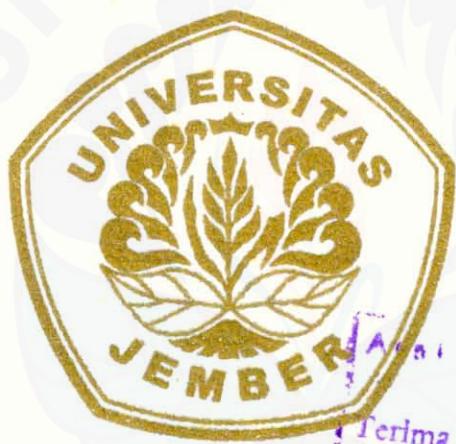




PENGGUNAAN ANALISIS KOMPONEN UTAMA
UNTUK MENGATASI MULTIKOLINIERITAS DALAM
ANALISIS REGRESI LINIER BERGANDA

S K R I P S I

Diajukan untuk Memenuhi Persyaratan Penyelesaian Program Sarjana Sains
Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Jember



Hadiah
Pembelian
Terima
Tgl. 14 JUL 2003
No. Induk: fat

S
Klass
519.536
AND
P
C..

Oleh :

Vita Desy Andriyani

NIM. 981810101029

JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS JEMBER
2003

MOTTO

“ Jadikanlah sabar dan sholat sebagai penolongmu, Dan sesungguhnya yang demikian itu berat, kecuali bagi orang-orang yang beriman “
(Q S. Albaqarah, 153)

“Orang yang gagal meraih sesuatu yang hebat, tidak bisa dikatakan gagal total. Dia selalu yakin dan percaya bahwa paling tidak dia telah memenangkan perang terpenting dalam kehidupan, yaitu mengalahkan rasa takut untuk mencoba”
(Robert H. Schuller)

“ Barang siapa yang menghendaki dunia, Maka carilah itu dengan ilmu. Barang siapa menghendaki akhirat, Maka carilah dengan ilmu. Barang siapa yangmenghendaki dua-duanya, Maka carilah dengan ilmu “
(Khutbatul Ali Rodliyallahu’ anhu)

“Bukanlah suatu aib jika anda gagal dalam suatu usaha, yang merupakan aib ialah jika anda tidak berusaha bangkit dari kegagalan itu”
(Ali bin Abi Tholib ra.)

“Mencintai kehidupan dengan bekerja adalah menyelami rahasia hidup yang paling dalam”
(Kahlil Gibran)

“Gapailah langit, karena jika melesetpun kau akan tetap berada diantara bintang-bintang”
(Rossa Torcasio)

Kupersembahkan Karya Tulis ini untuk:

- Ayahanda “ M. Solikhin “ dan Ibunda “ Sukartini “ tercinta, terima kasih atas semua pengorbanan, kasih sayang, nasehat serta doa yang tiada henti-hentinya.
- Adikku “ Andry Wahyudy “ yang paling aku sayangi.
- Dosen Pembimbingku “ Tanpa Tanda Jasa “ yang menjadi pelita harapanku, trimakasih atas bimbingan, nasehat dan ilmu yang telah diberikan menjadi penerang dalam kegelapan, Jasamu Tiada Tara.
- Kekasihku “ Edy Satrio Nugroho “ yang selalu memberiku semangat dan dorongan.
- Seseorang yang akan membimbing & mendampingiku kelak.
- Almamaterku yang kubanggakan.

DEKLARASI

Karya Tulis Ilmiah (Skripsi) ini berisi hasil kerja penelitian mulai bulan Januari 2003 sampai dengan bulan Juni 2003. Bersama ini saya nyatakan bahwa isi Karya Tulis Ilmiah (Skripsi) ini adalah hasil pekerjaan saya sendiri kecuali jika disebutkan sumbernya dan Karya Tulis Ilmiah (Skripsi) ini belum pernah diajukan pada instansi lain.

Jember, Juni 2003

Penulis,

(Vita Desy Andriyani)

ABSTRAK

Penggunaan Analisis Komponen Utama Untuk Mengatasi Multikolinieritas Dalam Analisis Regresi linier Berganda, Vita Desy Andriyani, 981810101029, Skripsi, Juni 2003, Jurusan Matematika, Fakultas Matematika Dan Ilmu Pengetahuan Alam, Universitas Jember.

Studi ini mengkaji tentang cara mendeteksi multikolinieritas dan penggunaan analisis komponen utama untuk mengatasi multikolinieritas dalam analisis regresi linier berganda. Analisis regresi linier berganda adalah analisis yang mempelajari hubungan kausal antara satu peubah tak bebas dengan dua atau lebih peubah bebas. Salah satu asumsi yang harus dipenuhi dalam analisis regresi linier berganda berhubungan dengan peubah bebas, peubah-peubah bebas tersebut tidak boleh ada korelasi atau terjadi multikolinieritas. Adanya multikolinieritas dapat dideteksi dengan memeriksa matriks korelasi, sedangkan untuk mengukur besarnya multikolinieritas dapat digunakan *Variance Inflation Factor* (VIF). Analisis komponen utama berusaha mereduksi K peubah pengamatan menjadi M peubah baru yang saling ortogonal, masing-masing M peubah baru tersebut merupakan kombinasi linier dari K peubah lama. Data yang dianalisis dalam penelitian ini ada dua jenis yaitu data simulasi dan data riil. Untuk data jenis simulasi didibangkitkan komputer dengan kriteria hubungan diantara dua peubah yang sempurna, kuat dan sedang. Metode analisis terhadap data dilakukan dengan memeriksa matriks korelasi dan menghitung nilai VIF, penerapan metode analisis komponen utama, kemudian membandingkan nilai koefisien regresi yang mengabaikan multikolinieritas dengan nilai koefisien regresi yang menggunakan metode analisis komponen utama. Hasil yang didapat menunjukkan bahwa multikolinieritas terdapat pada data yang memiliki kriteria hubungan diantara dua peubah yang sempurna dan kuat. Metode analisis komponen utama yang diterapkan pada analisis regresi mampu menghilangkan multikolinieritas, tetapi mengakibatkan koefisien regresi mempunyai bias yang lebih besar daripada metode kuadrat terkecil yang diterapkan secara langsung.

Kata kunci: *Analisis Regresi Linier berganda, Multikolinieritas, Analisis Komponen Utama, Ortogonal, Variance Inflation Factor (VIF).*

PENGESAHAN

Karya Tulis Ilmiah (Skripsi) ini diterima oleh Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Jember, pada :

Hari : **JUM'AT**
Tanggal : **27 JUN 2003**
Tempat : Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Jember

Tim Penguji

Ketua (Dosen Pembimbing Utama)


Drs. Made Tirta, Dip.Sc, M.Sc, Ph.D

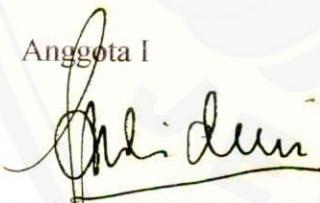
NIP : 131 474 500

Sekretaris (Dosen Pembimbing Anggota)


Rita Ratih T, S.Si, M.Si

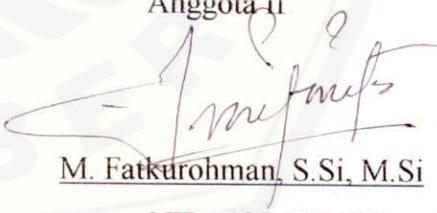
NIP : 132 243 343

Anggota I


Yuliani Setia Dewi, S.Si, M.Si

NIP : 132 258 183

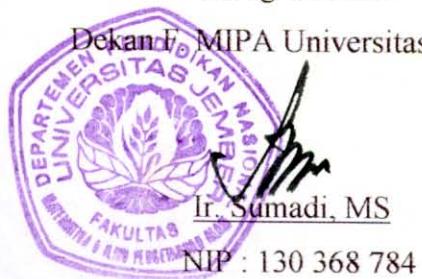
Anggota II


M. Fatkurohman, S.Si, M.Si

NIP : 132 210 538

Mengesahkan :

Dekan F MIPA Universitas jember



Ir. Sumadi, MS

NIP : 130 368 784

KATA PENGANTAR

Dengan memanjatkan puji syukur kehadirat Allah SWT, atas segala rahmat, taufiq serta hidayah – Nya sehingga penulis dapat menyelesaikan Tugas Akhir berupa Karya Tulis Ilmiah (Skripsi) ini.

Karya Tulis Ilmiah (Skripsi) ini disusun untuk memenuhi persyaratan Tugas Akhir (MAU 425) pada kurikulum pendidikan di jurusan Matematika, Fakultas MIPA Universitas Jember (UNEJ).

Dengan selesainya Karya Tulis Ilmiah (Skripsi) ini tidak lupa penulis mengucapkan terima kasih kepada :

1. Ibunda dan Ayahanda tercinta atas dorongan semangat dan petuah-petuah yang menuntunku menuju pendewasaan diri,
2. Bapak. Ir. Sumadi MS, selaku Dekan Fakultas MIPA Universitas Jember,
3. Bapak. Drs. Kusno, DEA, Ph.D, selaku Ketua Jurusan Matematika Fakultas MIPA Universitas Jember,
4. Bapak. Drs I Made Tirta M.Sc, Ph.D, selaku Dosen Pembimbing Utama (DPU) dari Jurusan Matematika Fakultas MIPA Universitas Jember,
5. Ibu Rita Ratih T, S.Si, M.Si, selaku Dosen Pembimbing Anggota (DPA) dari Jurusan Matematika Fakultas MIPA Universitas Jember,
6. Ibu Yuliani Setia Dewi, S.Si. M.Si, selaku Dosen Penguji Utama Karya Tulis Ilmiah (Skripsi) dari Jurusan Matematika Fakultas MIPA Universitas Jember,
7. Bapak. Fatkuraḥman S.Si. M.Si, selaku Dosen Penguji Anggota Karya Tulis Ilmiah (Skripsi) dari jurusan Matematika Fakultas MIPA Universitas Jember,
8. Sahabat-sahabatku sepejuangan “ Misti, Ninip, Lena, Mamad, Anis”,
9. Sahabat-sahabatku yang telah membantuku “Indah, Nonik, Rina, Indri, Bagus”,
10. Rekan-rekan seperjuangan angkatan ’98 Matematika UNEJ,

11. Rekan-rekan seperjuangan angkatan '97 dan '99 Matematika UNEJ,
12. Penghuni kost F mastrip 12 Jember,
13. Saudaraku seperjuangan "Laily, Dewi, Kotery, Anis (sincan)",
14. Sahabat Bermainku "Uud dan Agus, Titin, M' Desy",
15. Teman-temanku KKN "Adi, Yuli, Helmi, Soni, Ningsih",
16. Dan seluruh pihak terkait yang tidak dapat saya sebut satu persatu yang telah membantu penulis selama penyusunan Karya Tulis Ilmiah (Skripsi) ini.

Penulis menyadari bahwa Karya Tulis Ilmiah (Skripsi) ini masih jauh dari sempurna oleh karena itu saran dan koreksi atas kekurangan Karya Tulis Ilmiah (Skripsi) ini akan diterima dengan senang hati.

Akhir kata semoga dengan tersusunnya Karya Tulis Ilmiah (Skripsi) ini dapat memberikan manfaat.

Hormat Kami,

Penulis

DAFTAR ISI

	Hal
HALAMAN JUDUL.....	i
HALAMAN MOTTO.....	ii
HALAMAN PERSEMBAHIAN.....	iii
HALAMAN DEKLARASI.....	iv
ABSTRAK.....	v
LEMBAR PENGESAHAN.....	vi
KATA PENGANTAR	vii
DAFTAR ISI.....	ix
DAFTAR TABEL.....	xii
DAFTAR LAMPIRAN	xii
 BAB I. PENDAHULUAN	
1.1. Latar Belakang	1
1.2. Permasalahan	2
1.3. Tujuan Penelitian	2
1.4. Manfaat Penelitian	2
 BAB II. TINJAUAN PUSTAKA	
2.1. Analisis Regresi Linier Berganda	3
2.2. Asumsi-asumsi dalam Model Regresi Linier Berganda ..	4
2.3. Estimasi Parameter dengan Metode Kuadrat Terkecil.....	4
2.4. Interval Konfidensi untuk Koefisien Regresi.....	5
2.5. Pengujian Hipotesis.....	6
2.5.1. Pengujian Hipotesis untuk Koefisien Regresi Parsial secara Keseluruhan	6
2.5.2. Pengujian Hipotesis untuk Koefisien Regresi Parsial secara Individual	9
2.6. Koefisien Determinasi dan Korelasi Berganda.....	9
2.7. Multikolinieritas	10

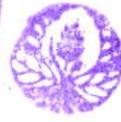
2.8. Analisis Komponen Utama.....	12
BAB III. METODOLOGI	
3.1. Sumber Data	16
3.1.1. Data Simulasi.....	16
3.1.2. Data Riil.....	17
3.2. Analisis Data Simulasi	17
3.3. Perbandingan Nilai Koefisien Regresi pada Data Simulasi	18
3.4. Analisis Data Riil	18
BAB IV. HASIL DAN PEMBAHASAN	
4.1 Ilustrasi Data Simulasi.....	19
4.2. Analisis Data Simulasi	19
4.2.1. Analisa Data Simulasi 1.....	19
4.2.1.1. Metode Kuadrat Terkecil	19
4.2.1.2. Metode Analisis Komponen Utama	19
4.2.2. Analisa Data Simulasi 2.....	22
4.2.2.1. Metode Kuadrat Terkecil	22
4.2.2.2. Metode Analisis Komponen Utama	23
4.2.3. Analisa Data Simulasi 3.....	25
4.2.3.1. Metode Kuadrat Terkecil	25
4.2.3.2. Metode Analisis Komponen Utama	26
4.3. Perbandingan Nilai Koefisien Regresi pada Data Simulasi	28
4.4. Analisa Data Riil	19
4.3.1. Pendekripsi Multikolinieritas.....	19
4.3.2. Metode Analisis Komponen Utama.....	30
BAB V. KESIMPULAN DAN SARAN	
5.1. Kesimpulan.....	33
5.2. Saran.....	33
DAFTAR PUSTAKA	
LAMPIRAN-LAMPIRAN	

DAFTAR TABEL

No	Judul	Hal
Tabel 2. 1	Analisis Ragam dalam Analisis Regresi Linier berganda	8
Tabel 2. 2	Kriteria Hubungan diantara Dua Peubah.....	11
Tabel 4. 1	Penjelasan Varian Total Data 1.....	20
Tabel 4. 2	ANOVA Model Regresi (4.3)	21
Tabel 4. 3	Pengujian Koefisien Regresi secara Individual Model (4.3).....	21
Tabel 4. 4	Koefisien Regresi Data 2.....	22
Tabel 4. 5	Penjelasan Varian Total Data 2.....	23
Tabel 4. 6	ANOVA Model Regresi (4.8)	24
Tabel 4. 7	Pengujian Koefisien Regresi secara Individual Model (4.8).....	24
Tabel 4. 8	Koefisien Regresi Data 3.....	25
Tabel 4. 9	Penjelasan Varian Total Data 3.....	26
Tabel 4. 10	ANOVA Model Regresi (4.13)	27
Tabel 4. 11	Pengujian Koefisien Regresi secara Individual Model (4.13)....	27
Tabel 4. 12	Perbandingan Koefisisen regresi	28
Tabel 4. 13	Penjelasan Varian Total Data Riil.....	30
Tabel 4. 14	ANOVA Model Regresi (4.19)	31
Tabel 4. 15	Pengujian Koefisien Regresi secara Individual Model (4.19)....	31

DAFTAR LAMPIRAN

No	Judul	Hal
Lampiran 1.	Data Simulasi 1(Korelasi Sempurna).....	34
Lampiran 2.	Analisa Data Simulasi 1	36
Lampiran 3.	Data Simulasi 2 (Korelasi Kuat)	39
Lampiran 4.	Analisa Data Simulasi 2	42
Lampiran 5.	Data Simulasi 3 (Korelasi Sedang)	46
Lampiran 6.	Analisa Data Simulasi 3	49
Lampiran 7.	Data Riil	53
Lampiran 8.	Analisa Data Riil	54



BAB I

PENDAHULUAN

1.1 Latar Belakang

Pada saat ini model regresi semakin populer dan familiar di kalangan mahasiswa, dosen, praktisi dan terlebih lagi bagi para peneliti. Aplikasi dari model ini sudah tidak didominasi oleh bidang ilmu matematika, statistika ataupun ekonometrika saja, akan tetapi sudah merambah ke berbagai bidang ilmu seperti biologi, pertanian dan seterusnya. Dengan didukung banyaknya paket program komputer para pengguna regresi dengan mudah dapat mengolah data, akan tetapi terkadang penafsiran dan pengambilan keputusan dari model regresi tidak semudah dibandingkan mengolah datanya. Dalam analisis regresi terdapat batasan-batasan (asumsi) yang menjadi dasar apakah model regresi secara tepat dapat digunakan atau tidak. Jika model tersebut bermasalah maka berakibat fatal, misalnya pengambilan kesimpulan (pengujian hipotesis) akan menyesatkan, koefisien regresi menjadi tidak dapat ditafsirkan dan kalaupun dipaksakan hasil yang diperoleh menjadi tidak tepat dan tidak signifikan.

Salah satu asumsi dalam analisis regresi linier berganda berhubungan dengan peubah bebas. Peubah-peubah tersebut tidak boleh ada korelasi. Dengan demikian diasumsikan tidak terjadi multikolinieritas pada peubah-peubah bebas (Gaspersz, 1991). Sebagai ilustrasi situasi adanya multikolinieritas dalam kehidupan sehari-hari, misalnya dalam menganalisis hubungan antara pendapatan dan kekayaan terhadap konsumsi. Ahli ekonomi berpendapat selain pendapatan, kekayaan, juga suatu penentu penting dari belanja konsumsi, sehingga modelnya dapat dituliskan:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \varepsilon$$

dengan Y konsumsi, X_1 pendapatan, X_2 kekayaan dan β_0 konstanta regresi, β_1 dan β_2 koefisien regresi serta ε galat.

Pada ilustrasi tersebut, dapat dipahami adanya korelasi antara pendapatan dan kekayaan sehingga penggunaan metode kuadrat terkecil (*Ordinary Least Squares Method*) adalah tidak tepat. Ada beberapa metode untuk mengatasi masalah multikolinieritas yang dapat digunakan sebagai petunjuk untuk memperbaiki model regresi diantaranya adalah metode regresi terbaik, dengan menambah data baru, penerapan analisis multivariat seperti analisis komponen utama, dan yang paling mudah adalah dengan membuang peubah-peubah yang diketahui menyebabkan multikolinieritas.

Dalam penelitian ini akan digunakan analisis komponen utama. Analisis komponen utama merupakan cara yang cukup baik untuk mengatasi masalah multikolinieritas (Sembiring, 1995). Cara kerja analisis komponen utama adalah dengan membuat peubah baru yang saling ortogonal dan jumlahnya lebih kecil dari peubah asal. Dari sifat keortogonalan peubah asal ini maka model regresi yang dibentuk tidak lagi mengalami masalah multikolinieritas.

1.2 Perumusan Masalah

1. Bagaimana mendekripsi adanya multikolinieritas pada analisis regresi linier berganda.
2. Bagaimanakah cara menganalisis data yang mengandung multikolinieritas dengan analisis komponen utama.

1.3 Tujuan

1. Mengetahui bagaimana cara mendekripsi adanya multikolinieritas pada analisis regresi linier berganda.
2. Membangun model regresi bila terdapat multikolinieritas pada peubah bebas dengan analisis komponen utama.

1.4 Manfaat

Penulis berharap bagi para pengguna regresi dapat menerapkan hasil penelitian ini sebagai metode perbaikan bila dalam analisis regresi terdapat masalah multikolinieritas pada peubah-peubah bebasnya.



BAB II

TINJAUAN PUSTAKA

2.1 Analisis Regresi Linier Berganda

Dalam penelitian yang menggunakan analisis regresi, sering kali dijumpai lebih dari satu peubah bebas, untuk itu diperlukan model regresi berganda. Jika model regresi berganda yang ditunjukkan oleh koefisinya adalah linier maka dinamakan model regresi linier berganda (Netty & Linggawati, 1988).

Jika terdapat k peubah bebas $X_1, X_2, X_3, \dots, X_k$ dan n pengamatan $Y_1, Y_2, Y_3, \dots, Y_n$ maka masing-masing pengamatan Y_i dapat ditulis dalam model:

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + \varepsilon_i \quad \dots(2.1)$$

dengan

β_0 = konstanta regresi

β_1 = koefisien regresi untuk peubah X_1

β_2 = koefisien regresi untuk peubah X_2

β_k = koefisien regresi untuk peubah X_k

k = banyaknya peubah bebas

ε_i = galat pada pengamatan ke i ; $i = 1, 2, \dots, n$.

Persamaan (2.1) dapat ditulis dalam bentuk matriks sebagai berikut:

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} 1 & X_{11} & X_{21} & \dots & X_{n1} \\ 1 & X_{12} & X_{22} & \dots & X_{n2} \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ 1 & X_{1k} & X_{2k} & \dots & X_{nk} \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix}. \quad \dots(2.2)$$

Persamaan (2.2) dapat ditulis kembali dalam bentuk matriks yang lebih sederhana:

$$\mathbf{Y} = \mathbf{X} \hat{\boldsymbol{\beta}} + \boldsymbol{\varepsilon} \quad \dots(2.3)$$

dengan \mathbf{Y} matriks berordo $(n \times 1)$, \mathbf{X} adalah matriks berordo $(n \times (k+1))$, $\boldsymbol{\beta}$ adalah matriks berordo $((k+1) \times 1)$, dan $\boldsymbol{\varepsilon}$ adalah matriks berordo $(n \times 1)$.

2.2 Asumsi-asumsi dalam Model Regresi Linier Berganda

Asumsi-asumsi dasar dalam model regresi linier berganda (Drapper & Smith, 1991):

1. ε_i merupakan suatu peubah acak normal dengan nilai tengah nol dan ragam σ^2 konstan atau $\varepsilon_i \sim NID(0, \sigma^2)$ dan *NID* adalah *Normal Identic Distribution*;

2. ε_i dan ε_j saling bebas untuk $i \neq j$ sehingga peragam $(\varepsilon_i, \varepsilon_j) = 0$;

$E(Y_i) = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki}$ dan ragam $(Y_i) = \sigma^2$, Y_i independen dengan Y_j untuk $i \neq j$ atau $Y \sim NID(E(Y), \sigma^2)$;

3. tidak terjadi multikolinieritas pada peubah bebas $X_1, X_2, X_3, \dots, X_k$.

2.3 Estimasi Parameter dengan Metode Kuadrat Terkecil

Pendugaan terhadap parameter $\hat{\beta}$ dalam model regresi linier berganda dapat dilakukan dengan metode kuadrat terkecil. Fungsi dari metode kuadrat terkecil adalah dengan meminimumkan jumlah dari kuadrat galat.

$$\begin{aligned} S &= \varepsilon^T \varepsilon \quad \text{dengan } \varepsilon = (\mathbf{Y} - \mathbf{X}\hat{\beta}) \\ &= (\mathbf{Y} - \mathbf{X}\hat{\beta})^T (\mathbf{Y} - \mathbf{X}\hat{\beta}) \\ &= \mathbf{Y}^T \mathbf{Y} - 2\hat{\beta}^T \mathbf{X}^T \mathbf{Y} + \hat{\beta}^T \mathbf{X}^T \mathbf{X} \hat{\beta}. \end{aligned} \quad \dots (2.4)$$

Selanjutnya S diturunkan terhadap $\hat{\beta}$ dan disamakan dengan nol

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

diperoleh:

$$\begin{aligned} -2\mathbf{X}^T \mathbf{Y} - 2\mathbf{X}^T \mathbf{X} \hat{\beta} &= \mathbf{0} \\ \mathbf{X}^T \mathbf{X} \hat{\beta} &= \mathbf{X}^T \mathbf{Y}. \end{aligned} \quad \dots (2.5)$$

Kedua ruas pada persamaan (2.5) dikalikan dengan $(\mathbf{X}^T \mathbf{X})^{-1}$ dan jika $(\mathbf{X}^T \mathbf{X})^{-1}$ tidak singular maka penduga kuadrat terkecil untuk $\hat{\beta}$ adalah

$$\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}, \quad \dots(2.6)$$

dan $var(\hat{\beta})$ adalah

$$var(\hat{\beta}) = var((\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}). \quad \dots(2.7)$$

Ruas kanan pada persamaan (2.7) dikalikan dengan $((\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T)^T$

$$\begin{aligned} var(\hat{\beta}) &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T var(\mathbf{Y}) \cdot ((\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T)^T \\ &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T (\sigma^2) \cdot \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \\ &= \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \\ &= \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1}. \end{aligned} \quad \dots(2.8)$$

2.4 Interval Konfidensi untuk Koefisien Regresi

Menurut Montgomery & Peck (1991), dari asumsi $\varepsilon_i \sim NID(0, \sigma^2)$, statistik uji t akan diberikan sebagai berikut:

$$t = \frac{\hat{\beta}_j - \beta_j}{\sqrt{\hat{\sigma}^2 C_{jj}}} \quad j = 0, 1, 2, \dots, k.$$

Statistik uji tersebut berdistribusi t dengan derajat kebebasan $n-k-1$, dengan C_{jj} adalah elemen ke- j dari diagonal matrik $(\mathbf{X}^T \mathbf{X})^{-1}$ dan $\hat{\sigma}^2$ adalah penduga dari ragam galat ($\hat{\sigma}^2 = KTG$ (Kuadrat Tengah Galat)). Interval konfidensi $(100 - \alpha)\%$ untuk koefisien regresi $\hat{\beta}_j$ adalah:

$$\hat{\beta}_j - t_{(\alpha/2; n-k-1)} \sqrt{\hat{\sigma}^2 C_{jj}} < \beta_j < \hat{\beta}_j + t_{(\alpha/2; n-k-1)} \sqrt{\hat{\sigma}^2 C_{jj}}.$$

dan biasanya $\sqrt{\hat{\sigma}^2 C_{jj}}$ disebut sebagai standar galat koefisien regresi $\hat{\beta}_j$.

2.5 Pengujian Hipotesis

2.5.1 Pengujian Koefesien Regresi Parsial secara Keseluruhan

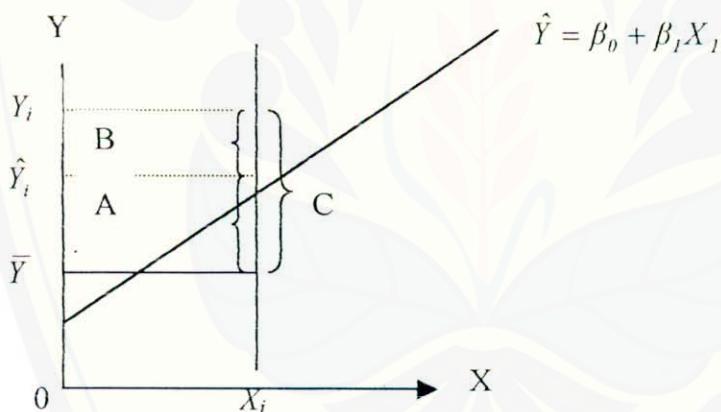
Pengujian hipotesis koefesien regresi parsial secara keseluruhan digunakan untuk menguji kecocokan model regresi yang ditentukan oleh hubungan linier antara peubah tak bebas Y dengan peubah bebas X_1, X_2, \dots, X_k . Pengujian hipotesis ini menggunakan uji statistik F dan pengujian hipotesisnya adalah :

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

$$H_1 : \text{minimal ada satu } \beta_j \neq 0.$$

Dasar dari metode ini adalah pemecahan jumlah kuadrat total (JKT) menjadi jumlah kuadrat regresi (JKR) dan jumlah kuadarat galat (JKG) (Netty & Linggawati, 1988). Perhatikan pemecahannya sebagai berikut:

Pemecahan JKT menjadi JKR dan JKG



Gambar 4.1 Pemecahan JKT menjadi JKR dan JKG

Keterangan gambar

$$C = (Y_i - \bar{Y})$$

$$A = (\hat{Y}_i - \bar{Y})$$

$$B = (Y_i - \hat{Y}_i)$$

$$C = A + B$$

$$\sum (Y_i - \bar{Y})^2 = \sum (\hat{Y}_i - \bar{Y})^2 + \sum (Y_i - \hat{Y}_i)^2.$$

$$JKT = JKR + JKG. \quad \dots(2.9)$$

Menurut Gaspersz (1991), persamaan (2.9) dapat diinterpretasikan bahwa jumlah kuadrat total (JKT) merupakan jumlah dari jumlah kuadrat regresi (JKR) dan jumlah kuadrat galat (JKG). Jumlah kuadrat regresi (JKR) merupakan jumlah dari total keragaman yang dijelaskan oleh persamaan regresi. Jumlah kuadrat galat (JKG) merupakan jumlah dari total keragaman yang tidak dapat dijelaskan oleh persamaan regresi.

Prosedur pengujian untuk $H_1 : \hat{\beta}_j \neq 0$.

$$F_0 = \frac{JKR/k}{JKE/(n-k-1)} = \frac{KTR}{KTG}$$

H_0 ditolak jika $F_0 > F_{(a,k;n-k-1)}$

Selanjutnya, menghitung jumlah kuadrat regresi (JKR) dengan meminimumkan jumlah kuadrat galat.

$$JKG = \sum_{i=1}^n (Y_i - \hat{Y})^2 = \boldsymbol{\varepsilon}^T \boldsymbol{\varepsilon}$$

Dari persamaan (2.4) telah diperoleh:

$$JKG = \mathbf{Y}^T \mathbf{Y} - 2\hat{\boldsymbol{\beta}}^T \mathbf{X}^T \mathbf{Y} + \hat{\boldsymbol{\beta}}^T \mathbf{X}^T \mathbf{X} \hat{\boldsymbol{\beta}}$$

Pada persamaan (2.5) telah diketahui bahwa $\mathbf{X}^T \mathbf{X} \hat{\boldsymbol{\beta}} = \mathbf{X}^T \mathbf{Y}$ sehingga:

$$JKG = \mathbf{Y}^T \mathbf{Y} - \hat{\boldsymbol{\beta}}^T \mathbf{X}^T \mathbf{Y}; \quad \dots (2.10)$$

$$\begin{aligned} JKT &= \sum_{i=1}^n (Y_i - \bar{Y})^2 \\ &= \sum_{i=1}^n (Y_i - 2Y_i \bar{Y} + \bar{Y}^2) \\ &= \sum_{i=1}^n \left(Y_i^2 - 2Y_i \frac{\sum_{i=1}^n Y_i}{n} + \left(\frac{\sum_{i=1}^n Y_i}{n} \right)^2 \right) \end{aligned}$$

$$\begin{aligned}
 &= \sum_{i=1}^n Y_i^2 - 2 \frac{\left(\sum_{i=1}^n Y_i \right)^2}{n} + n \left(\frac{\sum_{i=1}^n Y_i}{n} \right)^2 \\
 &= \sum_{i=1}^n Y_i^2 - \frac{\left(\sum_{i=1}^n Y_i \right)^2}{n} = \mathbf{Y}^T \mathbf{Y} - \frac{\left(\sum_{i=1}^n Y_i \right)^2}{n} . \quad \dots(2.11)
 \end{aligned}$$

Persamaan (2.10) dapat ditulis sebagai berikut:

$$JKG = \mathbf{Y}^T \mathbf{Y} - \frac{\left(\sum_{i=1}^n Y_i \right)^2}{n} - \left[\hat{\beta}^T \mathbf{X}^T \mathbf{Y} - \frac{\left(\sum_{i=1}^n Y_i \right)^2}{n} \right] \text{ atau}$$

$$JKG = JKT - JKR \quad (\text{dari persamaan}(2.9)).$$

$$\text{Diperoleh } JKR = \hat{\beta}^T \mathbf{X}^T \mathbf{Y} - \frac{\left(\sum_{i=1}^n Y_i \right)^2}{n}, \quad \dots(2.12)$$

$$JKG = \mathbf{Y}^T \mathbf{Y} - \hat{\beta}^T \mathbf{X}^T \mathbf{Y} \quad \text{dan}$$

$$JKT = \mathbf{Y}^T \mathbf{Y} - \frac{\left(\sum_{i=1}^n Y_i \right)^2}{n}.$$

Tabel 2.1 Analisis Ragam dalam Analisis Regresi Linier Berganda.

Sumber Keragaman	Jumlah Kuadrat (sum of Square) (JK)	Derajat bebas (Db)	Kuadrat Tengah (Mean Square) (KT)	F_0
Regresi	JKR	k	$KTR = JKR/k$	$\frac{KTR}{KTG}$
Galat	JKG	$n-k-1$	$KTG = JKG/n-k-1$	
Total	JKT	$n-1$		

2.5.2 Pengujian Koefesien Regresi secara Individual

Pengujian hipotesisnya adalah:

$$H_0: \hat{\beta}_j = 0$$

$$H_1: \hat{\beta}_j \neq 0$$

H_0 tidak ditolak artinya peubah bebas X_j bisa dihilangkan dari model. Uji statistiknya adalah :

$$t_0 = \frac{\hat{\beta}_j}{\sqrt{\hat{\sigma}^2 C_{jj}}} = \frac{\hat{\beta}_j}{\text{se}(\hat{\beta}_j)}$$

dengan C_{jj} adalah elemen ke- j dari diagonal matriks $(\mathbf{X}^T \mathbf{X})^{-1}$ yang berkorespondensi dengan $\hat{\beta}_j$ dan $\hat{\sigma}^2 = KTG$.

H_0 ditolak jika $|t_0| > t_{(\alpha/2, n-k-1)}$

2.6 Koefisien Determinasi Berganda dan Koefisien Korelasi Berganda

Koefisien determinasi berganda (R^2) mengukur proporsi keragaman total peubah tak bebas Y yang dijelaskan oleh peubah bebas X yang ada dalam model persamaan regresi secara bersama, sedangkan koefisien korelasi berganda (R) tidak lain merupakan akar pangkat dua dari koefisien determinasi berganda. Koefisien korelasi berganda (R) mengukur keeratan hubungan linier diantara peubah tak bebas Y dengan semua peubah bebas yang ada dalam model persamaan regresi (Gaspersz, 1991).

Koefisien determinasi dan korelasi berganda ditentukan berdasarkan formula:

$$R^2 = \frac{JKR}{JKT} \quad \text{dan} \quad R = \sqrt{\frac{JKR}{JKT}}.$$

Menurut Sembiring (1995), makin dekat R^2 dengan 1 makin baik kecocokan data dengan model, dan makin dekat R^2 dengan 0 makin jelek kecocokan data dengan model.

2.7 Multikolinieritas

Istilah multikolinieritas digunakan untuk hubungan linier pada peubah-peubah bebas dalam model regresi. Multikolinieritas ada yang sempurna dan juga tidak sempurna. Untuk hubungan yang terdiri dari k peubah bebas X_1, X_2, \dots, X_k dan satu peubah tak bebas Y dari persamaan regresi (2.1), maka hubungan linier sempurna terjadi jika:

$$\beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k = 0 \quad \dots(2.13)$$

dengan $\beta_1, \beta_2, \dots, \beta_k$ merupakan konstanta yang tidak seluruhnya nol atau paling sedikit ada satu yang tidak sama dengan nol, yaitu $\beta_j \neq 0$, ($j = 1, 2, \dots, k$), dan untuk hubungan linier tapi tidak sempurna:

$$\beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon_i = 0 \quad \dots(2.14)$$

dengan ε_i = kesalahan penganggu (galat).

Adanya multikolinieritas yang sempurna dapat menyebabkan koefisien regresi tidak menentu (*Indeterminate*) dan nilai standar galat koefisien regresi menjadi tidak terbatas (*Infinite*). bila multikolinieritas tidak sempurna maka koefisien regresi dapat dicari, tetapi standar galatnya besar, sehingga interval koefisiennya menjadi lebar dan mengakibatkan tingkat ketelitian untuk menguji koefisiennya berkurang. Adanya multikolinieritas yang tinggi tidak memungkinkan untuk memecah pengaruh secara terpisah individu dari peubah bebas X terhadap peubah tak bebas Y (Gujarati, 1992).

Ada beberapa cara mendeteksi multikolinieritas diantaranya adalah dengan memeriksa matriks korelasi, *Variance Inflation Factor* (VIF) dan dengan nilai *Condition Number*. Dalam penelitian ini untuk mendeteksi multikolinieritas akan digunakan matriks korelasi sedangkan untuk mengukur derajat kolinieritas pada peubah bebas akan digunakan *Variance Inflation Factor* (VIF).

Menurut Montgomery & Peack (1991), matriks korelasi dapat ditulis sebagai berikut:

$$\mathbf{R} = \begin{bmatrix} 1 & r_{12} & r_{13} & \dots & r_{1k} \\ r_{12} & 1 & r_{23} & \dots & r_{2k} \\ \dots & \dots & \dots & \dots & \dots \\ r_{1k} & r_{2k} & r_{3k} & \dots & 1 \end{bmatrix} \quad \dots(2.15)$$

Dengan $r_{ij} = \frac{S_{ij}}{(S_{ii}S_{jj})^{1/2}}$

$$S_{ij} = \sum_{u=1}^n (X_{ui} - \bar{X}_{ui})(X_{uj} - \bar{X}_{uj})$$

$$S_{jj} = \sum_{i=1}^n (X_{ij} - \bar{X}_j)^2$$

Menurut Sugiarto (1992), besarnya nilai r dapat digunakan untuk menentukan kuat lemahnya hubungan diantara dua peubah. Kuat lemahnya hubungan tersebut dapat ditunjukkan dalam tabel berikut:

Tabel 2.2 Kriteria Hubungan antara Dua Peubah.

Nilai $ r $	Kriteria Hubungan
$r = 0$	Tidak ada korelasi
$0 < r \leq 0,5$	Korelasi lemah
$0,5 < r \leq 0,8$	Korelasi sedang
$0,8 < r < 1$	Korelasi kuat
$r = 1$	Korelasi sempurna

Menurut Montgomery & Peck (1991), *Variance Inflation Factor* (VIF) merupakan elemen diagonal utama dari invers matriks korelasi dan persamaannya dapat ditulis sebagai berikut:

$$VIF_{ij} = \frac{1}{(1-R_{ij}^2)}$$

dengan R_{ij}^2 adalah koefisien determinasi dari peubah bebas X_{ij} jika diregresikan terhadap peubah bebas yang lain. R_{ij}^2 bernilai kecil jika peubah bebas X_{ij} tidak berkorelasi dengan peubah bebas yang lain sehingga VIF_{ij} bernilai mendekati satu, dan R_{ij}^2 bernilai mendekati satu jika peubah bebas X_{ij} berkorelasi dengan peubah bebas yang lain sehingga VIF_{ij} bernilai besar. Jika dari beberapa nilai VIF_{ij} bernilai lebih dari 10 maka adanya multikolinieritas tidak dapat diabaikan.

2.8 Analisis Komponen Utama

Multikolinieritas dalam analisis regresi dapat diatasi dengan beberapa cara yaitu dengan metode regresi terbaik, penambahan data baru, penerapan analisis multivariat seperti analisis komponen utama, dan yang paling mudah adalah dengan membuang peubah-peubah yang diketahui penyebab multikolinieritas. Dalam penelitian ini akan digunakan analisis komponen utama, karena dengan analisis komponen utama peubah-peubah bebas akan saling ortogonal sehingga tidak ada lagi masalah multikolinieritas.

Analisis komponen utama berusaha mereduksi K peubah pengamatan menjadi M peubah baru yang saling ortogonal, masing-masing M peubah baru tersebut merupakan kombinasi linier dari K peubah lama (Mattjik, dkk, 2002). Pemilihan M peubah baru ini sedemikian rupa sehingga keragaman yang dimiliki oleh K peubah lama sebagian besar dapat diterangkan oleh M peubah baru, dan M peubah baru ini kemudian diregresikan dengan peubah tak bebas Y atau dapat disebut dengan regresi komponen utama.

Tahap-tahap yang dilakukan dalam analisis komponen utama ini dimulai dari prosedur seleksi akar eigen, Jika K peubah bebas tidak menghadapi masalah perbedaan dalam skala pengukuran maka akar eigen diperoleh dari suatu persamaan $|\sum - \lambda I| = 0$ dengan \sum adalah matriks peragam atau matriks varian-covarian. Matriks peragam dapat dirumuskan sebagai berikut:

$$\sum = \frac{1}{n} \begin{bmatrix} X_{11} - \bar{X}_1 & \dots & X_{1k} - \bar{X}_1 \\ \vdots & \ddots & \vdots \\ \vdots & \dots & \vdots \\ \vdots & \vdots & \vdots \\ X_{k1} - \bar{X}_k & \dots & X_{kn} - \bar{X}_k \end{bmatrix}^T \begin{bmatrix} X_{11} - \bar{X}_1 & \dots & X_{1k} - \bar{X}_1 \\ \vdots & \ddots & \vdots \\ \vdots & \dots & \vdots \\ \vdots & \vdots & \vdots \\ X_{k1} - \bar{X}_k & \dots & X_{kn} - \bar{X}_k \end{bmatrix}$$

Jika K peubah bebas menghadapi masalah perbedaan dalam skala pengukuran maka akar eigen diperoleh dari suatu persamaan $|\mathbf{R} - \lambda \mathbf{I}| = 0$, dengan

$\mathbf{R} = \frac{1}{n-1} \mathbf{Z}^T \mathbf{Z}$ dan \mathbf{Z} adalah matriks \mathbf{X} yang dibakukan dengan persamaan.

$$Z_{ji} = \frac{(X_{ji} - \bar{X}_j)}{S_j} \quad \dots (2.16)$$

dengan

Z = peubah baku

X = peubah bebas

\bar{X} = nilai rata-rata peubah bebas

S = simpangan baku peubah bebas X

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

$j = 1, 2, \dots, k$.

Jika akar eigen λ diurut dari nilai terbesar sampai nilai terkecil, maka pengaruh komponen utama W_i berpadanan dengan mengurut λ_i . Ini berarti komponen-komponen tersebut menerangkan proporsi keragaman terhadap peubah W_i yang semakin lama semakin kecil. Menurut Gaspersz (1992), dengan menggunakan kriteria Kaiser dipilih komponen utama dengan akar eigen yang lebih besar dari satu. Vektor eigen \mathbf{V}_i diperoleh dari setiap akar eigen λ_i yang memenuhi suatu persamaan:

$$\left(\sum -\lambda \mathbf{I} \right) \mathbf{V}_i = \mathbf{0} \text{ atau } (\mathbf{R} - \lambda_i \mathbf{I}) \mathbf{V}_i = \mathbf{0}$$

dengan

$$\mathbf{V}_i = (V_{1i}, V_{2i}, \dots, V_{ki}) \text{ dan } \mathbf{V}_i^T \mathbf{V}_i = 1. \quad \dots (2.17)$$

Dari persamaan (2.16) dan persamaan (2.17) komponen utama W_i dapat dirumuskan:

$$W_i = V_{1i}Z_1 + V_{2i}Z_2 + \dots + V_{ki}Z_k. \quad \dots (2.18)$$

Dengan demikian $W_1, W_2, W_3, \dots, W_m$ sebagai banyaknya komponen utama yang dilibatkan dalam analisis regresi dan komponen-komponen utama ini saling ortogonal sesamanya.

Tahap selanjutnya adalah meregresikan komponen utama $W_1, W_2, W_3, \dots, W_m$ dengan peubah tak bebas Y , maka model regresi komponen utama dapat dirumuskan sebagai berikut:

$$Y_i = \hat{a}_0 + \hat{a}_1 W_1 + \hat{a}_2 W_2 + \dots + \hat{a}_m W_m + \varepsilon_i. \quad \dots (2.19)$$

Model persamaan regresi (2.19) identik dengan model persamaan regresi (2.1), dan dapat ditulis dalam bentuk matriks sebagai berikut:

$$\mathbf{Y} = \hat{\mathbf{a}}\mathbf{W} + \boldsymbol{\varepsilon}. \quad \dots (2.20)$$

Persamaan (2.20) identik dengan persamaan (2.3) maka taksiran parameternya adalah:

$$\hat{\mathbf{a}} = (\mathbf{W}^T \mathbf{W})^{-1} \mathbf{W}^T \mathbf{Y} \quad \text{dan} \quad \text{var}(\hat{\mathbf{a}}) = (\mathbf{W}^T \mathbf{W})^{-1} \boldsymbol{\sigma}^2. \quad \dots(2.21)$$

Persamaan regresi komponen utama (2.19) dengan peubah bebas W_i dapat ditransformasikan ke peubah baku Z sebagai berikut:

$$Y = \hat{b}_0 + \hat{b}_1 Z_1 + \hat{b}_2 Z_2 + \dots + \hat{b}_k Z_k. \quad \dots(2.22)$$

Untuk menghitung nilai \hat{b} substitusikan persamaan (2.18) ke persamaan (2.19)

$$\begin{aligned} Y &= \hat{a}_0 + \hat{a}_1 (V_{11}Z_1 + V_{21}Z_2 + \dots + V_{k1}Z_k) + \hat{a}_2 (V_{12}Z_1 + V_{22}Z_2 + \dots + V_{k2}Z_k) \\ &\quad + \dots + \hat{a}_m (V_{1m}Z_1 + V_{2m}Z_2 + \dots + V_{km}Z_k) \\ &= \hat{a}_0 + (\hat{a}_1 V_{11} + \hat{a}_2 V_{12} + \dots + \hat{a}_m V_{1m})Z_1 + (\hat{a}_1 V_{21} + \hat{a}_2 V_{22} + \dots + \hat{a}_m V_{2m})Z_2 \\ &\quad + \dots + (\hat{a}_1 V_{k1} + \hat{a}_2 V_{k2} + \dots + \hat{a}_m V_{km})Z_k, \end{aligned}$$

diperoleh:

$$\hat{b}_0 = \hat{a}_0$$

$$\hat{b}_1 = \hat{a}_1 V_{11} + \hat{a}_2 V_{12} + \dots + \hat{a}_m V_{1m}$$

$$\hat{b}_2 = \hat{a}_2 V_{21} + \hat{a}_2 V_{22} + \dots + \hat{a}_m V_{2m}$$

$$\dots$$

$$\hat{b}_k = \hat{a}_1 V_{k1} + \hat{a}_2 V_{k2} + \dots + \hat{a}_m V_{km}$$

$$\begin{aligned} \text{var}(\hat{b}) &= \text{var}(\hat{a}_1 V_{11} + \hat{a}_2 V_{12} + \dots + \hat{a}_m V_{km}) \\ &= V_{11}^2 \text{var}(\hat{a}_1) + V_{12}^2 \text{var}(\hat{a}_2) + \dots + V_{km}^2 \text{var}(\hat{a}_m) \quad \dots(2.23) \end{aligned}$$

$$i = 1, 2, 3, \dots, k.$$

Untuk membandingkan hasil taksiran koefisien regresi yang menggunakan analisis komponen utama dengan koefisien regresi yang menggunakan metode kuadrat terkecil secara langsung, persamaan model regresi dengan peubah baku Z (2.22) ditransformasi ke peubah asal X :

$$Y = \hat{\beta}_0 + \hat{\beta}_1 X_1 + \hat{\beta}_2 X_2 + \dots + \hat{\beta}_k X_k. \quad \dots(2.24)$$

Untuk menghitung nilai $\hat{\beta}_i$ substitusikan persamaan (2.16) ke persamaan (2.22)

$$Y = \hat{b}_0 + \hat{b}_1 \left(\frac{X_1 - \bar{X}_1}{S_1} \right) + \hat{b}_2 \left(\frac{X_2 - \bar{X}_2}{S_2} \right) + \dots + \hat{b}_k \left(\frac{X_k - \bar{X}_k}{S_k} \right)$$

$$Y = \hat{b}_0 - \left(\hat{b}_1 \frac{\bar{X}_1}{S_1} + \hat{b}_2 \frac{\bar{X}_2}{S_2} + \dots + \hat{b}_k \frac{\bar{X}_k}{S_k} \right) + \frac{\hat{b}_1}{S_1} X_1 + \frac{\hat{b}_2}{S_2} X_2 + \dots + \frac{\hat{b}_k}{S_k} X_k,$$

diperoleh:

$$\begin{aligned}\hat{\beta}_0 &= \hat{b}_0 - \left(\hat{b}_1 \frac{\bar{X}_1}{S_1} + \hat{b}_2 \frac{\bar{X}_2}{S_2} + \dots + \hat{b}_k \frac{\bar{X}_k}{S_k} \right) \\ \hat{\beta}_1 &= \frac{\hat{b}_1}{S_1} \\ \hat{\beta}_2 &= \frac{\hat{b}_2}{S_2} \\ &\dots \\ \hat{\beta}_k &= \frac{\hat{b}_k}{S_k}\end{aligned} \quad \dots (2.25)$$

$\text{var}(\hat{\beta}_i)$ sama dengan $\text{var}(\hat{b}_i)$ pada persamaan (2.23).

Pengujian hipotesis terhadap koefisien regresi parsial komponen utama pada persamaan (2.21) baik secara keseluruhan atau individual digunakan rumus seperti dalam sub bab 2.5.



MILIK UPT PERPUSTAKAAN
UNIVERSITAS JEMBER

BAB III METODOLOGI

3.1 Sumber Data

Sumber data yang digunakan dalam penelitian ini ada dua, yaitu data simulasi dan data riil.

3.1.1 Data simulasi

Data simulasi dibangkitkan melalui komputer menggunakan program statistika S-plus versi 4.5 dengan peubah tak bebas Y dan peubah bebas $X_1, X_2, X_3, \dots, X_k$. Data simulasi diasumsikan berdistribusi normal dan terjadi multikolinieritas pada peubah bebas. Prosedur simulasi :

1. menentukan nilai parameter $\beta = (\beta_0, \beta_1, \beta_2, \beta_3, \dots, \beta_k)$;
2. membangkitkan peubah bebas $X_1, X_2, X_3, \dots, X_k$ yang berkorelasi;

Untuk membangkitkan data ini $X_3 = \alpha X_2 + \delta$, dalam penelitian ini jenis peubah bebas yang dibangkitkan ada tiga:

- a. membangkitkan peubah bebas yang memiliki hubungan diantara dua peubah yang sempurna. Untuk membangkitkan data ini $\delta = 0$;
 - b. membangkitkan peubah bebas yang memiliki hubungan diantara dua peubah yang kuat. Untuk membangkitkan data ini $\delta \sim N(0,0.4)$;
 - c. membangkitkan peubah bebas yang memiliki hubungan diantara dua peubah yang sedang. Untuk membangkitkan data ini $\delta \sim N(0,3.3)$.
3. menentukan nilai mean:

$$\mu = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \dots + \beta_k X_{ki};$$

4. membangkitkan peubah tak bebas Y :

$$Y = rnorm(n, \mu, \sigma^2).$$

3.1.2 Data Riil

Untuk data riil dalam penelitian ini diambil dari skripsi Tinuk Fitrias yang berjudul “Faktor-Faktor Sosial Ekonomi Terhadap Pendapatan Petani Pisang Kuba” Fakultas Pertanian Jurusan Sosial Ekonomi Pertanian. Penelitian ini dilakukan di kecamatan Ajung Kabupaten Jember.

Adapun peubah yang digunakan dalam analisis adalah:

- peubah tak bebas (Y):

pendapatan;

- peubah bebas (X):

$X_1 = \text{umur}$

$X_2 = \text{pendidikan formal}$

$X_3 = \text{jumlah anggota keluarga}$

$X_4 = \text{luas lahan}$

$X_5 = \text{biaya produksi}$

$X_6 = \text{produksi}$

$X_7 = \text{harga jual.}$

3.2 Analisis Data Simulasi

Untuk mengolah data simulasi digunakan program SPSS versi 10.00, sedangkan untuk mencari vektor eigen digunakan program S-plus versi 4.5. Adapun langkah-langkah yang digunakan adalah sebagai berikut:

1. menganalisis semua data dengan metode kuadrat terkecil, pendekstrian multikolinieritas dengan memeriksa matriks korelasi dan menghitung besarnya multikolinieritas dengan *Variance Inflation Factor* (VIF).
2. penerapan metode analisis komponen utama.
 - menentukan peubah Z hasil pembakuan dari peubah X ;
 - menentukan nilai akar eigen dengan persamaan :
$$|R - \lambda I| = 0;$$
 - menentukan nilai vektor eigen dengan persamaan:
$$(R - \lambda I)V_i = 0;$$

- menentukan komponen utama W_i melalui kombinasi linier antara vektor eigen dan peubah baku Z :

$$W_i = V_{1i}Z_1 + V_{2i}Z_2 + \dots + V_{ki}Z_k ;$$

- meregresikan W_i terpilih berdasarkan keragamannya dengan peubah tak bebas Y sehingga didapat persamaan model regresi komponen utama:

$$Y_i = \hat{a}_0 + \hat{a}_1 W_1 + \hat{a}_2 W_2 + \dots + \hat{a}_m W_m + \varepsilon_i ;$$

- menentukan nilai koefisien regresi (\hat{a});
- menentukan JKG , JKT , JKR serta R^2 ;
- menguji koefisien regresi (\hat{a}) baik secara keseluruhan atau individual dengan menggunakan rumus seperti dalam sub bab 2.5 ;
- mentransformasi persamaan regresi dengan peubah bebas W_i ke peubah baku Z ;
- mentransformasi persamaan regresi dengan peubah baku Z ke peubah bebas X .

3.3 Perbandingan Nilai Koefisien Regresi pada Data Simulasi

Membandingkan nilai taksiran koefisien regresi ($\hat{\beta}$) yang mengabaikan multikolinieritas pada persamaan (2.1) dengan koefisien regresi ($\hat{\beta}$) yang menggunakan analisis komponen utama pada persamaan (2.25).

3.4 Analisis Data Riil

Untuk mengolah data riil digunakan program SPSS versi 10.00 dan untuk mencari vektor eigen digunakan program S-plus versi 4.5. Adapun langkah-langkah yang digunakan dalam analisa data riil sama seperti dalam sub bab 3.2.

DAFTAR PUSTAKA

- Draper N dan Smith H, (1992), *Analisis Regresi Terapan (Terjemahan)*, Edisi ke-2, Alih Bahasa Bambang Sumantri, Penerbit PT Gramedia Pustaka Utama Jakarta.
- Gaspersz V, (1991), *Ekonometrika Terapan 1*, Bandung, Penerbit Tarsito Bandung.
- Gaspersz V, (1991), *Ekonometrika Terapan 2*, Bandung, Penerbit Tarsito Bandung.
- Gujarati D, (1992), *Ekonometrika Dasar (Terjemahan)*, Edisi Ke-3, Alih Bahasa Zeinn, S, Penerbit Erlangga, Jakarta.
- Mattjik, A. A, dkk, (2002), *Aplikasi Analisis Peubah Ganda*, PKSDM Dikti Depdiknas, Jurusan Statistika, FMIPA, IPB, Bogor.
- Montgomery D. C & Peck E. A, (1991), *Introduction to Linear Regression Analysis*, New York: Jhon Willey & Sons, 2nd edition.
- Netty S dan Linggawati H, (1988), *Teori Inferensi Statistik*, Penerbit Karunia Jakarta, Universitas Terbuka.
- Sembiring RK, (1995), *Analisis Regresi*, Bandung, Penerbit ITB Bandung.
- Sugiarto, 1992, *Tahap Awal & Aplikasi Analisis Regresi*, Edisi Pertama, Andi Offset, Yogyakarta.

Lampiran 1
Data Simulasi 1 (Korelasi Sempurna)

```

n_20
k_4
x_matrix(1,n,k+1)
x[,2]_(abs(round(rnorm(n,10,1.9))))
epsilon_rnorm(n,0,0.5)
x[,3]_2*x[,2]
x[,4]_(abs(round(rnorm(n,15,1))))
x[,5]_(abs(round(rnorm(n,20,1.3))))
beta_matrix(0,k+1,1)
beta[,1]_c(1,4,3,2,1.7)
print(beta)
myu_x%*%beta
y_matrix(0,n,1)
y[,1]_(rnorm(n,myu,1.4))
print(x)
print(y)
beta.hat_solve(t(x)%*%x)%*%t(x)%*%y
print(beta.hat)

```

```

> n <- 20
> k <- 4
> x <- matrix(1, n, k + 1)
> x[, 2] <- (abs(round(rnorm(n, 10, 1.9))))
> epsilon <- rnorm(n, 0, 0.5)
> x[, 3] <- 2 * x[, 2]
> x[, 4] <- (abs(round(rnorm(n, 15, 1))))
> x[, 5] <- (abs(round(rnorm(n, 20, 1.3))))
> beta <- matrix(0, k + 1, 1)
> beta[, 1] <- c(1, 4, 3, 2, 1.7)
> print(beta)
[1]
[1,] 1.0
[2,] 4.0
[3,] 3.0
[4,] 2.0
[5,] 1.7
> myu <- x %*% beta
> y <- matrix(0, n, 1)
> y[, 1] <- (rnorm(n, myu, 1.4))

```

```

> print(x)
      [,1] [,2] [,3] [,4] [,5]
[1,] 1 9 18 14 18
[2,] 1 11 22 15 21
[3,] 1 7 14 16 22
[4,] 1 11 22 15 20
[5,] 1 10 20 15 17
[6,] 1 12 24 16 21
[7,] 1 9 18 15 20
[8,] 1 7 14 15 18
[9,] 1 7 14 14 22
[10,] 1 10 20 15 20
[11,] 1 10 20 16 20
[12,] 1 11 22 15 17
[13,] 1 8 16 15 17
[14,] 1 10 20 14 15
[15,] 1 8 16 14 21
[16,] 1 11 22 15 21
[17,] 1 12 24 17 21
[18,] 1 14 28 15 22
[19,] 1 9 18 14 19
[20,] 1 13 26 17 20

> print(y)
      [,1]
[1,] 151.9710
[2,] 174.9030
[3,] 139.5221
[4,] 173.2747
[5,] 162.1103
[6,] 187.9148
[7,] 153.1945
[8,] 132.4551
[9,] 135.3377
[10,] 166.3559
[11,] 168.1870
[12,] 170.8161
[13,] 138.4357
[14,] 154.5812
[15,] 146.2289
[16,] 175.4626
[17,] 189.1343
[18,] 207.7725
[19,] 152.4655
[20,] 202.2734

> beta.hat <- solve(t(x) %*% x) %*% t(x) %*% y
Error in solve.qr(a): apparently singular matrix

```

Lampiran 2
Analisa Data 1

Factor Analysis

	ZX1	ZX2	ZX3	ZX4
	-0.47832	-0.47832	-1.20626	-0.80639
	0.52866	0.52866	-0.10966	0.70559
	-1.4853	-1.4853	0.98694	1.20959
	0.52866	0.52866	-0.10966	0.2016
	0.02517	0.02517	-0.10966	-1.31039
	1.03215	1.03215	0.98694	0.70559
	-0.47832	-0.47832	-0.10966	0.2016
	-1.4853	-1.4853	-0.10966	-0.80639
	-1.4853	-1.4853	-1.20626	1.20959
	0.02517	0.02517	-0.10966	0.2016
	0.02517	0.02517	0.98694	0.2016
	0.52866	0.52866	-0.10966	-1.31039
	-0.98181	-0.98181	-0.10966	-1.31039
	0.02517	0.02517	-1.20626	-2.31838
	-0.98181	-0.98181	-1.20626	0.70559
	0.52866	0.52866	-0.10966	0.70559
	1.03215	1.03215	2.08354	0.70559
	2.03914	2.03914	-0.10966	1.20959
	-0.47832	-0.47832	-1.20626	-0.3024
	1.53564	1.53564	2.08354	0.2016

Descriptive Statistics

	N	Minimum	Maximum	Mean	Std. Deviation
Y	20	132.4551	207.7725	164.1198	21.5967613
X1	20	7	14	9.95	1.986
X2	20	14	28	19.90	3.972
X3	20	14	17	15.10	.912
X4	20	15	22	19.60	1.984
Valid N (listwise)	20				

Correlation Matrix ^a

	Zscore(X1)	Zscore(X2)	Zscore(X3)	Zscore(X4)
Correlation	1.000	1.000	.468	.155
	1.000	1.000	.468	.155
	.468	.468	1.000	.314
	.155	.155	.314	1.000

a. This matrix is not positive definite.

Vektor Eigen

```
>Sempurna_matrix(c(1,1,0.468,0.155,1,1,0.468,0.155,0.468,0.468,1,0.314,0.155,0.155,0.314,1),4,4)
```

```
> eigen(Sempurna)
```

```
$values:
```

[1] 2.4107072 1.0125374 0.5767554 0.0000000

\$vectors:

	[,1]	[,2]	[,3]	[,4]
[1,]	0.6073152	-0.2842193	-0.224472	0.7071068
[2,]	0.6073152	-0.2842193	-0.224472	-0.7071068
[3,]	0.4552095	0.3149289	0.832829	0.0000000
[4,]	0.2347783	0.8598015	-0.453454	0.0000000

Total Variance Explained

Component	Initial Eigenvalues			Extraction Sums of Squared Loadings		
	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %
1	2.411	60.263	60.263	2.411	60.263	60.263
2	1.013	25.319	85.582	1.013	25.319	85.582
3	.577	14.418	100.000			
4	.000	.000	100.000			

Extraction Method: Principal Component Analysis.

Component Matrix ^a

	Component	
	1	2
Zscore(X1)	.943	-.286
Zscore(X2)	.943	-.286
Zscore(X3)	.707	.317
Zscore(X4)	.365	.865

Extraction Method: Principal Component Analysis.

a. 2 components extracted.

Ku. 1	Ku. 2
-0.84979	-0.79647
0.48815	0.26964
-0.68975	2.18165
0.41193	-0.16087
-0.21061	-1.16789
1.20354	0.32872
-0.37587	0.40811
-1.3161	0.11607
-1.33273	1.49452
0.01803	0.12362
0.33952	0.46719
0.18329	-1.45238
-0.99841	-0.59892
-0.68454	-2.37246
-1.01504	0.77953
0.48815	0.26964
1.52503	0.67228
1.74606	-0.15332
-0.77358	-0.36596
1.84272	-0.04271

Regression

Variables Entered/Removed^b

Model	Variables Entered	Variables Removed	Method
1	REGR factor score 2 for analysis 1 , REGR factor score 1 for analysis 1		Enter

- a. All requested variables entered.
 b. Dependent Variable: Y

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.987 ^a	.974	.971	3.6765449

- a. Predictors: (Constant), REGR factor score 2 for analysis 1 , REGR factor score 1 for analysis 1

ANOVA^b

Model	Sum of Squares	df	Mean Square	F	Sig.
					.000 ^a
1	Regression	2	4316.097	319.309	
	Residual	17	13.517		
	Total	19			

- a. Predictors: (Constant), REGR factor score 2 for analysis 1 , REGR factor score 1 for analysis 1
 b. Dependent Variable: Y

Coefficients

Model	Unstandardized Coefficients		Beta	t	Sig.	Collinearity Statistics	
	B	Std. Error				Tolerance	VIF
1	(Constant)	164.120	.822	199.635	.000		
	REGR factor score 1 for analysis 1	21.144	.843	.979	25.068	.000	1.000
	REGR factor score 2 for analysis 1	-2.695	.843	-.125	-3.195	.005	1.000

- a. Dependent Variable: Y

Lampiran 3
Data Simulasi 2 (Korelasi Kuat)

```
n_20
k_4
x_matrix(1,n,k+1)
x[,2]_(abs(round(rnorm(n,10,1.9))))
epsilon_rnorm(n,0,0.4)
x[,3]_2*x[,2]+epsilon
x[,3]_(abs(round(x[,3])))
x[,4]_(abs(round(rnorm(n,15,1))))
x[,5]_(abs(round(rnorm(n,20,0.9))))
beta_matrix(0,k+1,1)
beta[,1]_c(1,4,3,2,1.7)
print(beta)
myu_x%*%beta
y_matrix(0,n,1)
y[,1]_(rnorm(n,myu,2))
print(x)
print(y)
beta.hat_solve(t(x)%*%x)%*%t(x)%*%y
print(beta.hat)
```

```
> n <- 20
> k <- 4
> x <- matrix(1, n, k + 1)
> x[, 2] <- (abs(round(rnorm(n, 10, 1.9))))
> epsilon <- rnorm(n, 0, 0.4)
> x[, 3] <- 2 * x[, 2] + epsilon
> x[, 3] <- (abs(round(x[, 3])))
> x[, 4] <- (abs(round(rnorm(n, 15, 1))))
> x[, 5] <- (abs(round(rnorm(n, 20, 0.9))))
> beta <- matrix(0, k + 1, 1)
> beta[, 1] <- c(1, 4, 3, 2, 1.7)
> print(beta)
[1]
[1,] 1.0
[2,] 4.0
[3,] 3.0
[4,] 2.0
[5,] 1.7
> myu <- x %*% beta
> y <- matrix(0, n, 1)
> y[, 1] <- (rnorm(n, myu, 2))
```

```
> print(x)
     [,1] [,2] [,3] [,4] [,5]
[1,]  1   10   20   15   20
[2,]  1    9   18   14   20
[3,]  1   11   22   16   20
[4,]  1    5   10   15   20
[5,]  1    7   14   16   21
[6,]  1   10   20   13   18
[7,]  1    8   16   16   21
[8,]  1   14   28   15   21
[9,]  1    9   18   15   20
[10,] 1   14   28   15   20
[11,] 1    9   18   16   19
[12,] 1    9   18   16   18
[13,] 1    7   13   15   20
[14,] 1   10   20   14   19
[15,] 1   13   26   15   20
[16,] 1   11   22   15   19
[17,] 1   10   20   14   19
[18,] 1    9   19   15   21
[19,] 1   12   24   16   18
[20,] 1   10   19   14   19
> print(y)
     [,1]
[1,] 163.9419
[2,] 153.8275
[3,] 177.3178
[4,] 114.7836
[5,] 139.7780
[6,] 159.5022
[7,] 146.7002
[8,] 207.5091
[9,] 157.1642
[10,] 203.3846
[11,] 156.5115
[12,] 153.2977
[13,] 129.9683
[14,] 162.2506
[15,] 196.6055
[16,] 172.6800
[17,] 164.9328
[18,] 156.4234
[19,] 185.5770
[20,] 155.5387
> beta.hat <- solve(t(x) %*% x) %*% t(x) %*% y
```

```
> print(beta.hat)
[1]
[1,] 16.136097
[2,] 2.185254
[3,] 3.944432
[4,] 1.844686
[5,] 1.020128
```

Lampiran 4
Analisa Data Simulasi 2

Regression

Variables Entered/Removed^b

Model	Variables Entered	Variables Removed	Method
1	X4, X2, X3, X1 ^a		Enter

a. All requested variables entered.

b. Dependent Variable: Y

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.997 ^a	.995	.994	1.8620519

a. Predictors: (Constant), X4, X2, X3, X1

ANOVA^b

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	10089.081	4	2522.270	727.458	.000 ^a
	Residual	52.009	15	3.467		
	Total	10141.090	19			

a. Predictors: (Constant), X4, X2, X3, X1

b. Dependent Variable: Y

Coefficients^a

Model	Unstandardized Coefficients		Beta	t	Sig.	Collinearity Statistics	
	B	Std. Error				Tolerance	VIF
1	(Constant)	16.136	11.071		1.457	.166	
	X1	2.185	2.297	.215	.951	.356	.007 149.952
	X2	3.944	1.131	.788	3.489	.003	.007 149.140
	X3	1.845	.518	.069	3.562	.003	.923 1.083
	X4	1.020	.459	.044	2.224	.042	.889 1.125

a. Dependent Variable: Y

Descriptive Statistics

	N	Minimum	Maximum	Mean	Std. Deviation
Y	20	114.7836	207.5091	162.8847	23.1028479
X1	20	5	14	9.85	2.277
X2	20	10	28	19.65	4.614
X3	20	13	16	15.00	.858
X4	20	18	21	19.65	.988
Valid N (listwise)	20				

Factor Analysis

ZX1	ZX2	ZX3	ZX4
0.06586	0.07585	0	0.35422
-0.37322	-0.35758	-1.16496	0.35422
0.50495	0.50928	1.16496	0.35422
-2.12956	-2.09131	0	0.35422
-1.25139	-1.22444	1.16496	1.36628
0.06586	0.07585	-2.32993	-1.66989
-0.81231	-0.79101	1.16496	1.36628
1.8222	1.80958	0	1.36628
-0.37322	-0.35758	0	0.35422
1.8222	1.80958	0	0.35422
-0.37322	-0.35758	1.16496	-0.65784
-0.37322	-0.35758	1.16496	-1.66989
-1.25139	-1.44116	0	0.35422
0.06586	0.07585	-1.16496	-0.65784
1.38312	1.37615	0	0.35422
0.50495	0.50928	0	-0.65784
0.06586	0.07585	-1.16496	-0.65784
-0.37322	-0.14087	0	1.36628
0.94403	0.94271	1.16496	-1.66989
0.06586	-0.14087	-1.16496	-0.65784

Correlation Matrix

	Zscore(X1)	Zscore(X2)	Zscore(X3)	Zscore(X4)	
Correlation	Zscore(X1)	1.000	.996	-.081	-.118
	Zscore(X2)	.996	1.000	-.066	-.098
	Zscore(X3)	-.081	-.066	1.000	.248
	Zscore(X4)	-.118	-.098	.248	1.000

Inverse of Correlation Matrix

	Zscore(X1)	Zscore(X2)	Zscore(X3)	Zscore(X4)
Zscore(X1)	149.952	-149.038	1.515	2.797
Zscore(X2)	-149.038	149.140	-1.460	-2.693
Zscore(X3)	1.515	-1.460	1.083	-.232
Zscore(X4)	2.797	-2.693	-.232	1.125

```
> Kuat_matrix(c(1,0.996,-0.081,-0.118,0.996,1,-0.066,-0.098,-0.081,-0.066,1,0.248,-0.118,-0.098,0.246,1),4,4)
> eigen(Kuat)
$values:
[1] 2.038357675 1.206885048 0.751033020 0.003724256
```

\$vectors:

	[,1]	[,2]	[,3]	[,4]
[1,]	0.7052340	0.2011452	-0.01185184	-0.706289749
[2,]	0.7022292	0.2301421	-0.01684319	0.704386337
[3,]	-0.1427633	0.9620531	0.50028783	-0.007658561
[4,]	-0.1805172	0.9295022	-0.51059193	-0.012459408

Total Variance Explained

Component	Initial Eigenvalues			Extraction Sums of Squared Loadings		
	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %
1	2.039	50.973	50.973	2.039	50.973	50.973
2	1.207	30.173	81.146	1.207	30.173	81.146
3	.751	18.770	99.916			
4	.348E-03	8.371E-02	100.000			

Extraction Method: Principal Component Analysis.

Component Matrix ^a

	Component	
	1	2
Zscore(X1)	.986	.162
Zscore(X2)	.982	.184
Zscore(X3)	-.200	.770
Zscore(X4)	-.252	.744

Extraction Method: Principal Component Analysis.

a. 2 components extracted.

Ku.1	Ku. 2
0.0246	0.23883
-0.28234	-0.62972
0.33154	1.10738
-2.08035	-0.38773
-1.47746	1.23007
0.50279	-2.49552
-1.05647	1.35538
1.58351	1.36402
-0.39639	0.11352
1.70855	0.74008
-0.38538	0.23281
-0.26034	-0.39112
-1.34272	-0.17021
0.26369	-1.12835
1.28757	0.61477
0.57064	-0.2598
0.26369	-1.12835
-0.41709	0.77056
1.00263	-0.01519
0.15934	-1.16145

Regression

Variables Entered/Removed^b

Model	Variables Entered	Variables Removed	Method
1	REGR factor score 2 for analysis 1 , REGR factor score 1 for analysis 1 ^a		Enter

a. All requested variables entered.

b. Dependent Variable: Y

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.997 ^a	.994	.994	1.8431240

a. Predictors: (Constant), REGR factor score 2 for analysis 1 , REGR factor score 1 for analysis 1

ANOVA^b

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	10083.339	2	5041.670	1484.107	.000 ^a
	Residual	57.751	17	3.397		
	Total	10141.090	19			

a. Predictors: (Constant), REGR factor score 2 for analysis 1 , REGR factor score 1 for analysis 1

b. Dependent Variable: Y

Coefficients

Model	Unstandardized Coefficients		Beta	t	Sig.	Collinearity Statistic	
	B	Std. Error				Tolerance	VIF
1	(Constant)	162.885	.412	395.222	.000		
	REGR factor s 1 for analysis	22.206	.423	.961	52.515	.000	1.000
	REGR factor s 2 for analysis	6.133	.423	.265	14.505	.000	1.000

a. Dependent Variable: Y

Lampiran 5
Data Simulasi 3 (Korelasi Sedang)

```
n_20
k_4
x_matrix(1,n,k+1)
x[,2]_(abs(round(rnorm(n,10,1.6))))
epsilon_rnorm(n,0,3.3)
x[,3]_2*x[,2]+epsilon
x[,3]_(abs(round(x[,3])))
x[,4]_(abs(round(rnorm(n,15,1))))
x[,5]_(abs(round(rnorm(n,20,1.2))))
beta_matrix(0,k+1,1)
beta[,1]_c(1,4,3,2,1.5)
print(beta)
myu_x%*%beta
y_matrix(0,n,1)
y[,1]_(rnorm(n,myu,0.9))
print(x)
print(y)
beta.hat_solve(t(x)%*%x)%*%t(x)%*%y
print(beta.hat)

> n <- 20
> k <- 4
> x <- matrix(1, n, k + 1)
> x[, 2] <- (abs(round(rnorm(n, 10, 1.6))))
> epsilon <- rnorm(n, 0, 3.3)
> x[, 3] <- 2 * x[, 2] + epsilon
> x[, 3] <- (abs(round(x[, 3])))
> x[, 4] <- (abs(round(rnorm(n, 15, 1))))
> x[, 5] <- (abs(round(rnorm(n, 20, 1.2))))
> beta <- matrix(0, k + 1, 1)
> beta[, 1] <- c(1, 4, 3, 2, 1.5)
> print(beta)
[1]
[1,] 1.0
[2,] 4.0
[3,] 3.0
[4,] 2.0
[5,] 1.5
> myu <- x %*% beta
> y <- matrix(0, n, 1)
> y[, 1] <- (rnorm(n, myu, 0.9))
> print(x)
```

```

[,1] [,2] [,3] [,4] [,5]
[1,] 1 9 21 16 22
[2,] 1 11 19 15 21
[3,] 1 9 16 15 20
[4,] 1 8 19 14 20
[5,] 1 11 24 15 20
[6,] 1 8 13 14 17
[7,] 1 12 23 15 18
[8,] 1 13 24 13 19
[9,] 1 7 19 16 20
[10,] 1 11 23 16 18
[11,] 1 9 19 16 21
[12,] 1 10 21 15 19
[13,] 1 8 17 16 20
[14,] 1 11 26 15 19
[15,] 1 10 19 15 19
[16,] 1 10 24 15 19
[17,] 1 8 19 16 20
[18,] 1 10 18 15 19
[19,] 1 12 26 18 23
[20,] 1 9 17 15 20
> print(y)
      [,1]
[1,] 163.5327
[2,] 163.0572
[3,] 143.5838
[4,] 148.0030
[5,] 177.4104
[6,] 127.7938
[7,] 176.9068
[8,] 179.6409
[9,] 147.1551
[10,] 173.5434
[11,] 157.9296
[12,] 162.7228
[13,] 143.9856
[14,] 181.6580
[15,] 156.0754
[16,] 170.6538
[17,] 151.2001
[18,] 153.1491
[19,] 197.9741
[20,] 147.2556
> beta.hat <- solve(t(x) %*% x) %*% t(x) %*% y

```

```
> print(beta.hat)
[1]
[1,] 3.963577
[2,] 4.309149
[3,] 2.960332
[4,] 2.191304
[5,] 1.081634
```

Lampiran 6
Analisa Data Simulasi 3

Regression

Variables Entered/Removed ^b

Model	Variables Entered	Variables Removed	Method
1	X4, X1, X3, X2 ^a	.	Enter

a. All requested variables entered.

b. Dependent Variable: Y

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.999 ^a	.998	.997	92844

a. Predictors: (Constant), X4, X1, X3, X2

ANOVA ^b

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	5350.674	4	1337.669	1551.815	.000 ^b
	Residual	12.930	15	.862		
	Total	5363.604	19			

a. Predictors: (Constant), X4, X1, X3, X2

b. Dependent Variable: Y

Coefficients^a

Model	Unstandardized Coefficients		Beta	t	Sig.	Collinearity Statistics	
	B	Std. Error				Tolerance	VIF
1	(Constant)	3.964	3.964	1.000	.333		
	X1	4.309	.208	.413	20.751	.000	.406
	X2	2.960	.098	.614	30.245	.000	.390
	X3	2.191	.280	.133	7.836	.000	.558
	X4	1.082	.197	.089	5.499	.000	.615

a. Dependent Variable: Y

Descriptive Statistics

	N	Minimum	Maximum	Mean	Std. Deviation
Y	20	127.7938	197.9741	161.1616	16.8016355
X1	20	7	13	9.80	1.609
X2	20	13	26	20.35	3.483
X3	20	13	18	15.25	1.020
X4	20	17	23	19.70	1.380
Valid N (listwise)	20				

Factor Analysis

	ZX1	ZX2	ZX3	ZX4
	-0.49715	0.1866	0.73562	1.66629
	0.74572	-0.38755	-0.24521	0.94182
	-0.49715	-1.24877	-0.24521	0.21734
	-1.11858	-0.38755	-1.22604	0.21734
	0.74572	1.04782	-0.24521	0.21734
	-1.11858	-2.11	-1.22604	-1.95608
	1.36715	0.76075	-0.24521	-1.2316
	1.98859	1.04782	-2.20687	-0.50713
	-1.74001	-0.38755	0.73562	0.21734
	0.74572	0.76075	0.73562	-1.2316
	-0.49715	-0.38755	0.73562	0.94182
	0.12429	0.1866	-0.24521	-0.50713
	-1.11858	-0.9617	0.73562	0.21734
	0.74572	1.62197	-0.24521	-0.50713
	0.12429	-0.38755	-0.24521	-0.50713
	0.12429	1.04782	-0.24521	-0.50713
	-1.11858	-0.38755	0.73562	0.21734
	0.12429	-0.67462	-0.24521	-0.50713
	1.36715	1.62197	2.69728	2.39076
	-0.49715	-0.9617	-0.24521	0.21734

Correlation Matrix

	Zscore(X1)	Zscore(X2)	Zscore(X3)	Zscore(X4)	
Correlation	Zscore(X1)	1.000	.727	-.096	-.028
	Zscore(X2)	.727	1.000	.211	.187
	Zscore(X3)	-.096	.211	1.000	.617
	Zscore(X4)	-.028	.187	.617	1.000

Inverse of Correlation Matrix

	Zscore(X1)	Zscore(X2)	Zscore(X3)	Zscore(X4)
Zscore(X1)	2.461	-1.928	.611	.054
Zscore(X2)	-1.928	2.562	-.641	-.139
Zscore(X3)	.611	-.641	1.792	-.968
Zscore(X4)	.054	-.139	-.968	1.625

VEKTOR EIGEN

```
> sedang_matrix(c(1,0.727,-0.096,-0.028,0.727,1,0.211,0.187,-0.096,0.211,1,0.617,-0.028,0.187,0.617,1),4,4)
> eigen(sedang)
```

\$values:

```
[1] 1.8348795 1.5589312 0.3942918 0.2118974
```

\$vectors:

	[,1]	[,2]	[,3]	[,4]
[1,]	0.4806412	-0.5506939	-0.1598630	0.6634487
[2,]	0.6255108	-0.3297512	0.1904785	-0.6809687
[3,]	0.4284522	0.5546298	0.6446702	0.3053113
[4,]	0.4406235	0.5295151	-0.7228846	-0.0538754

Total Variance Explained

Component	Initial Eigenvalues			Extraction Sums of Squared Loadings		
	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %
1	1.835	45.867	45.867	1.835	45.867	45.867
2	1.559	38.979	84.846	1.559	38.979	84.846
3	.394	9.854	94.700			
4	.212	5.300	100.000			

Extraction Method: Principal Component Analysis.

Component Matrix ^a

	Component	
	1	2
Zscore(X1)	.650	-.688
Zscore(X2)	.847	-.412
Zscore(X3)	.581	.692
Zscore(X4)	.597	.661

Extraction Method: Principal Component Analysis.

^a 2 components extracted.

Ku.1	Ku. 2
0.68543	1.20278
0.31434	0.06349
-0.75964	0.53287
-0.89284	0.14426
0.74119	-0.62295
-2.39575	-0.32145
0.35712	-1.43545
0.32459	-2.34934
-0.49188	1.28927
0.44748	-0.72577
0.18447	1.04754
-0.11256	-0.42794
-0.53674	1.16667
0.77039	-1.08174
-0.37765	-0.27616
0.28507	-0.6556
-0.27165	1.0149
-0.5102	-0.20028
2.86594	1.1779
-0.6271	0.45699

Regression

Model	Variables Entered/Removed		Method
	Variables Entered	Variables Removed	
1	REGR factor score 2 for analysis 1 , REGR factor score 1 for analysis 1		Enter

a. All requested variables entered.

b. Dependent Variable: Y

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.997 ^a	.993	.992	1.48181

a. Predictors: (Constant), REGR factor score 2 for analysis 1 , REGR factor score 1 for analysis 1

ANOVA^b

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	5326.276	2	2663.138	1212.860	.000 ^a
	Residual	37.328	17	2.196		
	Total	5363.604	19			

a. Predictors: (Constant), REGR factor score 2 for analysis 1 , REGR factor score 1 for analysis 1

b. Dependent Variable: Y

Coefficients^b

Model	Unstandardized Coefficients		Beta	t	Sig.	Collinearity Statistics	
	B	Std. Error				Tolerance	VIF
1	(Constant)	161.162	.331	486.390	.000		
	REGR factor score 1 for analysis 1	15.434	.340	.919	45.400	.000	1.000
	REGR factor score 2 for analysis 1	-6.491	.340	-.386	-19.094	.000	1.000

a. Dependent Variable: Y

Lampiran 7
Data Riil

X1	X2	X3	X4	X5	X6	X7	Y
40	9	5	1	1875000	16000	300	2925000
45	9	5	0.5	904000	8000	250	1096000
40	9	4	0.5	1163000	10000	300	1837000
38	6	2	0.5	1100000	10000	250	1400000
40	6	3	0.4	985000	8000	250	1015000
39	12	2	0.3	713500	6000	300	1086500
40	6	3	0.7	120000	12000	250	1800000
39	12	3	0.7	1334000	12000	300	2266000
42	6	4	0.5	968500	8000	250	1031500
38	12	4	0.4	857000	8000	250	1143000
37	9	3	0.2	444500	4000	300	755500
38	12	2	0.3	503000	6000	250	747000
43	12	4	0.5	1098500	10000	250	1401500
60	6	3	0.3	655000	6000	250	845000
60	6	5	1	2402000	20000	300	3598000
57	6	3	0.3	508000	5000	250	742000
46	6	3	0.6	120000	12000	300	2380000
46	6	3	0.7	1552500	14000	300	2647500
45	12	4	1	2031000	18000	300	3369000
39	12	3	0.5	891500	8000	300	1508500
67	6	5	0.4	940000	8000	300	1460000
50	9	3	0.3	696500	6000	300	1103500
44	9	5	0.5	1135000	10000	300	1865000
42	12	3	0.3	412500	4000	250	587500
43	9	2	0.5	1132500	10000	250	1367500
53	19	3	1.5	3505000	28000	300	4895000
40	6	3	0.3	561000	6000	300	1239000
46	12	2	1	2517000	20000	300	3583000
43	12	4	1	1471000	14000	250	2028000
48	6	5	0.6	1294000	12000	300	2306000

Lampiran 8
Analisa Data Riil

Regression

Variables Entered/Removed^b

Model	Variables Entered	Variables Removed	Method
1	X7, X2, X3, X1, ^a X4, X5, X6		Enter

a. All requested variables entered.

b. Dependent Variable: Y

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.997 ^a	.995	.993	85930.855

a. Predictors: (Constant), X7, X2, X3, X1, X4, X5, X6

ANOVA^b

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	3.10E+13	7	4.427E+12	599.589	.000 ^a
	Residual	1.62E+11	22	7384111925		
	Total	3.12E+13	29			

a. Predictors: (Constant), X7, X2, X3, X1, X4, X5, X6

b. Dependent Variable: Y

Coefficients^a

Model	Unstandardized Coefficients		Beta	t	Sig.	Collinearity Statistics	
	B	Std. Error				Tolerance	VIF
1	(Constant) -2569432	229244.0		-11.208	.000		
	X1 2184.803	2489.851	.016	.877	.390	.720	1.389
	X2 -351.210	6740.332	-.001	-.052	.959	.546	1.830
	X3 3179.504	19051.800	.003	.167	.869	.693	1.444
	X4 -773.683	274467.8	.000	-.003	.998	.038	26.665
	X5 -9.24E-02	.055	-.066	-1.688	.106	.155	6.450
	X6 181.659	17.035	.955	10.664	.000	.030	33.836
	X7 8758.064	730.739	.213	11.985	.000	.751	1.332

a. Dependent Variable: Y

Descriptive Statistics

	N	Minimum	Maximum	Mean	Std. Deviation
X1	30	37	67	44.93	7.552
X2	30	6	19	9.13	3.203
X3	30	2	5	3.43	1.006
X4	30	.2	1.5	.577	.3002
X5	30	120000	3505000	1129683	740384.738
X6	30	4000	28000	10633.33	5448.716
X7	30	250	300	278.33	25.200
Y	30	587500	4895000	1800950	1036480.553
Valid N (listwise)	30				

Factor Analysis

ZX1	ZX2	ZX3	ZX4	ZX5	ZX6	ZX7
-0.65326	-0.04163	1.55686	1.41012	1.00666	0.98494	0.85978
0.00883	-0.04163	1.55686	-0.25538	-0.30482	-0.48329	-1.12432
-0.65326	-0.04163	0.56312	-0.25538	0.045	-0.11624	0.85978
-0.9181	-0.97833	-1.42436	-0.25538	-0.04009	-0.11624	-1.12432
-0.65326	-0.97833	-0.43062	-0.58848	-0.19542	-0.48329	-1.12432
-0.78568	0.89507	-1.42436	-0.92158	-0.56212	-0.85035	0.85978
-0.65326	-0.97833	-0.43062	0.41082	-1.36373	0.25082	-1.12432
-0.78568	0.89507	-0.43062	0.41082	0.27596	0.25082	0.85978
-0.38843	-0.97833	0.56312	-0.25538	-0.2177	-0.48329	-1.12432
-0.9181	0.89507	0.56312	-0.58848	-0.3683	-0.48329	-1.12432
-1.05052	-0.04163	-0.43062	-1.25467	-0.92544	-1.21741	0.85978
-0.9181	0.89507	-1.42436	-0.92158	-0.84643	-0.85035	-1.12432
-0.25601	0.89507	0.56312	-0.25538	-0.04212	-0.11624	-1.12432
1.99511	-0.97833	-0.43062	-0.92158	-0.64113	-0.85035	-1.12432
1.99511	-0.97833	1.55686	1.41012	1.71845	1.71906	0.85978
1.59785	-0.97833	-0.43062	-0.92158	-0.83968	-1.03388	-1.12432
0.14125	-0.97833	-0.43062	0.07772	-1.36373	0.25082	0.85978
0.14125	-0.97833	-0.43062	0.41082	0.57108	0.61788	0.85978
0.00883	0.89507	0.56312	1.41012	1.21736	1.352	0.85978
-0.78568	0.89507	-0.43062	-0.25538	-0.3217	-0.48329	0.85978
2.92204	-0.97833	1.55686	-0.58848	-0.2562	-0.48329	0.85978
0.67092	-0.04163	-0.43062	-0.92158	-0.58508	-0.85035	0.85978
-0.12359	-0.04163	1.55686	-0.25538	0.00718	-0.11624	0.85978
-0.38843	0.89507	-0.43062	-0.92158	-0.96866	-1.21741	-1.12432
-0.25601	-0.04163	-1.42436	-0.25538	0.0038	-0.11624	-1.12432
1.06818	3.08071	-0.43062	3.07562	3.20822	3.1873	0.85978
-0.65326	-0.97833	-0.43062	-0.92158	-0.76809	-0.85035	0.85978
0.14125	0.89507	-1.42436	1.41012	1.87378	1.71906	0.85978
-0.25601	0.89507	0.56312	1.41012	0.461	0.61788	-1.12432
0.40608	-0.97833	1.55686	0.07772	0.22193	0.25082	0.85978

Correlation Matrix

	Zscore(X1)	Zscore(X2)	Zscore(X3)	Zscore(X4)	Zscore(X5)	Zscore(X6)	Zscore(X7)	
Correlation	Zscore(X1)	1.000	.236	.322	.156	.246	.212	.137
	Zscore(X2)		1.000	-.179	.423	.471	.380	.101
	Zscore(X3)			1.000	.206	.187	.162	.179
	Zscore(X4)				1.000	.865	.973	.296
	Zscore(X5)					1.000	.896	.367
	Zscore(X6)						1.000	.367
	Zscore(X7)							1.000

Inverse of Correlation Matrix

	Zscore(X1)	Zscore(X2)	Zscore(X3)	Zscore(X4)	Zscore(X5)	Zscore(X6)	Zscore(X7)
Zscore(X1)	1.389	.434	-.347	1.210	-.582	-1.090	.084
Zscore(X2)	.434	1.830	.508	-2.162	-1.497	2.613	-.107
Zscore(X3)	-.347	.508	1.444	-2.546	-.572	2.749	-.309
Zscore(X4)	1.210	-2.162	-2.546	26.665	2.165	-27.625	1.975
Zscore(X5)	-.582	-1.497	-.572	2.165	6.450	-7.073	-.077
Zscore(X6)	-1.090	2.613	2.749	-27.625	-7.073	33.836	-.2268
Zscore(X7)	.084	-.107	-.309	1.975	-.077	-2.268	1.332

Vektor Eigen

```
> RiiL_matrix(c(1,-0.236,0.322,0.156,0.246,0.212,0.137,-0.236,1,-0.179,0.423,0.471,0.380,0.101,0.322,-0.179,1,0.206,0.187,0.162,0.179,0.156,0.423,0.206,1,0.865,0.973,0.296,0.246,0.471,0.187,0.865,1,0.896,0.368,0.212,0.380,0.162,0.973,0.896,1,0.367,0.137,0.101,0.179,0.296,0.367,0.367,1),7,7)
```

> eigen(RiiL)

\$values:

```
[1] 3.32493236 1.51780202 0.81772486 0.68632241 0.50648096 0.13018659 0.01655081
```

\$vectors:

[,1]	[,2]	[,3]	[,4]	[,5]	[,6]	[,7]
[1,] 0.3055253	0.64295789	-0.302771953	0.43130823	-0.313923769	0.124869605	-0.02245705
[2,] 0.5688439	-0.58260485	-0.004316195	-0.12324561	-0.522765507	0.153880987	0.05363519
[3,] 0.3019417	0.61338843	0.003089598	-0.61014652	-0.123511478	0.002524521	0.05699342
[4,] 1.0883104	-0.06391110	-0.174575028	-0.05092934	0.195147927	0.412928311	-0.55985148
[5,] 1.0893080	-0.03960732	-0.103173214	0.04059354	0.006444685	-0.782604693	-0.10977457
[6,] 1.1041597	-0.03329854	-0.114724336	0.05141944	0.211196811	0.221130668	0.64501865
[7,] 0.5512374	0.18023284	0.949709508	0.13976305	-0.039976640	0.059226250	-0.04387733

Total Variance Explained

Component	Initial Eigenvalues			Extraction Sums of Squared Loadings		
	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %
1	3.325	47.497	47.497	3.325	47.497	47.497
2	1.518	21.682	69.179	1.518	21.682	69.179
3	.818	11.685	80.864			
4	.687	9.811	90.674			
5	.506	7.229	97.903			
6	.130	1.857	99.760			
7	1.677E-02	240	100.000			

Extraction Method: Principal Component Analysis.

Component Matrix ^a

	Component	
	1	2
Zscore(X1)	.265	.733
Zscore(X2)	.495	-.664
Zscore(X3)	.262	.699
Zscore(X4)	.946	-7.28E-02
Zscore(X5)	.947	-4.51E-02
Zscore(X6)	.960	-3.77E-02
Zscore(X7)	.479	.206

Extraction Method: Principal Component Analysis.

a. 2 components extracted.

Ku. 1	Ku. 2
1.16028	0.41425
-0.34349	0.6203
0.01644	0.09246
-0.61061	-0.8072
-0.75603	-0.192
-0.58583	-1.22835
-0.59259	-0.2234
0.42807	-0.88692
-0.56811	0.37818
-0.46934	-0.67691
-0.97212	-0.45282
-0.96295	-1.55282
-0.12289	-0.39202
-0.87223	1.1251
1.64698	2.06349
-1.01346	0.94375
-0.33832	0.44519
0.41337	0.36254
1.44007	-0.14896
-0.14354	-0.81896
-0.04558	2.72033
-0.53706	0.34315
0.12633	0.80695
-0.98306	-0.82671
-0.4059	-0.89871
3.34188	-1.23617
-0.83424	0.11912
1.58678	-1.02889
0.70604	-0.50508
0.29113	1.44112

Regression

Variables Entered/Removed^b

Model	Variables Entered	Variables Removed	Method
1	REGR factor score 2 for analysis 1 , REGR factor score 1 for analysis 1		Enter

a. All requested variables entered.

b. Dependent Variable: Y

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	.961 ^a	.923	.917	298741.330

a. Predictors: (Constant), REGR factor score 2 for analysis 1 , REGR factor score 1 for analysis 1

ANOVA^b

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	2.87E+13	2	1.437E+13	161.042	.000 ^a
	Residual	2.41E+12	27	8.925E+10		
	Total	3.12E+13	29			

a. Predictors: (Constant), REGR factor score 2 for analysis 1 , REGR factor score 1 for analysis 1

b. Dependent Variable: Y

Coefficients^b

Model	Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
	B	Std. Error	Beta			Tolerance	VIF
1	(Constant)	1800950	4542.455		.33.019	.000	
	REGR factor score 1 for analysis 1	995243.7	5474.872	.960	17.940	.000	1.000
	REGR factor score 2 for analysis 1	6274.815	5474.872	.025	.474	.640	1.000

a. Dependent Variable: Y

