0772
73	-6.5435	3.1114	-0.4118	-0.1273	-0.0292	-0.5287	0.0351
74	-2.1057	2.7355	0.0998	-0.1431	-0.8568	-0.1748	0.0355
75	-0.9808	2.235	0.2793	0.2737	0.0909	-0.42	-0.0493
76	-2.8534	1.2692	0.7422	0.217	0.1903	-0.075	-0.3736
77	-2.7246	0.5617	0.5768	0.4053	0.3568	0.199	-0.3579
78	3.8475	-2.9634	0.7844	0.1014	0.3483	-0.031	0.1949
79	-5.7373	-5.0474	0.4359	0.496	-0.6132	0.0448	0.4293
80	0.8195	-6.2988	-0.2469	0.3834	-0.3274	-0.2263	-0.0154

Lampiran 7. Lanjutan

No. Obs.	t1	t2	t3	t4	t5	t6	t7
81	0.2501	-4.2001	-0.6135	0.4729	-0.4682	0.2667	-0.1476
82	4.7774	-1.7818	-1.0303	0.8621	0.069	0.2178	-0.2764
83	9.7729	0.7666	-0.9765	0.6187	-0.1356	0.4051	-0.4403
84	14.7399	2.5048	-0.7613	0.4276	-0.3092	0.4227	-0.1651
85	14.3116	1.8786	-0.5083	0.7897	-0.5447	-0.1179	-0.0401
86	21.3363	1.8734	-0.1772	0.5123	-0.5574	-0.3611	-0.4419
87	12.2715	1.6843	0.3927	0.2705	-0.4574	0.1226	-0.1747
88	4.6864	1.6967	0.7559	0.3895	-0.2771	0.466	-0.3658
89	-4.4376	-0.1303	0.6076	0.5559	-0.1547	0.5529	-0.3223
90	3.8489	-3.088	0.6978	0.1418	-0.0485	0.336	-0.0508
91	0.518	-5.2488	0.2866	-0.0129	-0.0823	-0.2428	-0.2077
92	6.9348	-6.5373	0.1044	-0.3517	-0.2077	-0.2816	0.096
93	12.4775	-4.2362	-0.1328	-0.4296	-0.1548	0.0789	0.0534
94	12.5787	-1.3458	-0.2931	-0.4798	-0.2386	0.2494	-0.2432
95	16.7651	0.7451	-0.4589	-0.3948	0.4027	0.2549	0.1694
96	13.5611	2.3834	-0.7322	0.3516	0.5679	-0.1833	0.2507

Lampiran 7. Lanjutan

No. Obs.	t1	t2	t3	t4	t5	t6	t7
97	9.7035	2.153	-0.2346	0.4767	-0.4283	-0.2544	0.4287
98	14.7219	1.376	0.0758	0.0556	-0.2185	-0.535	0.1283
99	0.8354	2.9936	0.3089	0.3546	-0.4078	-0.0635	-0.1722
100	8.9009	2.7461	1.0849	-0.1809	-0.0308	0.4257	0.0542
101	-5.0931	0.6669	0.885	0.1946	0.2532	0.2583	0.1781
102	-3.0446	-1.8302	0.7478	-0.116	0.2883	-0.0013	0.0609
103	0.4993	-2.8231	0.5436	-0.548	0.0343	-0.085	0.1724
104	-6.1301	-3.6161	-0.1476	-0.3092	-0.0525	-0.2023	0.0645
105	2.8318	-2.6374	-0.422	-0.6904	0.4639	0.1338	0.1067
106	-14.5911	0.2351	-0.6028	-0.2272	0.0225	0.4876	0.4223
107	-6.32	2.1998	-0.0975	-1.2804	-0.4852	0.3573	-0.1279
108	-6.2025	3.73	-0.279	-1.0257	0.1198	-0.5534	-0.3545
109	-9.2846	3.4312	-0.1357	-0.6614	-0.1506	-0.801	-0.1376
110	-13.2793	4.4847	-0.1379	-0.2324	-0.0777	-0.5139	0.1813
111	-9.5152	4.4062	0.6076	-0.3312	-0.1692	-0.144	0.3748
112	15.1866	2.4991	1.5833	-1.0473	0.0652	0.2245	0.2178

Lampiran 7. Lanjutan

No. Obs.	t1	t2	t3	t4	t5	t6	t7
113	9.7665	0.9279	1.1032	-0.2183	0.1912	0.0898	-0.2805
114	1.3237	-0.9312	0.7104	0.4786	-0.0815	0.2786	0.2043
115	18.6764	-4.6604	0.4959	0.1086	-0.0973	0.0844	0.2499
116	17.0126	-4.846	-0.0059	0.1653	-0.4329	0.2453	0.2925
117	23.4913	-3.4725	-0.5225	0.3567	0.3212	0.2399	0.2501
118	17.6913	-0.6805	-0.33	0.3122	-0.5945	0.3473	-0.0723
119	16.3933	1.4289	-0.2898	0.2845	-0.7303	0.2692	-0.1054
120	27.1813	2.6142	-0.1416	0.0817	-0.3776	0.1068	0.2847

Lampiran 8. Nilai Loading P

peubah prediktor	p ₁	p ₂	p ₃	p ₄	p ₅	p ₆	p ₇
SST GRID 28	0.0233	0.389 ₆	0.7251	0.1364	-0.5527	0.0896	-0.2115
SST GRID 29	0.0256	0.442 ₇	-0.0679	-0.277	0.0246	0.8329	0.0401
SST GRID 30	0.041	0.588 ₁	-0.5379	-0.0951	0.322	0.1189	-0.5506
SST GRID 31	0.0443	0.500 ₁	-0.1267	0.2261	0.0439	-0.9423	0.7721
SST NINO 3.4	-0.0604	0.006 ₆	0.7825	-0.9095	0.6991	-0.0441	0.0775
ANO NINO 3.4	-0.0532	0.011 ₈	0.0843	-1.1718	0.3625	-0.343	0.2198
SOI	1.0169	-0.274 ₃	0.0632	0.1174	0.0576	-0.0073	-0.0007

Lampiran 9. Regresi Logistik \tilde{y} dengan Komponen T menggunakan SPSS 17.0

Case Processing Summary

	N	Marginal Percentage
y dibawah normal	65	54.2%
normal	18	15.0%
di atas normal	37	30.8%
Valid	120	100.0%
Missing	0	
Total	120	

Model Fitting Information

Model	-2 Log Likelihood	Chi-Square	df	Sig.
Intercept Only	235.066			
Final	195.042	40.024	7	.000

Link function: Logit.

Goodness-of-Fit

	Chi-Square	df	Sig.
Pearson	226.554	231	.570
Deviance	195.042	231	.959

Link function: Logit.

Pseudo R-Square

Cox and Snell	.284
Nagelkerke	.330
McFadden	.170

Lampiran 9. Lanjutan

Parameter Estimates

	Estimate	Std. Error	Wald	df	Sig.	95% Confidence Interval	
						Lower Bound	Upper Bound
Threshold [y = 0]	.212	.217	.952	1	.329	-.214	.637
	[y = 1]	1.068	.238	20.137	1 .000	.602	1.535
Location t1	.089	.022	16.760	1	.000	.046	.132
	t2	.234	.075	9.747	1 .002	.087	.381
t3	.753	.338	4.971	1	.026	.091	1.416
	t4	.698	.432	2.611	1 .106	-.149	1.545
t5	1.511	.569	7.063	1	.008	.397	2.626
	t6	.353	.583	.367	1 .545	-.789	1.495
t7	.549	.802	.469	1	.494	-1.023	2.121

Link function: Logit.



Lampiran 10. Perhitungan Nilai β Hasil Transformasi dari Komponen T

	W1*C1	W2*C2	W3*C3	W5*C5	beta
X1	0.11	0.10	0.28	-0.86	-0.37
X2	0.11	0.10	-0.08	0.29	0.41
X3	0.13	0.12	-0.30	0.39	0.35
X4	0.13	0.12	0.02	-0.02	0.25
X5	-0.04	0.02	0.53	1.03	1.54
X6	-0.05	-0.01	-0.34	0.50	0.09
X7	0.53	-0.06	0.00	0.03	0.50

Lampiran 11. Perhitungan Nilai β Hasil Transformasi dari Data Terpusat

	c*w	rata-rata	beta*rata2
X1	-0.37	27.52	-10.263
X2	0.41	28.54	11.750
X3	0.35	28.22	9.855
X4	0.25	27.26	6.828
X5	1.54	27.05	41.722
X6	0.09	0.01	0.001
X7	0.50	0.22	0.108
			60.00

$$\text{intercep 1 } (Y=1) = 0.212 + 60 = 60.212$$

$$\text{intercep 2 } (Y=2) = 1.068 + 60 = 61.28$$

Lampiran 12. Perhitungan Nilai *Odd Ratio*

Peubah Prediktor	Nilai beta	OR
SST_28	-0.37	0.69
SST_29	0.41	1.51
SST_30	0.35	1.42
SST_31	0.25	1.28
SST_NINO3.4	1.54	4.66
ANO_NINO3.4	0.09	1.09
SOI	0.50	1.65