



***BOOTSTRAP DALAM STRUCTURAL EQUATION  
MODELING (SEM) UNTUK MENGATASI ASUMSI  
NON-NORMAL MULTIVARIAT***

skripsi

disajikan sebagai salah satu syarat  
untuk memperoleh gelar Sarjana Sains

Prodi Matematika

oleh

Ita Ferawati

4150406502

**JURUSAN MATEMATIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS NEGERI SEMARANG**

**2010**

## PERSETUJUAN PEMBIMBING

Skripsi dengan judul “*Bootstrap dalam Structural Equation Modeling (SEM)* untuk Mengatasi Asumsi Non-normal Multivariat” telah disetujui oleh dosen pembimbing untuk diajukan di sidang panitia ujian skripsi

Hari : Rabu  
Tanggal : 15 September 2010

Menyetujui,

Pembimbing 1

Pembimbing 2

Prof. Dr. YL. Sukestiyarno, MS  
NIP. 195904201984031002

Endang S., S.Si, M.Kom  
NIP. 197401071999032001

Mengetahui,

Ketua Jurusan Matematika

PERPUSTAKAAN  
UNNES

Drs. Edy Soedjoko, M.Pd  
NIP. 195604191987031001

## PENGESAHAN

Skripsi dengan judul “*Bootstrap dalam Structural Equation Modeling (SEM)* untuk Mengatasi Asumsi Non-normal Multivariat”

telah dipertahankan di hadapan sidang Panitia Ujian Skripsi FMIPA UNNES pada tanggal September 2010.

Panitia:

Ketua

Sekretaris

Dr. Kasmadi Imam S., M.S  
195111151979031001

Drs. Edy Soedjoko, M.Pd  
195604191987031001

Penguji

Dr. Scolastika Mariani, M.Si  
196502101991022001

Penguji/Pembimbing 1

Penguji/Pembimbing 2

Prof. Dr. YL. Sukestiyarno, MS  
195904201984031002

Endang S., S.Si, M.Kom  
197401071999032001

## MOTTO DAN PERSEMBAHAN

### MOTTO

- ❖ *“ Dia-lah (Allah yang disembah), baik di langit maupun di bumi, Dia mengetahui apa yang kamu rahasiakan dan apa yang kamu lahirkan dan mengetahui (pula) apa yang kamu usahakan.” (QS. Al An’am: 3)*
- ❖ *“ Jika kita ingin melihat pelangi yang indah, kita harus bersabar menanti redanya hujan.” (Promod Brata)*
- ❖ *“Di dalam setiap usaha tidak selamanya menghasilkan sesuatu yang baik, namun ada sesuatu yang dapat kita nikmati yaitu proses terbaik.” (Penulis)*

### PERSEMBAHAN

*Skripsi ini penulis persembahkan untuk*

- ❖ *Bapak dan Ibu tercinta yang selalu mencurahkan kasih sayang, perhatian, dan do'a.*
- ❖ *Mas Herwanto dan Ade Rendi Her Mawan yang selalu memberikan do'a dan motivasi.*
- ❖ *Spirit of the morning yang mengawali semangatku.*
- ❖ *Mas Ali, yang selalu memotivasi dan mengajarku banyak hal.*
- ❖ *Teh Via, ETTY, Ria, Apit, Dedi, Upi, Mba Astri dan de' Ismi, sahabat-sahabat tersayang yang tak henti menyemangati.*

## KATA PENGANTAR

Puji syukur penulis panjatkan kehadirat Allah SWT, atas segala limpahan petunjuk, kemudahan, dan kekuatan sehingga penulis dapat menyelesaikan skripsi yang berjudul “ *Bootstrap dalam Structural Equation Modeling (SEM) untuk Mengatasi Asumsi Non-normal Multivariat*”.

Penulis menyadari bahwa dalam penyusunan skripsi ini, penulis menerima banyak bantuan dari berbagai pihak. Oleh karena itu, dalam kesempatan ini penulis ingin menyampaikan rasa terima kasih kepada:

1. Prof. Dr. Sudijono Sastroatmodjo, M. Si, Rektor Universitas Negeri Semarang.
2. Dr. Kasmadi Imam S., M.S, Dekan FMIPA Universitas Negeri Semarang.
3. Drs. Edy Soedjoko, M.Pd, Ketua Jurusan Matematika FMIPA Universitas Negeri Semarang.
4. Prof. DR. YL. Sukestiyarno, MS, Pembimbing utama yang dengan sabar telah memberikan bimbingan dan arahan kepada peneliti dalam penyusunan skripsi ini.
5. Endang Sugiharti, S.Si, M.Kom, Pembimbing pendamping yang dengan sabar telah memberikan bimbingan dan arahan kepada peneliti dalam penyusunan skripsi ini.
6. Bapak dan Ibu tercinta yang selalu mencurahkan kasih sayang, perhatian, dan do'a.

7. Mas Herwanto dan Ade Rendi Her Mawan yang selalu memberikan do'a dan motivasi.
8. Teman-teman seperjuangan Matematika angkatan 2006.
9. Teman-teman Kos Al Barokah.
10. Semua pihak yang telah mendukung dan membantu proses terselesainya skripsi ini yang tidak dapat penulis sebutkan satu persatu.

Semoga skripsi ini dapat memberikan manfaat kepada penulis khususnya dan kepada pembaca pada umumnya.

Penulis



## ABSTRAK

**Ferawati, Ita.** 2010. *Analisis Bootstrap dalam Structural Equation Modeling (SEM) untuk Mengatasi Asumsi Non-normal Multivariat*. Skripsi, Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Negeri Semarang. Dosen Pembimbing 1: Prof. DR. YL. Sukestiyarno, MS; Dosen Pembimbing 2 Endang Sugiharti, S.Si, M.Kom.

**Kata Kunci:** *Bootstrap, Structural Equation Modeling (SEM)*

Dalam melakukan penelitian di berbagai bidang selalu dihadapkan pada permasalahan dalam menentukan estimasi model penelitian yang paling sesuai dengan data hasil penelitian. *Structural Equation Modeling (SEM)* yaitu suatu teknik statistika untuk mempelajari hubungan sebab akibat antar variabel laten, di mana proses pengolahannya dapat melibatkan kekeliruan dalam pengukuran dari variabel indikator dan variabel laten. Asumsi terpenting yang berkaitan dengan SEM dalam analisis struktur kovarian dan *mean* adalah data harus berskala kontinyu dan berdistribusi normal secara multivariat. *Bootstrap* merupakan salah satu metode alternatif dalam SEM untuk memecahkan masalah non-normal multivariat.

Permasalahan yang ingin dikemukakan adalah mengapa metode *bootstrap* dapat menjadi metode alternatif bagi *Structural Equation Modeling (SEM)* dalam mengatasi asumsi non-normal multivariat dan bagaimana metode *bootstrap* mengatasi asumsi non-normal multivariat dalam *Structural Equation Modeling (SEM)* untuk mendapatkan estimasi model terbaik.

Metode pemecahan masalah adalah mengidentifikasi dan mengumpulkan materi-materi prasyarat yang nantinya digunakan sebagai pedoman dalam menganalisis data melalui pendekatan SEM dengan *software* AMOS 16.

Berdasarkan hasil penelitian dan pembahasan dapat disimpulkan sebagai berikut: Metode *bootstrap* dapat menjadi metode alternatif bagi *Structural Equation Modeling (SEM)* dalam mengatasi asumsi non-normal multivariat, karena metode *bootstrap* tidak memiliki asumsi normal multivariat seperti dalam metode ML. Meskipun nilai *standard error bootstrap* lebih besar dari *standard error* ML, namun pada nilai rasio kristis yang dihasilkan oleh *bootstrap* menghasilkan nilai yang signifikan dengan taraf signifikan yang telah ditentukan. Hal ini yang menjadi pertimbangan bahwa metode *bootstrap* sebagai metode alternatif bagi SEM mampu mengatasi asumsi non-normal multivariat ketika menggunakan metode ML untuk mendapatkan estimasi model yang baik.

Berdasarkan simpulan, saran yang dapat disampaikan adalah sebagai berikut: pemilihan metode estimasi yang tepat sesuai dengan data yang diperoleh dari penelitian, selain *bootstrap*, terdapat metode lainnya yang dapat mengatasi asumsi non-normal multivariat, yaitu *jackknifing, Scaled Chi-square, Robust Standard Error, WLS*, dan lainnya sehingga dapat dibandingkan hasilnya. Dalam penelitian ini, peneliti menggunakan *software* AMOS 16.0, diharapkan untuk penelitian selanjutnya menggunakan *software* lain seperti SAS dan CALIS, LISREL, STATISTICA, MPLUS, dan sebagainya.

## DAFTAR ISI

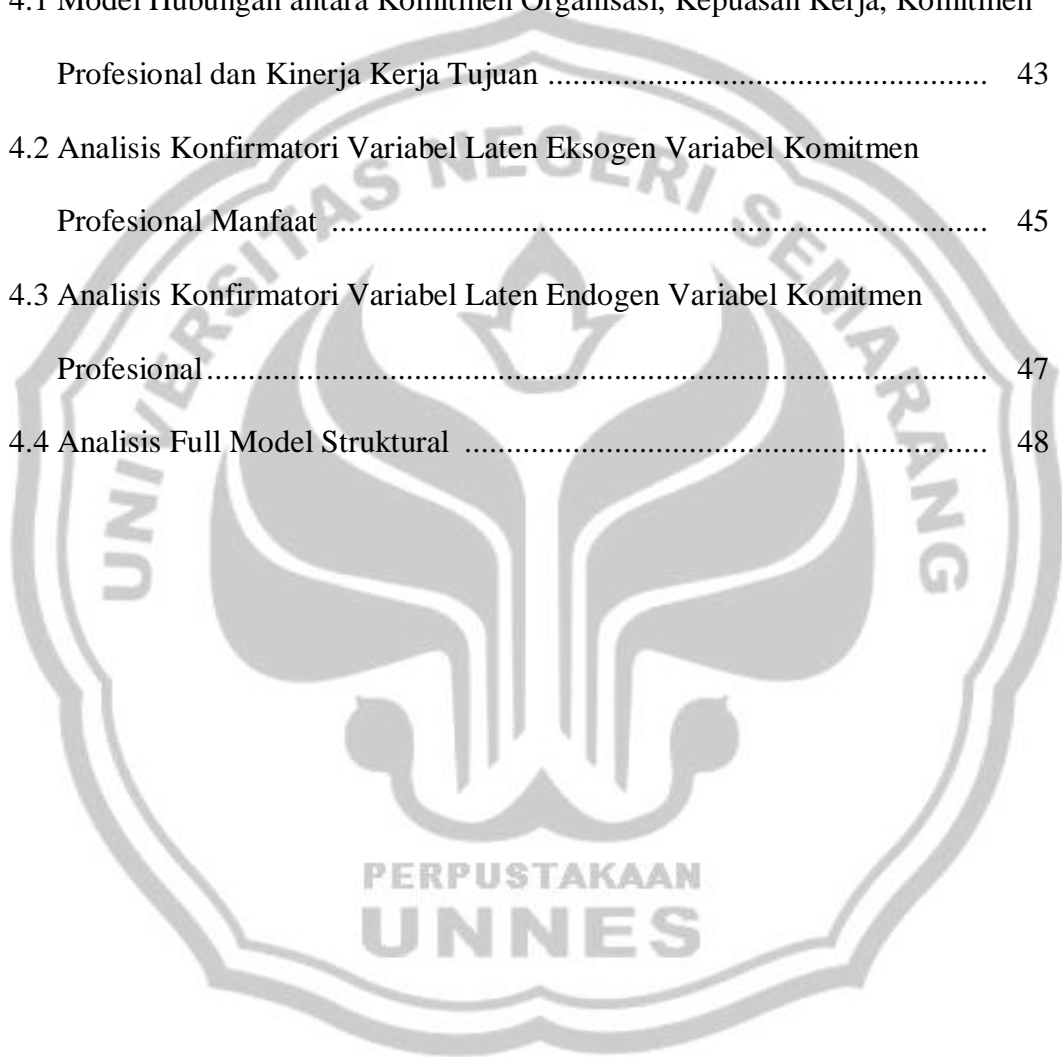
	Halaman
HALAMAN JUDUL .....	i
PERSETUJUAN PEMBIMBING .....	ii
PENGESAHAN .....	iii
MOTTO DAN PERSEMBAHAN .....	iv
KATA PENGANTAR .....	v
ABSTRAK .....	vii
DAFTAR ISI .....	viii
DAFTAR GAMBAR .....	x
DAFTAR TABEL .....	xi
BAB 1 PENDAHULUAN .....	1
1.1 Latar Belakang Masalah .....	1
1.2 Permasalahan .....	3
1.3 Tujuan .....	4
1.4 Manfaat .....	4
1.5 Pembatasan Masalah .....	4
1.6 Sistematika Skripsi .....	5
BAB 2 LANDASAN TEORI .....	7
2.1 Aljabar Matriks .....	7
2.2 Analisis Jalur ( <i>Path Analysis</i> ) .....	12
2.3 Analisis Faktor .....	15
2.4 <i>Structural Equation Modeling</i> (SEM) .....	17



2.5 Asumsi Normalitas .....	28
2.6 <i>Bootstrap</i> .....	29
2.7 AMOS ( <i>Analysis of Moment Structures</i> ) .....	34
2.8 Kerangka Berpikir .....	35
2.9 Hipotesis .....	36
<b>BAB 3 METODE PENELITIAN</b> .....	<b>37</b>
3.1 Pemilihan Masalah .....	37
3.2 Merumuskan Masalah .....	37
3.3 Studi Pustaka .....	38
3.4 Studi Laboratorium .....	38
3.5 Pemecahan Masalah .....	38
3.6 Menarik Simpulan .....	39
<b>BAB 4 HASIL DAN PEMBAHASAN</b> .....	<b>40</b>
4.1 <i>Bootstrap</i> dalam <i>Structural Equation Modeling (SEM)</i> untuk Mengatasi Asumsi Non-normal Multivariat .....	40
4.2 Contoh Kasus dan Analisis Data .....	42
4.3 Pembahasan .....	60
<b>BAB 5 PENUTUP</b> .....	<b>62</b>
5.1 Simpulan .....	62
5.2 Saran .....	63
<b>DAFTAR PUSTAKA</b> .....	<b>64</b>
<b>LAMPIRAN</b> .....	<b>65</b>

## DAFTAR GAMBAR

Gambar	Halaman
1.7 Diagram Jalur .....	13
1.8 Kerangka Berpikir .....	36
4.1 Model Hubungan antara Komitmen Organisasi, Kepuasan Kerja, Komitmen Profesional dan Kinerja Kerja Tujuan .....	43
4.2 Analisis Konfirmatori Variabel Laten Eksogen Variabel Komitmen Profesional Manfaat .....	45
4.3 Analisis Konfirmatori Variabel Laten Endogen Variabel Komitmen Profesional .....	47
4.4 Analisis Full Model Struktural .....	48



## DAFTAR TABEL

Tabel	Halaman
2.1 Simbol dalam Diagram Jalur .....	12
2.2 Korelasi Bivariat .....	14
4.1 Skala Hasil Estimasi Parameter dan <i>Standard Error</i> .....	51
4.2 <i>Bootstrap Standard Error</i> .....	53
4.3 Korelasi antar Variabel Laten dan Akar Kuadrat .....	58



# BAB 1

## PENDAHULUAN

### 1.1 Latar Belakang Masalah

Dalam melakukan penelitian baik yang bergerak dalam bidang psikologi, sosial, manajemen, maupun eksakta selalu dihadapkan pada permasalahan dalam menentukan model penelitian yang terbaik dan yang paling sesuai dengan data hasil penelitian. Analisis Regresi, Analisis Jalur (*Path Analysis*), dan Analisis Faktor adalah alat statistika yang sering digunakan dalam menganalisis hubungan sebab akibat dengan data yang mengandung variabel observasi.

Analisis Regresi, Analisis Jalur (*Path Analysis*), dan Analisis Faktor masing-masing mempunyai kelemahan. Analisis regresi dalam pengolahannya tidak melibatkan kekeliruan dalam pengukuran, Analisis Jalur (*Path Analysis*) tidak dapat menganalisis data yang mengandung variabel laten. Sedangkan Analisis Faktor tidak dapat menganalisis hubungan sebab akibat antar variabel laten.

Untuk mengatasi kelemahan Analisis Regresi, Analisis Jalur (*Path Analysis*), dan Analisis Faktor, maka digunakan teknik analisis multivariat *Structural Equation Modeling* (SEM) yaitu suatu teknik statistika untuk mempelajari hubungan sebab akibat antar variabel yang di dalamnya memuat variabel laten, di mana proses pengolahannya dapat melibatkan kekeliruan dalam pengukuran dari variabel indikator dan variabel laten.

Asumsi terpenting yang berkaitan dengan SEM dalam analisis struktur kovarian dan *mean* adalah data harus berskala kontinyu dan berdistribusi normal secara multivariat. (Ghozali, 2008:313). Data kontinyu adalah data yang dapat memiliki nilai apa saja dan tidak memiliki kategori-kategori yang berurutan. Pada umumnya data penelitian adalah data ordinal, data ordinal adalah data yang memiliki kategori berurutan (tidak kontinyu). Joreskog dan Sorbom (1993) menganjurkan untuk menggunakan metode estimasi WLS dalam analisis SEM pada data ordinal yang diperlakukan sebagai data kontinyu, padahal untuk menggunakan metode WLS tersebut harus dipenuhi beberapa syarat yang sulit. Chou et al. (1991) dan Hu et al. (1992) berpandangan bahwa akan lebih masuk akal jika memperlakukan variabel-variabel kategori sebagai variabel kontinyu dan menguji statistik dari pada menggunakan uji WLS. Beberapa penelitian SEM yang berbasis skala *Likert* pada 15 tahun terakhir menunjukkan bahwa penelitian tersebut menggunakan metode estimasi *Maksimum Likelihood* (ML) bukan WLS. (Ghozali, 2005:38)

Metode ML memerlukan asumsi sampel besar dan variabel-variabel indikator berdistribusi normal multivariat. *Bootstrap* adalah metode berbasis komputer yang dikembangkan untuk mengestimasi berbagai kuantitas statistik, metode *bootstrap* tidak memerlukan asumsi apapun. *Bootstrap* merupakan salah satu metode alternatif dalam SEM untuk memecahkan masalah non-normal multivariat.

Metode *bootstrap* pertama kali dikenalkan oleh Elfron (1979 dan 1982) dan kemudian dikembangkan oleh Kotz dan Johnson (1992). Istilah *bootstrap*

diambil dari “*to pull oneself up by the bootstraps*” yang memiliki makna bahwa sampel asli (*original sample*) akan menghasilkan tambahan berganda berikutnya. Jadi *bootstrap* merupakan prosedur *resampling* (pensampelan kembali) di mana sampel asli atau *original* diperlakukan sebagai populasi. *Multiple sub-sample* dengan ukuran sampel sama dengan sampel asli kemudian diambil secara random, dengan *replacement* dari populasi. Ide utama dari *bootstrap* adalah peneliti dapat menciptakan *multiple sample* dari *original data base*. (Ghozali, 2008:314)

Salah satu *software* yang mendukung estimasi *Maksimum Likelihood* (ML) dan *bootstrap* untuk data yang non-normal adalah AMOS (*Analysis of Moment Structures*). AMOS salah satu program pengolah data statistik untuk analisis multivariat yang sangat sederhana.

Dari uraian di atas, peneliti tergerak untuk mengkaji lebih lanjut dan membahas tentang “*Bootstrap dalam Structural Equation Modeling* (SEM) untuk Mengatasi Asumsi Non-normal Multivariat”.

## 1.2 Permasalahan

Berdasarkan latar belakang di atas, permasalahan yang ingin dikemukakan adalah sebagai berikut.

- (1) Mengapa metode *bootstrap* dapat menjadi metode alternatif bagi *Structural Equation Modeling* (SEM) dalam mengatasi asumsi non-normal multivariat?
- (2) Bagaimana metode *bootstrap* mengatasi asumsi non-normal multivariat dalam *Structural Equation Modeling* (SEM) untuk mendapatkan estimasi model terbaik?

### 1.3 Tujuan

Berdasarkan dari permasalahan di atas maka tujuan penelitian adalah sebagai berikut.

- (1) Untuk mengetahui metode *bootstrap* sebagai metode alternatif bagi *Structural Equation Modeling* (SEM) dalam mengatasi asumsi non-normal multivariat?
- (2) Untuk mengetahui bagaimana metode *bootstrap* mengatasi asumsi non-normal multivariat dalam *Structural Equation Modeling* (SEM) untuk mendapatkan estimasi model terbaik?

### 1.4 Manfaat

Manfaat yang ingin dicapai dalam penelitian ini adalah sebagai berikut.

- (1) Sebagai bahan perbandingan dalam mempelajari metode-metode statistika terutama yang berhubungan dengan *Structural Equation Modeling* (SEM) dan *bootstrap*.
- (2) *Bootstrap* sebagai metode alternatif dalam *Structural Equation Modeling* (SEM) dalam mengatasi asumsi non-normal multivariat.

### 1.5 Pembatasan Masalah

Pada penelitian ini, peneliti hanya membahas tentang cara mengatasi asumsi non-normal multivariat dalam *Structural Equation Modeling* (SEM) dengan menggunakan metode *bootstrap* sebagai metode alternatif untuk mendapatkan estimasi model terbaik dengan melihat nilai *standard error* dari *bootstrap*. Sebagai gambaran analisis akan diberikan contoh kasus dengan tipe

data ordinal berskala *Likert* dan analisis data menggunakan bantuan *software* AMOS 16.0.

## 1.6 Sistematika Skripsi

Secara garis besar skripsi ini dibagi menjadi tiga bagian yaitu bagian awal skripsi, bagian isi skripsi, dan bagian akhir skripsi.

Bagian awal skripsi meliputi Halaman Sampul, Halaman Judul, Pengesahan, Pernyataan, Motto dan Persembahan, Kata Pengantar, Abstrak, Daftar Isi, Daftar Gambar, dan Daftar Tabel.

Bagian isi skripsi secara garis besar terdiri dari lima bab, yaitu:

### BAB 1. PENDAHULUAN

Di dalam bab ini dikemukakan Latar Belakang Masalah, Permasalahan, Tujuan, Manfaat, Pembatasan Masalah dan Sistematika Skripsi.

### BAB 2. LANDASAN TEORI

Di dalam bab ini dikemukakan konsep-konsep yang dijadikan landasan teori sebagai berikut: Aljabar Matriks, Analisis Jalur (*Path Analysis*), Analisis Faktor, *Structural Equation Modeling* (SEM), Asumsi Normalitas, *Bootstrap*, AMOS (*Analysis of Moment Structures*), Kerangka Berfikir dan Hipotesis.

### BAB 3. METODE PENELITIAN

Di dalam bab ini dikemukakan metode penelitian yang berisi langkah-langkah yang dilakukan pada penelitian ini meliputi beberapa hal yaitu sebagai berikut, Pemilihan Masalah, Merumuskan Masalah, Studi



Pustaka, Studi Laboratorium, Pemecahan Masalah dan Menarik Simpulan.

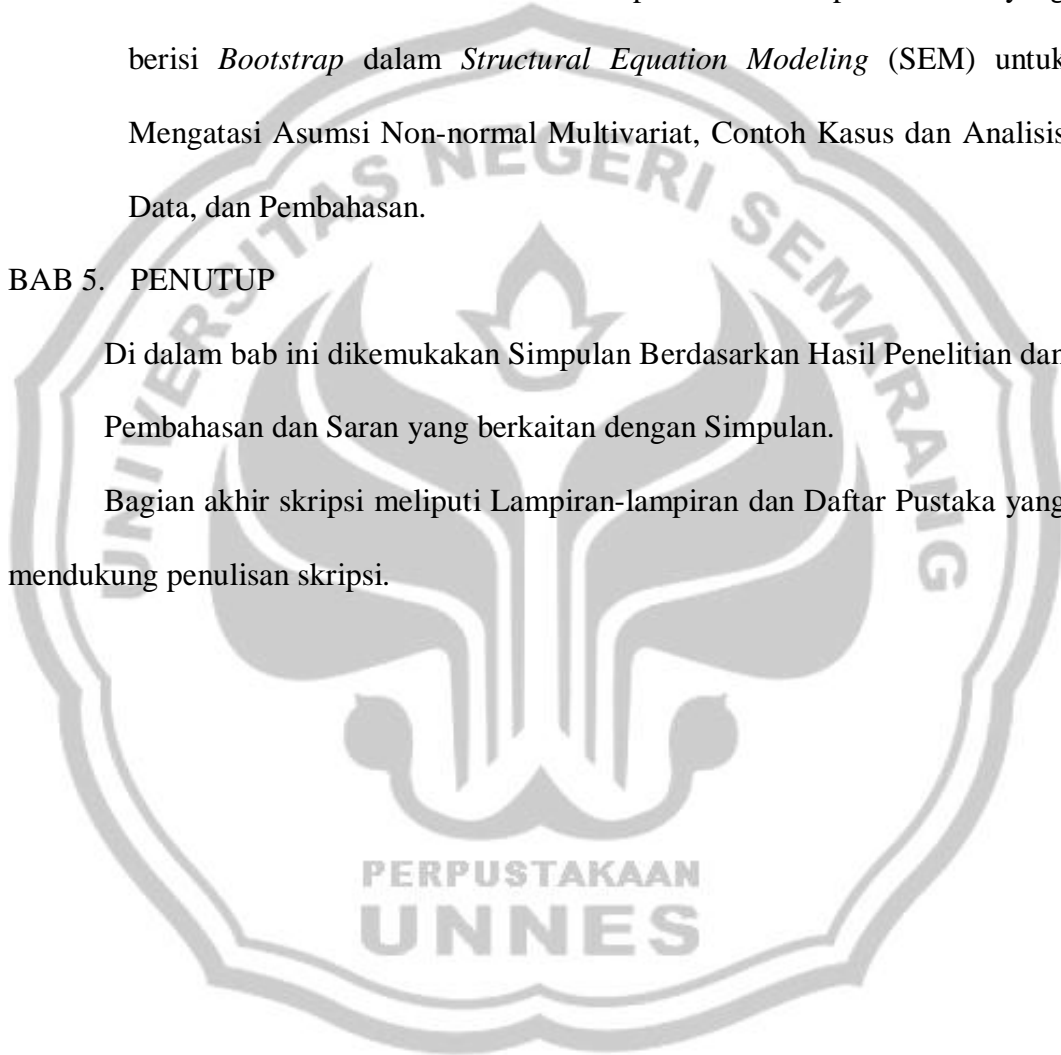
#### BAB 4. HASIL PENELITIAN DAN PEMBAHASAN

Di dalam bab ini dikemukakan hasil penelitian dan pembahasan yang berisi *Bootstrap* dalam *Structural Equation Modeling* (SEM) untuk Mengatasi Asumsi Non-normal Multivariat, Contoh Kasus dan Analisis Data, dan Pembahasan.

#### BAB 5. PENUTUP

Di dalam bab ini dikemukakan Simpulan Berdasarkan Hasil Penelitian dan Pembahasan dan Saran yang berkaitan dengan Simpulan.

Bagian akhir skripsi meliputi Lampiran-lampiran dan Daftar Pustaka yang mendukung penulisan skripsi.



## BAB 2

### LANDASAN TEORI

#### 2.1 Aljabar Matriks

Matriks berdimensi  $m \times k$  dengan huruf tebal adalah bilangan dengan  $m$  baris dan  $k$  kolom. Dimensi suatu matriks dapat dilihat di bawah huruf yang merupakan simbol dari matriksnya. Matriks  $A$  berdimensi  $m \times k$  ditulis  $A_{m \times k}$ .

Sembarang matriks  $A_{m \times k}$  ditulis  $A_{m \times k} = \begin{bmatrix} a_{11} & a_{12} & \dots & \dots & a_{1k} \\ a_{21} & a_{22} & \dots & \dots & a_{2k} \\ \vdots & \vdots & \ddots & \ddots & \vdots \\ a_{m1} & a_{m2} & \dots & \dots & a_{mk} \end{bmatrix}$

atau lebih singkat  $A_{m \times k} = \{a_{ij}\}$ ;  $i$  menyatakan baris dan  $j$  menyatakan kolom,  $a_{ij}$  menyatakan elemen baris ke- $i$  dan kolom ke- $j$  dari matriks  $A$ .

Matriks  $m \times 1$  merupakan vektor kolom (dimensi  $m$ ) dan matriks  $1 \times k$  merupakan vektor baris (dimensi  $k$ ).

Contoh:  $A_{3 \times 2} = \begin{bmatrix} -7 & 2 \\ 0 & 1 \\ 3 & 4 \end{bmatrix}$  adalah matriks berdimensi  $3 \times 2$ .

##### 2.1.1 Transpos Matriks

Transpos dari suatu matriks  $A$  berdimensi  $m \times k$  adalah matriks  $B$  berdimensi  $k \times m$  yang didefinisikan oleh:

$$b_{ij} = a_{ji} \quad (2.1.1)$$

untuk  $j = 1, 2, \dots, k$  dan  $i = 1, 2, \dots, m$ . Transpos dari  $A$  dinyatakan oleh  $A^T$ .

Beberapa aturan tranpos matriks, yaitu:

$$1. (A^T)^T = A \quad (2.1.2)$$

$$2. (\alpha A)^T = \alpha A^T; \alpha \text{ adalah konstanta} \quad (2.1.3)$$

$$3. (A + B)^T = A^T + B^T \quad (2.1.4)$$

$$4. (AB)^T = B^T A^T \quad (2.1.5)$$

Contoh: Jika  $A_{2 \times 3} = \begin{bmatrix} 1 & 2 & 3 \\ 4 & 5 & 6 \end{bmatrix}$  maka  $(A_{3 \times 2})^T = \begin{bmatrix} 1 & 4 \\ 2 & 5 \\ 3 & 6 \end{bmatrix}$ .

### 2.1.2 Matriks Bujur Sangkar

Matriks sembarang  $A$  dengan jumlah baris = jumlah kolom disebut matriks bujur sangkar.  $A_{m \times k}$  adalah matriks bujur sangkar.

Contoh:  $A_{2 \times 2} = \begin{bmatrix} 1 & 2 \\ 4 & 5 \end{bmatrix}$  adalah matriks bujur sangkar dengan jumlah baris = jumlah kolom = 2.

### 2.1.3 Matriks Simetris

Matriks  $A$  adalah matriks bujur sangkar berdimensi  $k \times k$ . Matriks  $A$  disebut simetris jika  $A = A^T$ . Jadi  $A$  adalah simetris jika  $a_{ij} = a_{ji}$ ,  $i = 1, \dots, k; j = 1, \dots, k$ .

Contoh:  $A_{3 \times 3} = \begin{bmatrix} 4 & 4 & 5 \\ 4 & 1 & 3 \\ 5 & 3 & 2 \end{bmatrix}$ .

### 2.1.4 Matriks Diagonal

Suatu matriks  $A$  berdimensi disebut matriks diagonal jika  $A_{ij} = 0$  untuk  $i \neq j$ .

Contoh:  $A_{3 \times 3} = \begin{bmatrix} 4 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 2 \end{bmatrix}$ .

### 2.1.5 Matriks Identitas

Matriks identitas berdimensi  $k \times k$  adalah matriks bujur sangkar dengan elemen pada diagonal utama = 1 dan untuk elemen yang lain = 0, diberi notasi  $I_{k \times k}$ .

Contoh:  $I_{3 \times 3} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}$ .

### 2.1.6 Determinan Matriks

Determinan dari suatu matriks bujur sangkar  $A$  berdimensi  $k \times k$ ,  $A = \{a_{ij}\}$ , diberi notasi  $|A|$ , adalah skalar

$$|A| = a_{11} \quad \text{jika } k = 1$$

$$= \sum_{j=1}^k a_{ij} |A_{ij}| (-1)^{1+j} \quad \text{jika } k > 1$$

di mana  $A_{ij}$  adalah matriks berdimensi  $(k-1) \times (k-1)$  yang didapat dari matriks  $A$  dengan mengalikan baris pertama kolom ke- $j$ . Contoh: Jika  $A_{2 \times 2} = \begin{bmatrix} 1 & 2 \\ 4 & 5 \end{bmatrix}$ , maka determinannya adalah  $|A| = -3$ .

### 2.1.7 Matriks Singular dan Non-singular

Matriks bujur sangkar  $A$  berdimensi  $k \times k$  dikatakan singular jika  $|A| = 0$ , dan dikatakan non-singular jika  $|A| \neq 0$ .

Contoh:  $A_{2 \times 2} = \begin{bmatrix} 1 & 0 \\ 2 & 3 \end{bmatrix}$  mempunyai  $|A| = 3 \neq 0$ , matriks  $A$  adalah non-singular. dan  $B_{2 \times 2} = \begin{bmatrix} 1 & 0 \\ 0 & 0 \end{bmatrix}$  mempunyai  $|B| = 0$ , maka matriks  $B$  adalah singular.

### 2.1.8 Invers Matriks

Matriks  $B$  sedemikian sehingga  $AB = BA = I$  disebut invers dari matriks  $A$ , dinotasikan  $A^{-1}$ .

Contoh: Invers dari  $A = \begin{bmatrix} 2 & 3 \\ 1 & 5 \end{bmatrix}$  adalah  $A^{-1} = \begin{bmatrix} \frac{5}{7} & -\frac{3}{7} \\ -\frac{1}{7} & \frac{2}{7} \end{bmatrix}$ .

### 2.1.9 Matriks Ortogonal

Elemen baris ke- $j$  kolom ke- $i$  dari  $A^{-1}$  adalah  $(-1)^{i+j} |A_{ij}|/|A|$ , di mana  $A_{ij}$  didapat dari baris matriks  $A$  dengan menghilangkan baris ke- $i$  kolom ke- $j$ , dan  $|A| \neq 0$ . Matriks bujur sangkar  $A$  disebut ortogonal bila baris-barisnya (dipandang sebagai vektor) saling tegak lurus dan mempunyai panjang 1 yaitu  $AA^T = I$ .

Contoh:  $A_{4 \times 4} = \begin{bmatrix} -\frac{1}{2} & \frac{1}{2} & \frac{1}{2} & \frac{1}{2} \\ \frac{1}{2} & -\frac{1}{2} & \frac{1}{2} & \frac{1}{2} \\ \frac{1}{2} & \frac{1}{2} & -\frac{1}{2} & \frac{1}{2} \\ \frac{1}{2} & \frac{1}{2} & \frac{1}{2} & -\frac{1}{2} \end{bmatrix}$ .

### 2.1.10 Akar Ciri

A matriks bujur sangkar berdimensi  $k \times k$  dan  $I$  matriks identitas berdimensi  $k \times k$ . Skalar  $\lambda_1, \lambda_2, \dots, \lambda_k$  yang memenuhi persamaan  $|A - \lambda I| = 0$  disebut akar ciri (akarkarakteristik) dari matriks  $A$ . Persamaan  $|A - \lambda I| = 0$  disebut persamaan karakteristik.

Contoh: Misalkan  $A_{2 \times 2} = \begin{bmatrix} 1 & 0 \\ 1 & 3 \end{bmatrix}$ .  $|A - \lambda I| = 0$ ,

maka  $\left| \begin{bmatrix} 1 & 0 \\ 1 & 3 \end{bmatrix} - \lambda \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \right| = \left| \begin{bmatrix} 1-\lambda & 0 \\ 1 & 3-\lambda \end{bmatrix} \right| = (1-\lambda)(3-\lambda) = 0$  diperoleh

$\lambda_1 = 1$  dan  $\lambda_2 = 3$  yang merupakan ciri matriks  $A$ .

### 2.1.11 Vektor Ciri

A matriks berdimensi  $k \times k$  dan  $\lambda$  adalah ciri dari  $A$ . Jika  $x$  adalah vektor tak nol sedemikian sehingga  $Ax = \lambda x$ , maka  $x$  dikatakan vektor ciri (vektor karakteristik) dari matriks  $A$  yang bersesuaian dengan akar ciri  $\lambda$ .

Contoh: Misalkan  $A_{2 \times 2} = \begin{bmatrix} 1 & 0 \\ 1 & 3 \end{bmatrix}$  dengan akar ciri  $\lambda_1 = 1$  dan  $\lambda_2 = 3$

untuk  $\lambda_1 = 1$ :  $\begin{bmatrix} 1 & 0 \\ 1 & 3 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = 1 \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$  maka  $x_1 = x_1$ ;  $x_1 + 3x_2 = x_2$ , maka

$x_1 = -2x_2$ , sehingga diperoleh vektor ciri untuk  $\lambda_1 = 1$  adalah  $\begin{bmatrix} -2 \\ 1 \end{bmatrix}$ , dan untuk

$\lambda_2 = 3$ :  $\begin{bmatrix} 1 & 0 \\ 1 & 3 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = 3 \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$  maka  $x_1 = 3x_1$ ;  $x_1 + 3x_2 = 3x_2$ , maka  $x_1 = 0$  dan

$x_2 = 1$  sehingga diperoleh vektor ciri untuk  $\lambda_2 = 3$  adalah  $\begin{bmatrix} 0 \\ 1 \end{bmatrix}$ .

## 2.2 Analisis Jalur (*Path Analysis*)

Analisis Jalur (*Path Analysis*) merupakan pengembangan dari Analisis Regresi, sehingga Analisis Regresi dapat dikatakan sebagai bentuk khusus dari Analisis Jalur. Analisis Jalur digunakan untuk melukiskan dan menguji model hubungan antar variabel yang berbentuk sebab akibat (bukan bentuk hubungan interaktif/*reciprocal*). (Sugiyono, 2007:299)

Diagram jalur merupakan gambar dari hubungan yang diasumsikan. Bagi banyak peneliti, gambar lebih jelas mewakili hubungan yang ada dari pada persamaan. Berikut adalah simbol-simbol yang terdapat dalam diagram jalur.

Tabel 2.1. Simbol dalam Diagram Jalur

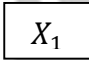
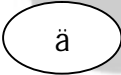
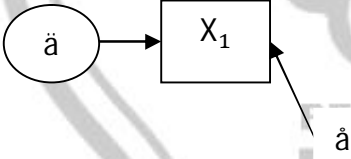

Simbol	Keterangan
	Kotak merupakan variabel terukur (indikator)
	Ellips merupakan variabel tak terukur (laten)
	Variabel yang tidak berada dalam kotak maupun ellips merupakan variabel pengganggu ( <i>outlier</i> ), sedangkan panah satu arah menggambarkan arah pengaruh dari suatu variabel ke variabel yang lain
	Kurva dengan dua anak panah menggambarkan hubungan dua variabel

Diagram jalur merupakan dasar dari analisis jalur untuk estimasi empiris tentang kuatnya setiap hubungan yang tergambar dalam diagram jalur. Untuk

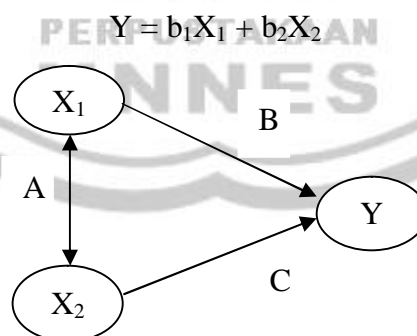
menghitung estimasi (kuatnya hubungan) dapat digunakan hanya dengan satu matrik korelasi atau kovarians sebagai input.

Menurut Supranto (2004), korelasi sederhana antara dua variabel dapat direpresentasikan sebagai *the sum of the compound paths connecting these points*.

*A compound path* merupakan suatu jalur sepanjang anak panah yang mengikuti tiga aturan:

- 1) Setelah bergerak maju pada suatu anak panah, jalur tidak boleh bergerak ke belakang (mundur) lagi, akan tetapi boleh bergerak ke belakang beberapa kali, sebelum bergerak maju lagi.
- 2) Jalur tidak boleh bergerak melalui beberapa variabel yang sama lebih dari sekali.
- 3) Seperti hanya boleh mencakup satu kurva anak panah (sepasang variabel yang berkorelasi).

Sebagai contoh sederhana misalkan kita akan meneliti dua faktor  $X_1$  dan  $X_2$  yang akan mempengaruhi  $Y$  dan dinyatakan dalam persamaan regresi linear berganda.



Gambar 2.1. Diagram Jalur



Untuk mengestimasi koefisien jalur B dan C digunakan korelasi. Misalkan diketahui korelasi antar variabel adalah sebagai berikut:

Tabel 2.2. Korelasi Bivariat

	$X_1$	$X_2$	Y
$X_1$	1,0		
$X_2$	0,50	1,0	
Y	0,60	0,70	1,0

dari Tabel 2.2 diperoleh:

$$\text{Corr } (X_1, X_2): A = 0,50$$

$$\text{Corr } (X_1, Y): B + AC = 0,60$$

$$\text{Corr } (X_2, Y): C + AB = 0,70$$

Substitusikan  $A = 0,50$  ke persamaan:  $B + AC = 0,60$

$$C + AB = 0,70$$

Maka akan didapat:  $B = 0,33$

$$C = 0,53$$

Korelasi antara  $X_1$  dan Y ( $\text{Corr } (X_1, Y)$ ) merupakan dua jalur kausalitas yaitu jalur pengaruh langsung dari  $X_1$  ke Y dan jalur pengaruh tidak langsung dari  $X_1$  ke  $X_2$  kemudian ke Y. Begitu juga dengan korelasi antara  $X_2$  dan Y ( $\text{Corr } (X_2, Y)$ ) merupakan dua jalur kausalitas yaitu jalur pengaruh langsung dari  $X_2$  ke Y dan jalur pengaruh tidak langsung dari  $X_2$  ke  $X_1$  kemudian ke Y. Dengan hanya menggunakan input korelasi maka koefisien persamaan regresi dari  $X_1$  ke Y dapat diketahui sebesar 0,33 dan koefisien persamaan regresi dari  $X_2$  ke Y dapat diketahui sebesar 0,53.

Pengaruh langsung	$X_1$ ke Y:	B	= 0,33
Pengaruh tak langsung	$X_1$ ke Y:	AC	= $0,37 \times 0,53 = 0,27$
Pengaruh total	$X_1$ ke Y:	B + AC	= $0,33 + 0,27 = 0,6$

### 2.3 Analisis Faktor

Analisis Faktor merupakan nama umum yang menunjukkan suatu kelas prosedur, utamanya digunakan untuk mereduksi data atau meringkas dari variabel yang banyak diubah menjadi sedikit variabel, misalnya dari 15 variabel yang lama diubah menjadi 4 atau 5 variabel baru yang disebut faktor dan masih memuat sebagian informasi yang terkandung dalam variabel asli (*original variable*). (Supranto, 2004:114)

Suatu variasi dari teknik Analisis Faktor di mana matriks korelasi dari faktor-faktor tertentu dilakukan analisis pada faktornya sendiri untuk membuat faktor-faktor. Model analisis faktor ini adalah sebagai berikut.

$$\begin{aligned}
 Z_1 - \mu_1 &= L_{11}F_1 + L_{12}F_2 + \dots + L_{1m}F_m + \varepsilon_1 \\
 Z_2 - \mu_2 &= L_{21}F_1 + L_{22}F_2 + \dots + L_{2m}F_m + \varepsilon_2 \\
 &\vdots \\
 Z_p - \mu_p &= L_{p1}F_1 + L_{p2}F_2 + \dots + L_{pm}F_m + \varepsilon_p
 \end{aligned}
 \tag{2.3.1}$$

atau dalam notasi matriks

$$Z_{px1} - \mu_{px1} = L_{pxm}F_{mx1} + \varepsilon_{px1} \tag{2.3.2}$$

di mana:

$Z_i$  : variabel acak ke-i,  $i= 1, 2, \dots, p$

$\mu_i$  : rata-rata variabel ke-i

$\varepsilon_i$  : faktor spesifik ke-i

$F_j$  : faktor bersama ke-j,  $j = 1, 2, \dots, m$

$L_p$  : loading faktor variabel ke-i faktor ke-j

$Z$  : vektor variabel acak  $Z$ , berdimensi  $p \times 1$

$\mu$  : vektor rata-rata variabel acak  $Z$ , berdimensi  $p \times 1$

$L$  : matriks loading faktor, berdimensi  $p \times m$

$\varepsilon$  : vektor faktor spesifik, berdimensi  $p \times 1$

Model Analisis Faktor pada persamaan (2.3.2) membawa implikasi pada struktur matriks kovarian, yaitu:

$$\begin{aligned}
 \Sigma &= \text{Cov}(Z, Z) \\
 &= E[ZZ^T] \\
 &= E[(Z - \mu)(Z - \mu)^T] \\
 &= E[(LF + \varepsilon)(LF + \varepsilon)^T] \\
 &= E[(LF + \varepsilon)((LF)^T + \varepsilon^T)] \\
 &= E[(LF + \varepsilon)(F^T L^T + \varepsilon^T)] \\
 &= E[LFF^T L^T + LF\varepsilon^T + \varepsilon F^T L^T + \varepsilon\varepsilon^T] \\
 &= LE[FF^T]L^T + LE[F\varepsilon^T] + E[\varepsilon F^T]L^T + E[\varepsilon\varepsilon^T] \\
 &= LL^T + \psi
 \end{aligned} \tag{2.3.3}$$

dengan asumsi  $\text{Cov}(F, \varepsilon) = 0$ ,  $E(F) = 0$ ,  $\text{Cov}(F) = I$ ,  $E(\varepsilon) = 0$ ,  $\text{Cov}(\varepsilon) = \psi$ , di mana  $\psi$  matriks diagonal.

## 2.4 *Structural Equation Modeling (SEM)*

Menurut Ghozali, SEM adalah suatu teknik variabel ganda yang dapat digunakan untuk mendeskripsikan keterkaitan hubungan linier secara simultan antara variabel-variabel pengamatan, yang sekaligus melibatkan variabel laten yang tidak dapat diukur secara langsung.

Jenis variabel menurut Ramadiani et al. (2010), dalam SEM mengandung dua jenis variabel yaitu variabel laten dan variabel teramati, dua jenis model yaitu model struktural dan model pengukuran serta dua jenis kesalahan yaitu kesalahan struktural dan kesalahan pengukuran.

### 2.4.1 *Spesifikasi Model*

SEM terdiri atas model pengukuran dan model struktural. Model struktural menggambarkan hubungan antar variabel-variabel indikator dengan variabel laten yang dibangunnya, sedangkan model struktural menjelaskan antar variabel laten.

Model struktural dinyatakan sebagai berikut:

$$\eta = \beta\eta + \Gamma\xi + \zeta \quad (2.4.1)$$

Model pengukuran dinyatakan sebagai berikut:

$$Y = \Lambda_Y\eta + \varepsilon \quad (2.4.2)$$

$$X = \Lambda_X\xi + \delta \quad (2.4.3)$$

di mana:

$\eta$  : vektor variabel laten endogen, berdimensi  $m \times 1$

$\beta$  : matriks koefisien  $\eta$ , berdimensi  $m \times m$

$\Gamma$  : matriks koefisien  $\xi$ , berdimensi  $m \times n$

$\xi$  : vektor variabel laten eksogen, berdimensi  $n \times 1$

$\zeta$  : vektor galat pada persamaan struktural, berdimensi  $m \times 1$

$Y$  : vektor variabel indikator untuk variabel laten endogen berdimensi  $p \times 1$

$\Lambda_y$  : matriks koefisien  $Y$  terhadap  $\eta$ , berdimensi  $m \times 1$

$\varepsilon$  : vektor galat pengukuran  $Y$ , berdimensi  $p \times 1$

$X$  : vektor variabel indikator untuk variabel laten eksogen berdimensi  $q \times 1$

$\Lambda_x$  : matriks koefisien  $X$  terhadap  $\xi$ , berdimensi  $q \times n$

$\delta$  : vektor galat pengukuran  $X$ , berdimensi  $q \times 1$

diasumsikan bahwa  $\zeta$  tidak berkorelasi dengan  $\xi$ , dan  $(I - \beta)$  non-singular. nilai harapan  $\eta$ ,  $\xi$ ,  $\zeta$ ,  $\varepsilon$  dan  $\delta$  adalah nol. Galat pengukuran  $\varepsilon$  dan  $\delta$  dianggap tidak berkorelasi satu sama lain, juga dengan variabel-variabel laten.

#### 2.4.2 Pembentukan Matriks Kovarian

Model struktural dalam persamaan (2.4.1) dapat ditulis sebagai berikut:

$$\begin{aligned}\eta &= \beta\eta + \Gamma\xi + \zeta \\ \eta - \beta\eta &= \Gamma\xi + \zeta \\ (I - \beta)\eta &= \Gamma\xi + \zeta \\ (I - \beta)^{-1}(I - \beta)\eta &= (I - \beta)^{-1}(\Gamma\xi + \zeta) \\ \eta &= (I - \beta)^{-1}(\Gamma\xi + \zeta)\end{aligned}\tag{2.4.4}$$

Bila  $\Phi$  adalah matriks kovarian bagi  $\xi$ ,  $\psi$  adalah matriks kovarian bagi  $\zeta$ ,  $\Theta_\varepsilon$  adalah matriks kovarian bagi  $\varepsilon$  dan  $\Theta_\delta$  adalah matriks kovarian bagi  $\delta$ , maka matriks kovarian bagi  $\eta$  adalah:

$$\begin{aligned}
\sum_{\eta\eta} &= \text{Cov}(\eta, \eta) \\
&= E\{\eta\eta^T\} \\
&= E\{[(1 - \beta)^{-1}(\Gamma\xi + \zeta)][(1 - \beta)^{-1}(\Gamma\xi + \zeta)]^T\} \\
&= E\{(1 - \beta)^{-1}(\Gamma\xi + \zeta)(\Gamma\xi + \zeta)^T[(1 - \beta)^{-1}]^T\} \\
&= E\{(1 - \beta)^{-1}(\Gamma\xi + \zeta)(\zeta^T + \xi^T\Gamma^T)[(1 - \beta)^{-1}]^T\} \\
&= E\{(1 - \beta)^{-1}(\Gamma\xi\xi^T + \Gamma\xi\xi^T\Gamma^T + \zeta\zeta^T + \zeta\xi^T\Gamma^T)[(1 - \beta)^{-1}]^T\} \\
&= (1 - \beta)^{-1}\{E[\Gamma\xi\xi^T] + E[\Gamma\xi\xi^T\Gamma^T] + E[\zeta\zeta^T] + E[\zeta\xi^T\Gamma^T]\}[(1 - \beta)^{-1}]^T \\
&= (1 - \beta)^{-1}(\Gamma\Phi\Gamma^T + \Psi)[(1 - \beta)^{-1}]^T \tag{2.4.5}
\end{aligned}$$

dan matriks kovarian bagi  $\eta$  dan  $\xi$

$$\begin{aligned}
\sum_{\eta\xi} &= \text{Cov}(\eta, \xi) \\
&= E[\eta\xi^T] \\
&= E[(1 - \beta)^{-1}(\Gamma\xi + \zeta)\xi^T] \\
&= (1 - \beta)^{-1}E[\Gamma\xi\xi^T + \zeta\xi^T] \\
&= (1 - \beta)^{-1}\Gamma\Phi \tag{2.4.6}
\end{aligned}$$

partisi matriks kovarian bagi  $X$  dan  $Y$  ke dalam empat bagian dapat ditulis sebagai berikut:

$$\sum = \begin{bmatrix} \sum_{YY} & \sum_{YX} \\ \sum_{XY} & \sum_{XX} \end{bmatrix}$$

$$\begin{aligned}
\sum_{YY} &= \text{Cov}(Y, Y) \\
&= E[YY^T] \\
&= E[(\Lambda_Y\eta + \varepsilon)(\Lambda_Y\eta + \varepsilon)^T] \\
&= E[(\Lambda_Y\eta + \varepsilon)(\eta^T\Lambda_Y^T + \varepsilon^T)]
\end{aligned}$$

$$\begin{aligned}
&= E[\Lambda_Y \eta \eta^T \Lambda_Y^T + \varepsilon \eta^T \Lambda_Y^T + \Lambda_Y \eta \varepsilon^T + \varepsilon \varepsilon^T] \\
&= \Lambda_Y E[\eta \eta^T] \Lambda_Y^T + E[\varepsilon \eta^T] \Lambda_Y^T + \Lambda_Y E[\eta \varepsilon^T] + E[\varepsilon \varepsilon^T] \\
&= \Lambda_Y (I - \beta)^{-1} (\Gamma \Phi \Gamma^T + \Psi) [(I - \beta)^{-1}]^T \Lambda_Y^T + \Theta_\varepsilon \tag{2.4.7}
\end{aligned}$$

$$\begin{aligned}
\Sigma_{YX} &= \text{Cov}(Y, X) \\
&= E[YZ^T] \\
&= E[(\Lambda_Y \eta + \varepsilon)(\Lambda_X \xi + \delta)^T] \\
&= E[(\Lambda_Y \eta + \varepsilon)(\xi^T \Lambda_X^T + \delta^T)] \\
&= E[\Lambda_Y \eta \xi^T \Lambda_X^T + \varepsilon \xi^T \Lambda_X^T + \Lambda_Y \eta \delta^T + \varepsilon \delta^T] \\
&= \Lambda_Y E[\eta \xi^T] \Lambda_X^T + E[\varepsilon \xi^T] \Lambda_X^T + \Lambda_Y E[\eta \delta^T] + E[\varepsilon \delta^T] \\
&= \Lambda_Y (I - \beta)^{-1} \Gamma \Phi \Lambda_X^T \tag{2.4.8}
\end{aligned}$$

$$\begin{aligned}
\Sigma_{XY} &= \text{Cov}(X, Y) \\
&= E[XY^T] \\
&= E[(\Lambda_X \xi + \delta)(\Lambda_Y \eta + \varepsilon)^T] \\
&= E[(\Lambda_X \xi + \delta)(\eta^T \Lambda_Y^T + \varepsilon^T)] \\
&= E[\Lambda_X \xi \eta^T \Lambda_Y^T + \delta \eta^T \Lambda_Y^T + \Lambda_X \xi \varepsilon^T + \delta \varepsilon^T] \\
&= \Lambda_X E[\xi \eta^T] \Lambda_Y^T + E[\delta \eta^T] \Lambda_Y^T + \Lambda_X E[\xi \varepsilon^T] + E[\delta \varepsilon^T] \\
&= \Lambda_X \Gamma \Phi (I - \beta)^{-1} \Lambda_Y^T \tag{2.4.9}
\end{aligned}$$

$$\begin{aligned}
\Sigma_{XX} &= \text{Cov}(X, X) \\
&= E[XX^T] \\
&= E[(\Lambda_X \xi + \delta)(\Lambda_X \xi + \delta)^T] \\
&= E[(\Lambda_X \xi + \delta)(\xi^T \Lambda_X^T + \delta^T)] \\
&= E[\Lambda_X \xi \xi^T \Lambda_X^T + \delta \xi^T \Lambda_X^T + \Lambda_X \xi \delta^T + \delta \delta^T]
\end{aligned}$$

$$\begin{aligned}
&= \Lambda_X E[\xi \xi^T] \Lambda_X^T + E[\delta \xi^T] \Lambda_Y^T + \Lambda_Y E[\xi \delta^T] + E[\delta \delta^T] \\
&= \Lambda_X \Phi \Lambda_X^T + \Theta_\delta
\end{aligned} \tag{2.4.10}$$

matriks kovarian  $\Sigma$  dapat dinyatakan dalam parameter model  $\theta$ , yaitu:

$$\begin{aligned}
\Sigma &= \Sigma(\theta) \\
&= \begin{bmatrix} \Lambda_Y (I - \beta)^{-1} (\Gamma \Phi \Gamma^T + \psi) [(I - \beta)^{-1}]^T \Lambda_Y^T + \Theta_\varepsilon & \Lambda_Y (I - \beta)^{-1} \Gamma \Phi \Lambda_X^T \\ \Lambda_X \Gamma \Phi (I - \beta)^{-1} \Lambda_Y^T & \Lambda_X \Phi \Lambda_X^T + \Theta_\delta \end{bmatrix}
\end{aligned} \tag{2.4.11}$$

di mana  $\theta$  adalah vektor yang beranggotakan unsur-unsur  $\Lambda_Y$ ,  $\Lambda_X$ ,  $\beta$ ,  $\Gamma$ ,  $\Phi$ ,  $\psi$ ,  $\Theta_\varepsilon$  dan  $\Theta_\delta$  yang dapat dinyatakan sebagai parameter tetap, kendala dan bebas. Parameter tetap adalah parameter yang ditentukan nilainya, parameter kendala adalah parameter yang tidak diketahui nilainya tetapi ditentukan kesamaannya dengan satu atau lebih parameter lain, dan parameter bebas adalah parameter yang tidak diketahui nilainya dan tidak diketahui kesamaan dengan parameter yang lainnya.

### 2.4.3 Identifikasi Model

Masalah identifikasi adalah pemecahan yang unik terjadi untuk setiap parameter. Jika semua parameter model teridentifikasi. Jika semua parameter tidak dapat teridentifikasi, maka tidak dapat ditentukan estimator yang konsisten untuk parameter tersebut.

Syarat teridentifikasi bagi semua parameter adalah:

$$u < \frac{1}{2} (p + q)(p + q + 1) \tag{2.4.12}$$



di mana  $u$  adalah banyaknya parameter yang tidak diketahui,  $p$  adalah banyaknya variabel laten endogen dan  $q$  adalah banyaknya variabel indikator laten eksogen.

#### 2.4.4 Estimasi Model

Pada SEM diasumsikan bahwa variabel indikator dan variabel laten kontinyu. Padahal dalam penelitian sosial variabel-variabel indikatornya umumnya menggunakan skala Likert atau merupakan variabel ordinal. Konsekuensi dari masalah tersebut adalah model pengukuran (2.4.2) dan (2.4.3) tidak dapat dijabarkan sebagai hubungan linear  $Y$  terhadap  $\eta$  dan  $X$  terhadap  $\xi$  karena pada SEM diasumsikan bahwa  $\eta$  dan  $\xi$  merupakan variabel laten yang kontinyu, sehingga perlu penyesuaian model pengukuran sebagai berikut:

$$Y^* = \Lambda_Y \eta + \varepsilon \quad (2.4.13)$$

$$X^* = \Lambda_X \xi + \delta \quad (2.4.14)$$

di mana  $Y^*$  dan  $X^*$  adalah indikator laten kontinyu. Fungsi non-linear yang menghubungkan variabel indikator berskala ordinal ( $Y$  dan  $X$ ) dengan variabel indikator laten berskala kontinyu ( $Y^*$  dan  $X^*$ ), dinyatakan sebagai berikut:

$$Y = \begin{cases} 1, & \text{jika } Y^* \leq a_1 \\ 2, & \text{jika } a_1 < Y^* \leq a_2 \\ \vdots & \vdots \\ c-1, & \text{jika } a_{c-2} < Y^* \leq a_{c-1} \\ c, & \text{jika } a_{c-1} < Y^* \end{cases} \quad (2.4.15)$$

$$X = \begin{cases} 1, & \text{jika } Y^* \leq b_1 \\ 2, & \text{jika } b_1 < Y^* \leq b_2 \\ \vdots & \vdots \\ d-1, & \text{jika } b_{d-2} < Y^* \leq b_{d-1} \\ d, & \text{jika } b_{d-1} < Y^* \end{cases} \quad (2.4.16)$$

di mana  $c$  adalah banyaknya kategori pada  $Y$ ,  $a_i$  adalah parameter ambang untuk kategori pada  $Y$ , di mana  $i = 1, 2, \dots, c-1$ , di mana  $d$  adalah banyaknya kategori pada  $X$ ,  $b_j$  adalah parameter ambang untuk kategori pada  $X$ , di mana  $j = 1, 2, \dots, d-1$ , dengan  $a_0 = b_0 = -\infty$  dan  $a_c = b_d = +\infty$ .

Diasumsikan  $Y^*$  dan  $X^*$  berdistribusi normal baku, sehingga estimasi parameter ambangnya adalah sebagai berikut:

$$a_i = \Phi^{-1} \left( \sum_{k=1}^i \frac{n_k}{n} \right), i = 1, 2, \dots, c-1 \quad (2.4.17)$$

$$b_j = \Phi^{-1} \left( \sum_{k=1}^j \frac{n_k}{n} \right), j = 1, 2, \dots, d-1 \quad (2.4.18)$$

di mana  $\Phi^{-1}(\cdot)$  adalah invers dari fungsi distribusi normal baku,  $n_k$  adalah frekuensi pengamatan pada kategori ke- $k$  dan  $n$  adalah banyaknya pengamatan untuk  $k$  kategori.

Misalkan  $Y^*$  dan  $X^*$  adalah variabel indikator laten kontinu berdistribusi normal baku dengan mean nol dan varian satu (0,1), maka dapat diasumsikan  $Y^*$  dan  $X^*$  berdistribusi normal baku bivariat dengan korelasi  $\rho$ . Korelasi  $\rho$  ini disebut korelasi polikhorik, yaitu korelasi antara variabel indikator laten kontinu  $Y^*$  dan  $X^*$ .

Misalkan fungsi densitas normal baku bivariat dengan  $\rho$  dinyatakan sebagai berikut:

$$\phi(X^*, Y^*; \rho) = \frac{1}{2\pi(1-\rho^2)^{\frac{1}{2}}} \exp \left[ \frac{-1}{2(1-\rho^2)} (X^{*2} - 2\rho X^* Y^* + Y^{*2}) \right]$$

(2.4.19)

Sehingga peluang pengamatan untuk  $Y = i$  dan  $X = j$  adalah:

$$P_{ij} = \int_{a_{i-1}}^{a_i} \int_{b_{j-1}}^{b_j} \phi(X^*, Y^*; \rho) dX^* dY^*$$

(2.4.20)

misalkan  $n_{ij}$  adalah banyaknya frekuensi pengamatan kategori ke- $i$  variabel pertama dan frekuensi pengamatan kategori ke- $j$  variabel kedua, maka fungsi *Maksimum Likelihoodnya* adalah:

$$L = K \prod_{i=1}^c \prod_{j=1}^d P_{ij}^{n_{ij}}, K \text{ adalah konstanta}$$

(2.4.21)

Estimasi korelasi polikhorik diperoleh dengan memaksimumkan fungsi  $\ln(L)$  atau ekuivalen dengan meminimalkan fungsi pengepasan:

$$F(\theta) = \sum_{i=1}^c \sum_{j=1}^d \frac{n_{ij}}{n} \left[ \ln \frac{n_{ij}}{n} - \ln P_{ij}(\theta) \right] = \sum_{i,j} \frac{n_{ij}}{n} \ln \left[ \frac{\frac{n_{ij}}{n}}{P_{ij}(\theta)} \right]$$

(2.4.22)

dengan metode numerik (model iterasi),  $\theta = \{P, a_1, \dots, a_{c-1}, b_1, \dots, b_{d-1}\}$ . sebelum meminimalkan fungsi  $F(\theta)$ , terlebih dahulu semua parameter ambang diestimasi dengan persamaan (2.4.17) dan (2.4.18).

Menurut Chou et al. (1991) dan Hu et al. (1992), berpendapat bahwa akan lebih masuk akal jika memperlakukan variabel-variabel *categorical* sebagai

variabel kontinu dan mengoreksi uji statistik. Beberapa penelitian SEM yang berbasis skala *Likert* pada 15 tahun terakhir menunjukkan bahwa penelitian SEM menggunakan metode estimasi *Maksimum Likelihood* (ML).

Dengan asumsi bahwa sebaran dari variabel-variabel pengamatan dapat digambarkan oleh vektor rata-rata dan matriks kovarians, maka masalah estimasi merupakan pengepasan matriks  $\Sigma(\theta)$  dengan matriks kovarians sampel  $S$ . Misalkan fungsi pengepasan dinyatakan dengan  $F(S, \Sigma(\theta))$ , yaitu fungsi yang tergantung pada  $S$  dan  $\Sigma(\theta)$ . Jika estimasi parameter  $\theta$  disubstitusikan dalam  $\Sigma$ , maka diperoleh  $\hat{\Sigma}$  dan fungsi pengepasannya adalah  $F(S, \hat{\Sigma})$ . Fungsi pengepasan *Maksimum Likelihood* adalah:

$$F_{ML} = \log|\Sigma(\theta)| + \text{tr}[S\Sigma^{-1}(\theta) - \log|S| - (p + q)] \quad (2.4.23)$$

$S$  dan  $\Sigma(\theta)$  matriks dengan dimensi  $\left[\frac{1}{2}(p + q)(p + q + 1) \times \frac{1}{2}(p + q)(p + q + 1)\right]$ .

#### 2.4.5 Evaluasi Model

Uji kelayakan model dilakukan untuk mengetahui model telah fit atau belum. Uji kelayakan model diantaranya sebagai berikut:

##### 1) Model Keseluruhan (Struktur Sekaligus Pengukuran)

Uji kelayakan pada model keseluruhan

###### a) Uji *Chi-square*

Hipotesis:

$$H_0 : \Sigma = \Sigma(\theta)$$

$$H_1 : \Sigma \neq \Sigma(\theta)$$

$$\begin{aligned} \text{Ststistik uji: } \chi^2 &= (n - 1)F_{ML} \\ &= (n - 1)\log|\Sigma(\theta)| + \text{tr}[S\Sigma^{-1}(\theta) - \log|S| - (p + q)] \end{aligned} \quad (2.4.24)$$

Kriteria uji:

$H_0$  ditolak jika  $\chi^2_{\text{hitung}} > \chi^2_{\alpha, (\frac{1}{2}(p+q)(p+q+1)-t)}$ , di mana  $t$  adalah jumlah parameter bebas untuk perkiraan model. Dan jika digunakan perangkat lunak,  $H_0$  ditolak jika  $p\text{-value} < 0,05$ .

$\Sigma$  adalah matriks kovarians sampel dari variabel observasi.  $\Sigma(\theta)$  adalah matriks kovarians dari populasi,  $S$  adalah matriks kovarians sampel dari observasi.

b) Uji RMSEA (*Root Mean Square Error Aproximate*)

Statistik Uji:

$$\text{RMSEA} = \sqrt{\frac{\hat{F}_0}{df}} \quad (2.4.25)$$

dengan

$$\hat{F}_0 = \frac{\chi^2_{\text{model}} - df}{N} \quad (2.4.26)$$

Kriteria Uji:

Model dikatakan baik jika nilai  $\text{RMSEA} < 0,08$ .

## 2) Model Pengukuran

Setelah keseluruhan model fit, maka langkah berikutnya adalah pengukuran setiap konstruk. Pendekatan untuk menilai model pengukuran diantaranya adalah sebagai berikut:

### a) Uji Reliabilitas

Reliabilitas adalah ukuran konsistensi internal dari indikator-indikator sebuah variabel. Terdapat dua cara untuk menentukan reliabilitas, yaitu *composit (construct) reliability* dan *variance extracted*. *Cut-off value* dari *construct reliability* adalah minimal 0,70 sedangkan *cut-off* untuk *variance extracted* minimal 0,50.

*Composite reliability* didapat dengan rumus:

$$\text{Construct Reliability} = \frac{(\sum \text{standardized loading})^2}{(\sum \text{standardized loading})^2 + \sum \epsilon_j} \quad (2.4.27)$$

*Standardized loading* : besarnya nilai koefisien terhadap variabel laten

$\epsilon_j$  : *measurement error* =  $1 - \text{standardized loading}^2$ .

*Variance extracted* didapat dengan rumus:

$$\text{Variance extracted} = \frac{\sum \text{standardized loading}^2}{\sum \text{standardized loading}^2 + \sum \epsilon_j} \quad (2.4.28)$$

(Ghozali, 2008:233)

b) Uji *Diskriminant Validity*

Validitas adalah ukuran sampai sejauh mana suatu indikator secara akurat mengukur apa yang hendak diukur. Masing-masing konstruk laten dinilai baik jika besarnya akar dari *variance extracted* ( $\sqrt{AVE}$ ) lebih tinggi nilainya dibandingkan nilai korelasi antar variabel laten. (Ghozali, 2008:235)

## 2.5 Asumsi Normalitas

Uji normalitas adalah untuk melihat apakah nilai residual terdistribusi normal atau tidak. Model yang baik adalah memiliki nilai residual yang terdistribusi normal. Jadi uji normalitas bukan dilakukan pada masing-masing variabel tetapi pada nilai residualnya. Sering terjadi kesalahan yang jamak yaitu bahwa uji normalitas dilakukan pada masing-masing variabel. Hal ini tidak dilarang tetapi model memerlukan normalitas pada nilai residualnya bukan pada masing-masing variabel penelitian.

Normalitas adalah asumsi yang paling fundamental dalam analisis multivariat khususnya SEM. Apabila asumsi normalitas tidak dipenuhi dan penyimpangan normalitas tersebut besar, maka seluruh hasil uji statistik tidak valid karena untuk menguji hubungan antar variabel adalah dengan asumsi data normal. Normalitas dibagi menjadi dua, yaitu normalitas univariat (*univariate normality*) dan normalitas multivariat (*multivariate normality*). Berbeda halnya dengan normalitas univariat yang dapat diuji dengan menggunakan data ordinal

maupun data kontinyu, uji normalitas multivariat hanya dapat dilakukan untuk data kontinyu. (Ghozali, 2005:37)

Untuk menguji dilanggar/tidaknya asumsi normalitas, maka dapat digunakan nilai statistik z untuk skewness dan kurtosisnya. Nilai z skewness dapat dihitung sebagai berikut:

$$Z_{skweness} = \frac{\text{skewness}}{\sqrt{\frac{6}{N}}} \quad (2.5.1)$$

$$Z_{kurtosis} = \frac{\text{kurtosis}}{\sqrt{\frac{24}{N}}} \quad (2.5.2)$$

di mana N merupakan ukuran sampel. Di dalam SEM menghendaki berdistribusi normalitas multivariat. Untuk mengetahui apakah berdistribusi normal multivariat, maka dibutuhkan nilai dari  $Z_{skweness}$  atau  $Z_{kurtosis} < \pm 1,96$  pada  $\alpha = 0,05$  dan  $< \pm 2,58$  pada  $\alpha = 0,01$ .

## 2.6 *Bootstrap*

### 2.6.1 Konsep Dasar Metode *Bootstrap*

Metode *bootstrap* pertama kali diperkenalkan oleh Bradley Elfron pada tahun 1979. Metode *bootstrap* pada dasarnya adalah melakukan pengambilan sampel (resampling) dengan pengembalian dari sampel hasil observasi dengan replikasi B kali ( $n \leq B \leq n^n$ ) dengan n adalah banyaknya ukuran sampel dan selanjutnya hasil resampling tersebut dipergunakan untuk mencari penaksir



*bootstrap*. Metode *bootstrap* merupakan suatu metode pendekatan nonparametrik untuk menaksir berbagai kualitas statistik seperti *mean*, *standard error* dan bias suatu estimator atau untuk membentuk interval konfidensi dengan memanfaatkan kecanggihan teknologi komputer. Metode *bootstrap* dapat juga untuk mengestimasi distribusi suatu statistik. Distribusi ini diperoleh dengan menggantikan distribusi populasi yang tidak diketahui dengan distribusi empiris berdasarkan data sampel, kemudian melakukan pengambilan sampel (*resampling*) dengan pengembalian dari distribusi empiris yang selanjutnya dipergunakan untuk mencari penaksir *bootstrap*. Dengan metode *bootstrap* tidak perlu melakukan asumsi distribusi dan asumsi-asumsi awal untuk menduga bentuk distribusi dan pengujian-pengujian statistiknya.

Algoritma *bootstrap* berdasarkan pada model sederhana yaitu model satu sampel, di mana distribusi peluang yang tidak diketahui  $F$  (distribusi sembarang) dari data  $x$  dengan sampel random.

$$F \rightarrow x = (x_1, x_2, \dots, x_n) \quad (2.6.1)$$

Untuk menjelaskan metode *bootstrap*, dipikirkan dua masalah, yaitu masalah *real* dan masalah buatan. Dimana masalah buatan tersebut dikenal sebagai masalah *bootstrap*. Dalam masalah *real* (dunia nyata), di mana distribusi peluang yang tidak diketahui  $F$  (distribusi sembarang) dengan data pengamatan  $x = (x_1, x_2, \dots, x_n)$  dengan sampel random. Dapat dihitung statistik yang menjadi perhatian dari  $x$ ,  $\hat{\theta} = s(x)$ , dan diharapkan dapat diketahui tentang statistik  $\hat{\theta}$ , dan *standard error*  $se_{(B)}(\hat{\theta})$ . Sedangkan pada dunia *bootstrap*, distribusi nyata dari  $\hat{F}$  dengan memberikan sampel *bootstrap* dengan sampel

random di mana dapat dihitung replikasi *bootstrap* dari statistik yang menjadi perhatian yaitu  $\hat{\theta}^* = s(x^*)$ . Keuntungan dalam penggunaan dunia *bootstrap* ini yaitu dapat dihitung replikasi  $\hat{\theta}^*$  yang diinginkan.

Sebelum era komputerisasi, penggunaan analisis statistika yang menggunakan matematika dan teori probabilitas untuk mendapatkan rumus dari *standard error* dan interval konfidensi sering mendapatkan kendala yang cukup berarti pada sampel dengan ukuran besar. Namun, dengan menggunakan komputer dan paket program statistika, misalkan AMOS, metode *bootstrap* dapat digunakan untuk menpacatkan *standard error* dan interval konfidensi dari suatu data dengan ukuran besar tanpa harus melakukan perhitungan secara manual. Hasil menggunakan ini akan lebih *reliable* dari pada menggunakan teori statistika secara manual.

### 2.6.2 Pembentukan Sampel *Bootstrap*

Metode *bootstrap* sangat bergantung pada estimasi-estimasi dari sampel *bootstrap*.  $\hat{F}$  adalah suatu distribusi empiris yang memberikan bobot  $\frac{1}{n}$  untuk setiap nilai terobservasi  $x_i, i = 1, 2, \dots, n$ . Sampel *bootstrap* didefinisikan sebagai suatu sampel *random* berukuran  $n$  yang ditarik dari  $\hat{F}$ , katakan  $x^* = (x_1^*, x_2^*, \dots, x_n^*)$ . Notasi bintang mengindikasikan bahwa  $x^*$  bukanlah data sebenarnya pada data set  $x$ , namun merupakan versi dari  $x$  yang telah mengalami *resampling*.

Secara umum langkah-langkah dasar metode *bootstrap* menurut Elfron yaitu:

- 1) Menentukan distribusi empiris  $F_n^*(x)$  bagi sampel dengan peluang  $\frac{1}{n}$  untuk masing-masing  $x_i$ .
- 2) Menentukan sampel *bootstrap*  $x^* = (x_1^*, x_2^*, \dots, x_n^*)$  yang diambil dari  $x_i$  dengan pengembalian.
- 3) Menentukan replikasi *bootstrap*  $\hat{\theta}^*$  berdasarkan sampel *bootstrap*.
- 4) Ulangi langkah 2) dan 3) sebanyak B kali, untuk B yang cukup besar.
- 5) Berikan probabilitas untuk B  $\hat{\theta}^*$  dengan menempatkan peluang  $\frac{1}{B}$  bagi masing-masing  $\hat{\theta}^*(1), \hat{\theta}^*(2), \dots, \hat{\theta}^*(B)$ . Distribusi ini adalah estimasi *bootstrap* untuk distribusi sampling  $\hat{\theta}$ .

### 2.6.3 *Standard Error Bootstrap*

*Standard error* merupakan *standard deviasi* dari statistik. *Standard error* ini digunakan untuk menindikasikan ketelitian statistik. Sedangkan estimasi *bootstrap* dari  $se_F(\hat{\theta})$  yaitu *standard error* dari sebuah statistik,  $\hat{\theta}$  adalah sebuah estimasi pengganti yang menggunakan distribusi empiris fungsi F yang belum diketahui. Secara spesifik, estimasi *bootstrap* dari  $se_F(\hat{\theta})$  didefinisikan sebagai:

$$s\hat{e}_B = \left\{ \sum_{b=1}^B \frac{[\hat{\theta}^*(b) - \hat{\theta}^*(\cdot)]^2}{B-1} \right\}^{\frac{1}{2}}$$

(2.6.2)

di mana:

$$\hat{\theta}^*(\cdot) = \sum_{b=1}^B \frac{\hat{\theta}^*(b)}{B}$$

(2.6.3)

#### 2.6.4 *Bootsrap dalam Structural Equation Modeling (SEM)*

Seperti yang telah dijelaskan di atas, terdapat langkah-langkah dalam analisis SEM yaitu: spesifikasi model, pembentukan matriks kovarians, identifikasi model, estimasi model dan evaluasi model. Dalam beberapa literatur, tujuan utama dalam analisis SEM adalah melakukan uji statistik untuk  $H_0 : \Sigma = \Sigma(\theta)$ , di mana  $\Sigma$  adalah matriks kovarians sampel dari variabel observasi,  $\Sigma(\theta)$  adalah matriks kovarians dari populasi dan  $\theta$  adalah vektor yang terdiri dari parameter *free* dalam model. Jika model telah ditentukan dengan tepat dan asumsi distribusi untuk data terpenuhi, peneliti dapat menggunakan uji statistik.

Dalam Bollen dan Stine (1992) diperkirakan dua macam prosedur *bootstrapping* dalam SEM, yaitu *neive bootstrapping* dan modifikasi *bootstrapping*. Prosedur *neive bootstrapping* tidak tepat untuk menguji keseluruhan kesesuaian model dalam analisis SEM, hal ini dikarenakan prosedur *neive bootstrapping* menghasilkan nilai kesesuaian model yang tidak akurat, yaitu besarnya variasi dan banyaknya model yang ditolak. Bollen dan Stine memberikan prosedur perbaikan (modifikasi *bootstrapping*) yaitu dengan melakukan *resampling* pada data dengan tujuan agar  $H_0 : \Sigma = \Sigma(\theta)$  dapat diterima. Estimasi yang digunakan dalam metode *bootstrap* dalam SEM ini adalah *Maksimum Likelihood Estimation (MLE)*.

$$\log|\Sigma(\theta)| + \text{tr}[S\Sigma^{-1}(\theta) - \log|S| - (p + q)]$$

(2.6.4)

## 2.7 AMOS (*Analysis of Moment Structures*)

Amos (*Analysis of Moment Structures*) merupakan *software* khusus yang digunakan dalam SEM. AMOS semula merupakan perangkat lunak komputasi statistik yang mandiri namun dalam perkembangannya saat ini AMOS diambil alih oleh SPSS sehingga versi-versinya mengikuti perkembangan SPSS.

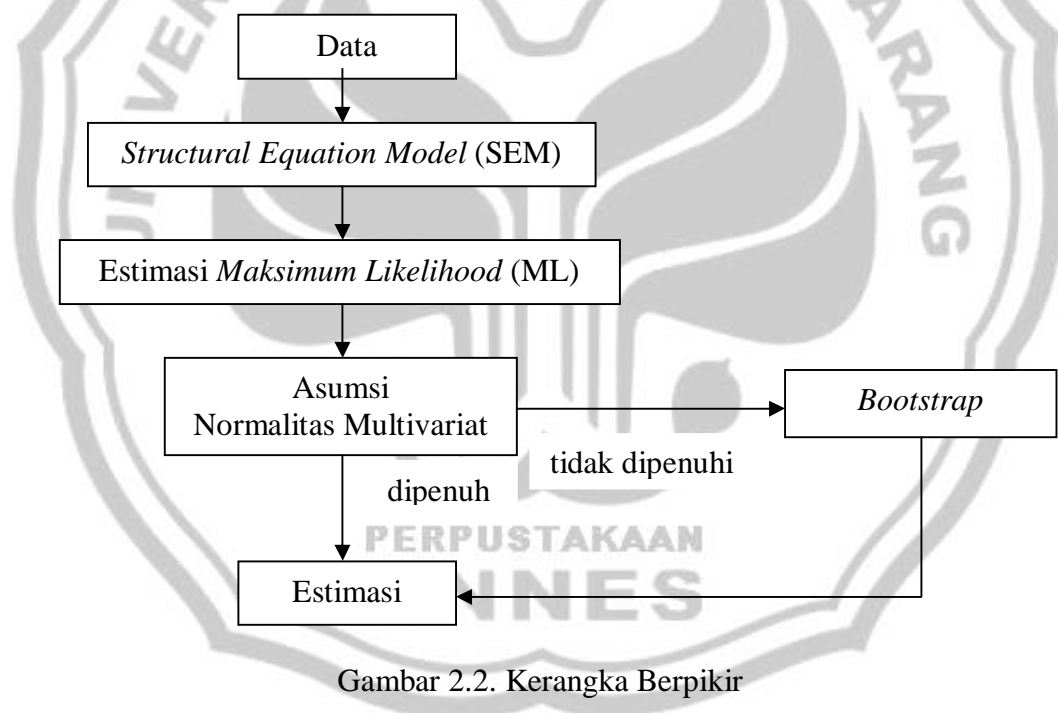
Banyak orang yang menghindari melakukan penelitian dengan menggunakan pendekatan SEM dengan alasan kompleksitas prosedur analisis SEM. Analisis dengan menggunakan SEM memang sangat kompleks karena SEM merupakan analisis multivariat dengan banyak variabel. Namun dengan menggunakan AMOS, analisis SEM menjadi menarik dan menantang. AMOS menyediakan kanvas di dalam programnya agar peneliti menuangkan modelnya dalam bentuk gambar di dalam kanvas tersebut. Analisis menjadi semakin mudah karena dengan satu kali klik, gambar model yang dituangkan di dalam kanvas langsung dianalisis dengan lengkap.

AMOS menyediakan analisis untuk SEM dan metode *bootstrap*. Jika peneliti menggunakan AMOS untuk melakukan kedua analisis tersebut, peneliti akan dilengkapi dengan satu set estimasi parameter dengan dua set *standard error* yaitu *standard error* untuk sampel ML atau GLS (*original*) dan *standard error* untuk sampel *bootstrap*.

## 2.8 Kerangka Berpikir

Pada umumnya penelitian di bidang sosial, psikologi, manajemen, dan lainnya, data yang digunakan adalah data ordinal yang diperoleh melalui angket kuesioner. Permasalahan yang timbul dari data ordinal ini adalah bagaimana menentukan model penelitian yang terbaik dan yang paling sesuai dengan data yang diperoleh dalam penelitian. *Structural Equation Modeling* (SEM) adalah suatu teknik analisis multivariat yang dapat digunakan untuk menganalisis permasalahan dalam menentukan estimasi, syarat dalam SEM adalah data harus kontinu padahal data ordinal bukan merupakan data kontinu. Pemilihan metode estimasi dalam SEM untuk tipe data ordinal harus diperhatikan dan harus disesuaikan dengan jumlah data yang diperoleh dalam penelitian. Metode estimasi yang populer dalam SEM adalah *Maksimum Likelihood* (ML), metode ini dianggap mampu menyelesaikan masalah untuk data dengan tipe ordinal dengan menggunakan skala *Likert*. Analisis yang dihasilkan harus memperhatikan asumsi, terdapat syarat penting dalam pemilihan estimasi model, yaitu data berdistribusi normal multivariat. Jika asumsi ini tidak dipenuhi maka akan terjadi penyimpangan dan untuk mengatasi adanya data non-normal secara multivariat salah satunya menggunakan prosedur yang dikenal dengan istilah *Bootstrap*. Dengan metode *bootstrap*, akan dilakukan analisis pada matriks kovarians populasinya. Untuk kasus *standard error* pada sampel *bootstrap* jika diketahui normal dari metode estimasi ML maka akan menghasilkan *standard error* yang kecil, sebaliknya jika diketahui non-normal, sampel *bootstrap* akan menghasilkan *standard error* yang besar. Begitu juga untuk nilai bias, bias yang mutlak kecil,

menandakan distribusi empiris *bootstrap* hanya sedikit menyimpang dari distribusi normal. Keberhasilan analisis *bootstrap* tergantung pada sejauh mana perilaku sampling statistik saat sampel diambil dari distribusi empiris, dan ketika mereka diambil dari populasi asli. Akhirnya, ketika data multivariat normal, *bootstrap standard error* telah ditemukan lebih bias dari pada yang berasal dari metode ML. Sebaliknya, ketika distribusi yang mendasarinya tidak normal, perkiraan *bootstrap* kurang bias dari perkiraan ML. Hal ini merupakan fakta yang mendukung harapan teoritis. Untuk memudahkan analisis ini, peneliti menggunakan bantuan *software* AMOS 16.0



Gambar 2.2. Kerangka Berpikir

## 2.9 Hipotesis

*Bootstrap* dapat mengatasi asumsi non-normal multivariat dalam *Structural Equation Modeling (SEM)* untuk mendapatkan estimasi model terbaik.

## **BAB 3**

### **METODE PENELITIAN**

Dalam suatu penelitian peran metode penelitian sangat penting. Sehingga dengan metode penelitian dapat mencapai tujuan penelitian yang telah ditetapkan dan agar penelitian yang telah dilakukan berjalan dengan lancar. Melalui metode penelitian, masalah yang dihadapi dapat diatasi dan dipecahkan dari perolehan data yang telah dikumpulkan.

Langkah-langkah yang dilakukan pada penelitian ini meliputi beberapa hal yaitu sebagai berikut.

#### **3.1 Pemilihan Masalah**

Dalam perkuliahan yang diperoleh penulis, banyak masalah yang perlu dikaji lebih lanjut. Dari beberapa masalah tersebut dihadapkan pada persoalan untuk memilih masalah yang kemudian dijadikan bahan dasar untuk melakukan penelitian lebih lanjut.

#### **3.2 Merumuskan Masalah**

Perumusan masalah diperlukan untuk membatasi permasalahan sehingga diperoleh bahan kajian yang jelas. Sehingga akan lebih mudah untuk menentukan langkah dalam memecahkan masalah tersebut.



### **3.3 Studi Pustaka**

Setelah diperoleh masalah untuk diteliti, peneliti mengadakan studi pustaka. Studi pustaka adalah penelaahan sumber pustaka yang *relevant*, digunakan untuk mengumpulkan data informasi yang diperlukan dalam penelitian. Studi pustaka diawali dengan mengumpulkan sumber pustaka yang berupa buku atau *literature*, jurnal dan sebagainya. Setelah pustaka terkumpul dilanjutkan dengan pemahaman isi sumber pustaka tersebut yang pada akhirnya sumber pustaka ini dijadikan landasan untuk menganalisis permasalahan.

### **3.4 Studi Laboratorium**

Setelah melakukan studi pustaka, peneliti kemudian mengadakan studi laboratorium untuk menganalisis suatu masalah yang telah diperoleh sebelumnya. Studi laboratorium dengan fasilitas seperti seperangkat alat komputer dapat memudahkan peneliti dalam melakukan penelitian untuk menyusun hasil penelitian.

### **3.5 Pemecahan Masalah**

Setelah permasalahan dirumuskan dan sumber pustaka terkumpul, langkah selanjutnya adalah pemecahan masalah melalui pengkajian secara teoritis yang selanjutnya disusun secara rinci dalam bentuk pembahasan.

Dalam pembahasan masalah dilakukan beberapa langkah pokok yaitu sebagai berikut.

- (1) Mengidentifikasi dan mengumpulkan materi-materi prasyarat yang nantinya digunakan sebagai pedoman dalam menganalisis data melalui pendekatan SEM dengan *software* AMOS 16.
- (2) Menganalisis data sebagai contoh kasus.
  - a. Menyusun kerangka pemikiran teoritis dalam bentuk hipotesis.
  - b. Membentuk diagram jalur hubungan kausalitas.
  - c. Menguji konfirmatori untuk variabel laten.
  - d. Mengestimasi persamaan full model.
  - e. Menguji evaluasi asumsi model struktural.
  - f. Jika diketahui adanya pelanggaran terhadap asumsi normalitas multivariat maka dilakukan analisis menggunakan metode *bootstrap*.
  - g. Menilai estimasi parameter.
  - h. Pengukuran model fit.

### **3.6 Menarik Simpulan**

Langkah terakhir dalam kegiatan penelitian ini adalah menarik kesimpulan dari keseluruhan permasalahan yang telah dirumuskan dengan berdasarkan pada landasan teori dan hasil pemecahan masalah.

## BAB 4

### HASIL DAN PEMBAHASAN

#### 4.1 *Bootstrap* dalam *Structural Equation Modeling* (SEM) untuk Mengatasi Asumsi Non-normal Multivariat

Estimasi dalam SEM umumnya berdasarkan pada metode *Maksimum Likelihood* (ML). Metode ML menghendaki adanya asumsi yang harus dipenuhi yaitu, (1) jumlah sampel harus besar (*asymptotic*); (2) distribusi dari *observed variable* normal secara multivariat; (3) model yang dihipotesiskan harus valid; dan (4) skala pengukuran variabel harus kontinyu.

Jumlah sampel harus besar, analisis struktur kovarian atau SEM berdasarkan pada ukuran sampel yang besar (*large sample size theory*). Sehingga jumlah sampel yang besar sangat kritis untuk mendapatkan estimasi parameter yang tepat. Distribusi *observed variable* normal multivariat, analisis SEM juga menghendaki distribusi variabel harus normal multivariat sebagai konsekuensi dari asumsi sampel besar dan penggunaan metode estimasi ML, jika asumsi ini dilanggar maka akan mempengaruhi hasil analisis. Pertama jika data meningkat menjadi semakin tidak normal, maka nilai *Chi-square* yang diperoleh dari estimasi ML menjadi sangat besar, jika hal ini ditemui maka peneliti harus melakukan modifikasi terhadap model yang dihipotesiskan agar diperoleh model fit karena jika tidak akan berakibat pada model yang tidak sesuai secara teoritis. Kedua, jika jumlah sampel kecil, metode ML akan menghasilkan nilai *Chi-square*

yang *inflated*, lebih jauh lagi jika sampel kecil dan tidak normal, maka peneliti akan menghadapi hasil analisis yang tidak konvergen. Ketiga, jika data tidak normal, maka fit indeks lainnya akan menghasilkan nilai yang *underestimate*. Keempat, data yang tidak normal dapat menghasilkan *standard error* yang rendah, dengan derajat kebebasan (df) berkisar dari moderat ke kuat, oleh karena *standard error underestimate*, maka koefisien regresi dan *error covariance* akan signifikan secara statistik, walaupun hal ini tidak akan terjadi pada populasinya. Skala pengukuran variabel harus kontinyu, skala pengukuran variabel dalam SEM merupakan yang paling *controversial* dan banyak diperdebatkan. Kontroversi ini timbul karena perlakuan variabel ordinal yang dianggap sebagai variabel kontinyu, di bidang psikologi perdebatan ini sudah terselesaikan karena penggunaan variabel ordinal dengan skala *Likert* dianggap kontinyu atau interval.

Salah satu cara untuk mengatasi adanya data non-normal secara multivariat adalah menggunakan metode yang dikenal dengan nama *bootstrap*. Metode *bootstrap* pertama kali dikenalkan oleh Efron (1979 dan 1982) dan kemudian dikembangkan oleh Kotz dan Johnson (1992). Istilah *bootstrap* diambil dari “*to pull oneself up by the bootstraps*” yang memiliki makna bahwa sampel asli (*original*) akan menghasilkan tambahan berganda berikutnya. Jadi *bootstrap* merupakan prosedur *resampling* (pensampelan kembali) di mana sampel asli atau *original* diperlakukan sebagai populasi. *Multiple sub-sample* dengan ukuran sampel sama dengan sampel asli kemudian diambil secara random, dengan *replacement* dari populasi. Ide utama dari *bootstrap* adalah peneliti dapat menciptakan *multiple sample* dari *original data base*.

Dengan metode *bootstrap*, akan dilakukan analisis pada matriks kovarians populasinya. Untuk kasus *standard error* pada sampel *bootstrap* jika diketahui normal dari metode estimasi ML maka akan menghasilkan *standard error* yang kecil, sebaliknya jika diketahui non-normal, sampel *bootstrap* akan menghasilkan *standard error* yang besar. Begitu juga untuk nilai bias, bias yang mutlak kecil, menandakan distribusi empiris *bootstrap* hanya sedikit menyimpang dari distribusi normal.

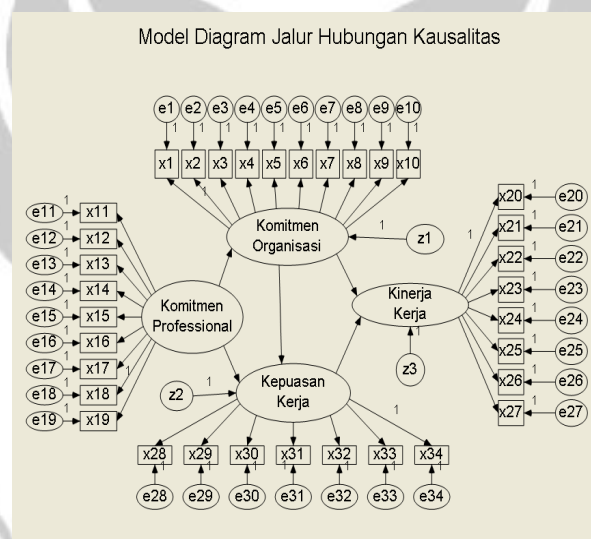
Keberhasilan analisis *bootstrap* tergantung pada sejauh mana perilaku sampling statistik saat sampel diambil dari distribusi empiris, dan ketika mereka diambil dari populasi asli. Akhirnya, ketika data multivariat normal, *bootstrap standard error* telah ditemukan lebih bias dari pada yang berasal dari metode ML. Sebaliknya, ketika distribusi yang mendasarinya tidak normal, perkiraan *bootstrap* kurang bias dari perkiraan ML. Hal ini merupakan fakta yang mendukung harapan teoritis.

## **4.2 Contoh Kasus dan Analisis Data**

### **4.2.1 Contoh Kasus**

Sebagai contoh kasus peneliti mengambil studi yang dilakukan oleh Ishak Soebekti (2002), yaitu menggunakan data penelitian mengenai model hubungan antara Komitmen Organisasi, Kinerja Kerja, Komitmen Profesional dan Kepuasan Kerja pada para Auditor yang bekerja di Badan Pengawasan Keuangan dan Pembangunan (BPKP). Model tersebut terdiri dari tiga variabel laten endogen, Komitmen Organisasi, Kinerja Kerja dan Kepuasan Kerja serta satu variabel

eksogen, Komitmen Profesional. Untuk model pengukuran laten endogen variabel laten Komitmen Organisasi diukur melalui variabel observasi X1, X2, X3, X4, X5, X6, X7, X8, X9, dan X10. Untuk model pengukuran laten endogen variabel laten Kinerja Kerja diukur melalui variabel observasi X20, X21, X22, X23, X24, X25, X26, X27, dan X28. Untuk model pengukuran laten endogen variabel laten Kepuasan Kerja diukur melalui variabel observasi X28, X29, X30, X31, X32, X33, dan X34. Serta untuk model pengukuran laten eksogen variabel laten Komitmen Profesional diukur melalui variabel observasi X11, X12, X13, X14, X15, X16, dan X17, X18, dan X19. Adapun model hubungan antara Komitmen Organisasi, Kinerja Kerja, Komitmen Profesional dan Kepuasan Kerja.



Gambar 4.1. Model hubungan antara Komitmen Organisasi, Kinerja Kerja, Komitmen Profesional dan Kepuasan Kerja

#### 4.2.2 Analisis Data

- a. Merubah Diagram Jalur ke dalam Persamaan Struktural dan Model Pengukuran.

Persamaan struktural dari model diagram jalur dinyatakan sebagai berikut:

$$KO = \beta_1 KP + z_1 \quad (1)$$

$$KPK = \beta_1 KP + \beta_2 KO + z_2 \quad (2)$$

$$KK = \beta_2 KO + \beta_3 KPK + z_3 \quad (3)$$

Keterangan

KO = Komitmen Organisasi

KP = Komitmen Profesional

KPK = Kepuasan Kerja

KK = Kinerja Kerja

Sedangkan spesifikasi terhadap model pengukuran adalah sebagai berikut:

Variabel Laten Eksogen Komitmen Profesional

$$X_{11} = \lambda_{11} KP + e_{11} \quad X_{16} = \lambda_{16} KP + e_{16}$$

$$X_{12} = \lambda_{12} KP + e_{12} \quad X_{17} = \lambda_{17} KP + e_{17}$$

$$X_{13} = \lambda_{13} KP + e_{13} \quad X_{18} = \lambda_{18} KP + e_{18}$$

$$X_{14} = \lambda_{14} KP + e_{14} \quad X_{19} = \lambda_{19} KP + e_{19}$$

$$X_{15} = \lambda_{15} KP + e_{15}$$

Variabel Laten Endogen Komitmen Organisasi

$$X_1 = \lambda_1 KO + e_1 \quad X_6 = \lambda_6 KO + e_6$$

$$X2 = \lambda 2KO + e2$$

$$X7 = \lambda 7KO + e7$$

$$X3 = \lambda 3KO + e3$$

$$X8 = \lambda 8KO + e8$$

$$X4 = \lambda 4KO + e4$$

$$X9 = \lambda 9KO + e9$$

$$X5 = \lambda 5KO + e5$$

$$X10 = \lambda 10KO + e10$$

Variabel Laten Endogen Kepuasan Kerja

$$X28 = \lambda 28KPK + e28$$

$$X32 = \lambda 32KPK + e32$$

$$X29 = \lambda 29KPK + e29$$

$$X33 = \lambda 33KPK + e33$$

$$X30 = \lambda 30KPK + e30$$

$$X34 = \lambda 34KPK + e34$$

$$X31 = \lambda 31KPK + e31$$

Variabel Laten Endogen Kinerja Kerja

$$X20 = \lambda 20KK + e20$$

$$X24 = \lambda 24KK + e24$$

$$X21 = \lambda 21KK + e21$$

$$X25 = \lambda 25KK + e25$$

$$X22 = \lambda 22KK + e22$$

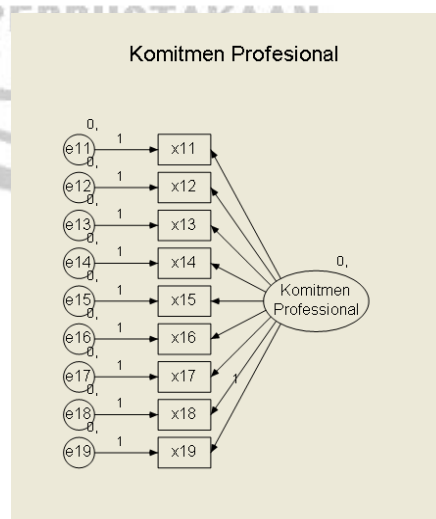
$$X26 = \lambda 26KK + e26$$

$$X23 = \lambda 23KK + e23$$

$$X27 = \lambda 27KK + e27$$

b. Analisis Konfirmatori Variabel Laten

1) Analisis konfirmatori variabel laten eksogen Komitmen Profesional





Gambar 4.2. Analisis Konfirmatori Variabel Laten Eksogen  
Komitmen Profesional

a) *Chi-square*

Statistik Uji:

$$\chi^2 = (n - 1) \log \left| \sum (\theta) \right| + \text{tr}[\mathbf{S}\Sigma^{-1}(\theta) - \log|\mathbf{S}| - (p + q)]$$

Kriteria Uji:

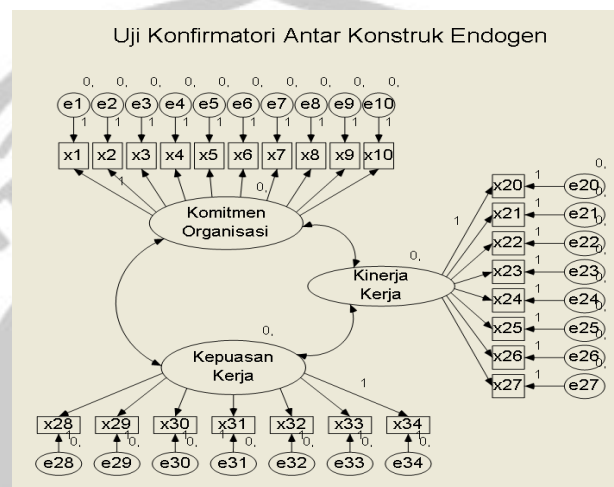
$H_0$  ditolak jika  $\chi^2_{\text{hitung}} > \chi^2(\alpha, \text{df})$  dengan  $\text{df} = \frac{1}{2}(p + q)(p + q + 1) - t$ , atau dengan menggunakan probabilitas p-value,  $H_0$  ditolak jika  $p\text{-value} < \alpha$ .

Berdasarkan output AMOS 16.0 pada Lampiran 2b, diperoleh angka *Chi-square* sebesar 131,642 dengan derajat kebebasan (df) 27 dengan p-value sebesar 0,000. Dengan mengambil tingkat signifikan ( $\alpha$ ) 0,05 maka  $H_0$  pada pengujian hipotesis ditolak. Sehingga dapat dikatakan model ditolak. Dan ada tiga indikator yang tidak signifikan yaitu X13, X14, dan X17 karena memiliki nilai *convergen validity* di bawah 0,50. Sehingga X13, X14, dan X17 *drop out*. Kemudian kita lakukan revisi, pemodelan ulang.

Setelah dilakukan pemodelan ulang, hasil analisis berdasarkan output AMOS 16.0 pada Lampiran 3a, menunjukkan nilai *Chi-square* sebesar 18,133 dengan p-value sebesar 0,034 dengan df 9 dan  $\alpha$  0,05 masih tidak fit. Namun nilai fit lainnya seperti TLI dan RMSEA

menunjukkan nilai fit. TLI sebesar  $0,976 > 0,90$  dan RMSEA sebesar  $0,077 < 0,80$ .

- 2) Analisis konfirmatori antar variabel laten endogen Komitmen Organisasi, Kepuasan Kerja, dan Kinerja Kerja.



Gambar 4.3. Analisis Konfirmatori Variabel Laten Endogen Variabel Komitmen Organisasi, Kepuasan Kerja, dan Kinerja Kerja

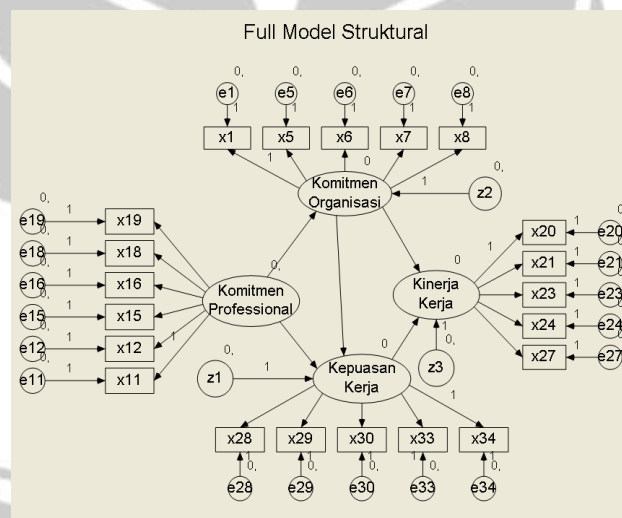
Berdasarkan output AMOS 16.0 pada Lampiran 4a, diperoleh angka *Chi-square* sebesar 894,663 dengan derajat kebebasan (df) 272 dengan p-value sebesar 0,000. Dengan mengambil tingkat signifikan ( $\alpha$ ) 0,05 maka  $H_0$  pada pengujian hipotesis ditolak. Sehingga dapat dikatakan model ditolak. Dan ada beberapa indikator yang tidak signifikan yaitu X2, X3, X4, X9, X10, X22, X25, X26, X31, dan X32 karena memiliki nilai *convergen validity* di bawah 0,50. Sehingga X2,

X3, X4, X9, X10, X22, X25, X26, X31, dan X32 *drop out*. Seperti analisis sebelumnya, kita lakukan revisi, pemodelan ulang.

Setelah dilakukan pemodelan ulang, hasil analisis berdasarkan output AMOS 16.0 pada Lampiran 5a, menunjukkan nilai *Chi-square* sebesar 98,601 dengan p-value sebesar 0,186 dengan df 87 dan  $\alpha$  0,05 telah fit. Begitu nilai fit lainnya seperti TLI dan RMSEA menunjukkan nilai fit. TLI sebesar  $0,986 > 0,90$  dan RMSEA sebesar  $0,028 < 0,80$ .

### c. Estimasi Parameter Full Model

Setelah dilakukan analisis konfirmatori langkah selanjutnya melakukan estimasi model *full structural* yang hanya memasukkan indikator yang telah diuji dengan konfirmatori. Berikut ini tampilannya.



Gambar 4.4. Analisis Full Model Struktural

Berdasarkan output AMOS 16.0, pada Lampiran 6a, model persamaan struktural ini ternyata telah memenuhi kriteria model fit yaitu ditunjukkan dengan nilai *Chi-square* sebesar 208,784 dengan probabilitas nilai p-value sebesar 0,102 dengan df 184 dan  $\alpha$  0,05. Begitu juga dengan

nilai kriteria lainnya seperti TLI sebesar  $0,983 > 0,90$  dan RMSEA sebesar  $0,028 < 0,08$ . Maka dapat disimpulkan bahwa model persamaan struktural adalah fit.

#### d. Pengujian Evaluasi Asumsi Model Struktural

##### 1) Normalitas Data

###### Uji Normalitas Multivariat

###### Uji Hipotesis

$H_0$  : data mengikuti distribusi normal multivariat

$H_1$  : data tidak mengikuti distribusi normal multivariat

###### Statistik Uji

$$Z_{skweness} = \frac{\text{skweness}}{\sqrt{\frac{6}{N}}} ; \quad Z_{kurtosis} = \frac{\text{kurtosis}}{\sqrt{\frac{24}{N}}}$$

###### Kriteria Uji

$H_0$  ditolak jika  $Z_{skweness} > z(\alpha)$  atau  $Z_{kurtosis} > z(\alpha)$ . Jika menggunakan *software*  $H_0$  ditolak jika nilai *critical ratio skewness value* di atas harga mutlak 2,58 untuk  $\alpha$  0,01 atau 1,96 untuk  $\alpha$  0,05.

###### Kesimpulan

Dari Lampiran 7, diperoleh nilai *critical rasio skewness value* semua indikator menunjukkan distribusi normal karena nilainya di bawah 2,58 kecuali indikator X21 yang memiliki *critical rasio* di atas 2,58 yaitu dengan nilai -2,636. Sedangkan uji normalitas multivariat memberikan nilai *critical rasio* 2,608 sedikit

di atas nilai 2,58. Jadi secara multivariat berdistribusi tidak normal.

e. Metode *Bootstrap* untuk Mengatasi Pelanggaran Asumsi Normal Multivariat

Analisis di atas menunjukkan bahwa data tidak mengikuti distribusi normal secara multivariat. Jika kita tetap melakukan analisis selanjutnya maka akan terjadi pelanggaran asumsi normal multivariat. Untuk mengatasi pelanggaran ini, kita gunakan metode alternatif dalam SEM yaitu metode *bootstrap*.

Metode *bootstrap* berbasis *resampling*, dalam analisis ini, peneliti melakukan *resampling* sebanyak 500 kali dan *bias corrected confidence intervals* sebesar 90%. Hasil uji *Goodness-of-fit*:

a) Uji *Chi-square*

Statistik Uji:

$$\chi^2 = (n - 1) \log \left| \sum (\theta) \right| + \text{tr}[\Sigma^{-1}(\theta) - \log|S| - (p + q)]$$

Kriteria Uji:

$H_0$  ditolak jika  $\chi^2_{\text{hitung}} > \chi^2(\alpha, \text{df})$  dengan  $\text{df} = \frac{1}{2}(p + q)(p + q + 1) - t$ , atau dengan menggunakan probabilitas p-value,  $H_0$  ditolak jika  $p\text{-value} < \alpha$ .

Berdasarkan output AMOS 16.0 pada Lampiran 10b, diperoleh angka *Chi-square* sebesar 208,784 dengan derajat kebebasan (df) 184 dengan p-value sebesar 0,102. Dengan

mengambil tingkat signifikan ( $\alpha$ ) 0,05 maka  $H_0$  pada pengujian hipotesis ditolak. Sehingga dapat dikatakan model diterima.

b) Uji RMSEA (*Root Mean Square Error Aproximate*)

Statistik Uji:

$$RMSEA = \sqrt{\frac{\hat{F}_0}{df}}$$

dengan

$$\hat{F}_0 = \frac{\chi^2_{\text{model}} - df}{N} = \frac{208,784 - 184}{175} = 0,028$$

Kriteria Uji:

Model dikatakan baik jika nilai RMSEA < 0,08.

Perhitungan RMSEA di atas sesuai dengan output AMOS 16.0 pada Lampiran 10b, yang menunjukkan nilai RMSEA sebesar 0,028 < 0,08. Sehingga dapat dikatakan bahwa model baik.

Hasil estimasi parameter dari output AMOS 16.0 untuk *Regression Weights* pada Lampiran 10a dan *bootstrap standard error* pada Lampiran 10c diperoleh sebagai berikut:

Tabel 4.1. Hasil Estimasi Parameter dan *Standard Error*

Parameter			Estimasi	SE ML	SE Bootstrap
Komitmen_Organisasi	<---	Komitmen_Profesional	0,224	0,087	0,091
Kepuasan_Kerja	<---	Komitmen_Profesional	0,205	0,104	0,107
Kepuasan_Kerja	<---	Komitmen_Organisasi	0,282	0,117	0,130
Kinerja_Kerja	<---	Komitmen_Organisasi	0,204	0,104	0,125
Kinerja_Kerja	<---	Kepuasan_Kerja	0,166	0,078	0,085
X1	<---	Komitmen_Organisasi	1,000	0,000	0,000

X5	<---	Komitmen_Organisasi	1,332	0,168	0,179
X6	<---	Komitmen_Organisasi	1,110	0,154	0,135
X7	<---	Komitmen_Organisasi	1,151	0,156	0,179
X8	<---	Komitmen_Organisasi	1,130	0,152	0,160
X11	<---	Komitmen_Profesional	1,000	0,000	0,000
X12	<---	Komitmen_Profesional	1,350	0,142	0,139
X15	<---	Komitmen_Profesional	1,141	0,137	0,131
X16	<---	Komitmen_Profesional	1,426	0,145	0,143
X18	<---	Komitmen_Profesional	1,334	0,151	0,144
X19	<---	Komitmen_Profesional	1,176	0,129	0,124
X20	<---	Kinerja_Kerja	1,000	0,000	0,000
X21	<---	Kinerja_Kerja	0,856	0,124	0,126
X23	<---	Kinerja_Kerja	0,957	0,113	0,105
X24	<---	Kinerja_Kerja	1,032	0,121	0,116
X27	<---	Kinerja_Kerja	0,915	0,120	0,117
X34	<---	Kepuasan_Kerja	1,000	0,000	0,000
X33	<---	Kepuasan_Kerja	1,022	0,085	0,064
X30	<---	Kepuasan_Kerja	0,926	0,091	0,102
X29	<---	Kepuasan_Kerja	1,007	0,104	0,103
X28	<---	Kepuasan_Kerja	0,848	0,087	0,077

Hasil dari nilai *standard error* di atas harus dibandingkan, untuk variabel laten Komitmen Profesional ke Komitmen Organisasi antara *original sample* dengan *bootstrap sample* ada perbedaan sebesar  $(0,091 - 0,087) = 0,004$  yang berarti terdapat kenaikan 4,59% *standard error* dari *bootstrap* dibandingkan dengan *standard error* dari *original sample*. Variabel laten Komitmen Profesional ke Kepuasan Kerja antara *original sample* dengan *bootstrap sample* ada perbedaan sebesar  $(0,107 - 0,104) = 0,003$  yang berarti terdapat kenaikan 2,88% *standard error* dari *bootstrap* dibandingkan dengan *standard error* dari *original sample*. Variabel laten Komitmen Organisasi ke Kepuasan Kerja antara *original sample* dengan *bootstrap sample* ada perbedaan

sebesar  $(0,130 - 0,117) = 0,013$  yang berarti terdapat kenaikan 11,11% *standard error* dari *bootstrap* dibandingkan dengan *standard error* dari *original sample*. Variabel laten Kepuasan Kerja ke Kinerja Kerja antara *original sample* dengan *bootstrap sample* ada perbedaan sebesar  $(0,085 - 0,078) = 0,007$  yang berarti terdapat kenaikan 8,97% *standard error* dari *bootstrap* dibandingkan dengan *standard error* dari *original sample*.

Tabel 4.2. *Bootstrap Standard Error*

Parameter			SE	SE-SE	Mean	Bias	SE-Bias
Komitmen_Organisasi	<---	Komitmen_Professional	.091	.003	.222	-.003	.004
Kepuasan_Kerja	<---	Komitmen_Professional	.107	.003	.205	.000	.005
Kepuasan_Kerja	<---	Komitmen_Organisasi	.130	.004	.276	-.006	.006
Kinerja_Kerja	<---	Komitmen_Organisasi	.125	.004	.217	.013	.006
Kinerja_Kerja	<---	Kepuasan_Kerja	.085	.003	.168	.001	.004
x1	<---	Komitmen_Organisasi	.000	.000	1.000	.000	.000
x5	<---	Komitmen_Organisasi	.179	.006	1.349	.017	.008
x6	<---	Komitmen_Organisasi	.135	.004	1.116	.006	.006
x7	<---	Komitmen_Organisasi	.179	.006	1.163	.012	.008
x8	<---	Komitmen_Organisasi	.160	.005	1.144	.014	.007
x11	<---	Komitmen_Professional	.000	.000	1.000	.000	.000
x12	<---	Komitmen_Professional	.139	.004	1.358	.008	.006
x15	<---	Komitmen_Professional	.131	.004	1.141	.001	.006
x16	<---	Komitmen_Professional	.143	.005	1.434	.008	.006
x18	<---	Komitmen_Professional	.144	.005	1.340	.007	.006
x19	<---	Komitmen_Professional	.124	.004	1.188	.012	.006
x20	<---	Kinerja_Kerja	.000	.000	1.000	.000	.000
x21	<---	Kinerja_Kerja	.126	.004	.867	.011	.006
x23	<---	Kinerja_Kerja	.105	.003	.961	.004	.005
x24	<---	Kinerja_Kerja	.116	.004	1.038	.006	.005
x27	<---	Kinerja_Kerja	.117	.004	.921	.006	.005
x34	<---	Kepuasan_Kerja	.000	.000	1.000	.000	.000
x33	<---	Kepuasan_Kerja	.064	.002	1.025	.004	.003



Parameter		SE	SE-SE	Mean	Bias	SE-Bias
x30	<--- Kepuasan_Kerja	.102	.003	.931	.005	.005
x29	<--- Kepuasan_Kerja	.103	.003	1.012	.005	.005
x28	<--- Kepuasan_Kerja	.077	.002	.852	.004	.003

Kolom kedua dengan label S.E.S.E adalah *approximate standard error* dari *bootstrap standard error* itu sendiri. Seperti dapat dilihat bahwa nilainya kecil. Kolom ketiga dengan label *Mean* yaitu nilai parameter *mean* yang dihitung dari 500 sampel *bootstrap* dan nilai ini tidak harus identik besarnya dengan *mean original estimate*. Kolom keempat dengan label *Bias* menggambarkan perbedaan antara *mean bootstrap* yang lebih tinggi dibandingkan dengan *mean original sample* dan kolom terakhir dengan label S.E bias merupakan *approximate standard error* dari bias *estimate*.

Kita dapat menggunakan *bootstrap* Mean dan kolom SE untuk menghitung nilai rasio kritis berdasarkan hasil *bootstrap*. *Standard error* estimasi sampel *bootstrap* lebih besar dari *standard error original sample*. Meskipun lebih besar tetapi selisihnya kecil, perbedaan ini menandakan bahwa *bootstrap* tidak jauh berbeda dengan ML.

Rasio kritis yang dihasilkan dari sampel *bootstrap* dapat diperoleh dengan membagi estimasi parameter sampel *bootstrap* dengan *standard error* estimasi. Untuk menguji, kita bisa menggunakan nilai p-nilai pada *bias-corrected percentile*. Pada

Lampiran 10d, dengan interval kepercayaan 90%, variabel laten Komitmen Profesional ke Komitmen Organisasi adalah 0,006; variabel laten Komitmen Profesional ke Kepuasan Kerja adalah 0,053; variabel laten Komitmen Organisasi ke Kepuasan Kerja adalah 0,019; variabel laten Komitmen Organisasi ke Kinerja Kerja adalah 0,055; dan variabel laten Kepuasan Kerja ke Kinerja Kerja adalah 0,058. Jadi hubungan antar variabel laten signifikan. Dan model sesuai yang dihipotesiskan dapat diterima.

## 2) Evaluasi *Outlier*

Deteksi terhadap multivariat *outlier* dilakukan dengan memperhatikan nilai *mahalanobis distance*.

Statistik Uji:

*Chi-square* (df;  $\alpha$ ), di mana df jumlah variabel indikator pada  $\alpha$  0,001.

Kriteria Uji:

Akan terjadi multivariat jika nilai Nilai *mahalanobis distance* > *Chi-square*. Model yang baik adalah, apabila tidak ada nilai *mahalanobis distance* yang lebih besar dari *Chi-square* (df;  $\alpha$ ).

Hasil analisis output AMOS 16.0 pada Lampiran 8, menunjukkan bahwa semua nilai *mahalanobis distance* < *Chi-square* (df;  $\alpha$ ). Dengan df sebesar 34 dan  $\alpha$  0,001, nilai  $\chi^2$  (34; 0,001) = 56,25. Jadi tidak ada *outlier* pada data.

## 3) Evaluasi Multikolinieritas

Multikolinieritas dapat dilihat melalui determinan matrik kovarian. Nilai determinan yang sangat kecil menunjukkan indikasi terdapatnya masalah multikolinieritas atau singularitas, sehingga data tidak dapat digunakan untuk penelitian.

Hasil output AMOS pada Lampiran 9, memberikan nilai *determinan of sample covariance matrix* sebesar 5,856. Nilai ini jauh dari angka nol sehingga dapat disimpulkan bahwa tidak terdapat masalah multikolinieritas dan singularitas pada data yang dianalisis.

f. Estimasi Nilai Parameter

Dari hasil output AMOS 16.0 untuk koefisien parameter pada Lampiran 2a, jelas bahwa semua hipotesis diterima hubungan variabel Komitmen Profesional ke Komitmen Organisasi signifikan dengan *standardized* koefisien parameter sebesar 0,236 (H1), hubungan variabel Komitmen Organisasi ke Kinerja Kerja dengan *standardized* koefisien parameter sebesar 0,189 (H2). Hubungan antar variabel Kepuasan Kerja ke Kinerja Kerja juga signifikan dengan nilai *standardized* koefisien sebesar 0,197 (H3), hubungan Komitmen Profesional ke Kepuasan Kerja signifikan dengan nilai *standardized* koefisien sebesar 0,164 (H4) dan hubungan Komitmen Organisasi ke Kepuasan Kerja dengan nilai *standardized* koefisien sebesar 0,221 (H5).

Dipeoleh estimasi model struktural adalah sebagai berikut:

$$KO = 0,236 KP;$$

$$KPK = 0,164 KP + 0,221 KO$$

$$KK = 0,189 KO + 0,197 KPK$$

g. Pengukuran Model Fit

a) Uji Reliabilitas

$$\text{Construct Reliability} = \frac{(\sum \text{standardized loading})^2}{(\sum \text{standardized loading})^2 + \sum \epsilon_j}$$

*Standardized loading* diperoleh langsung dari *standardized loading* untuk tiap-tiap indikator

$\epsilon_j$  adalah *measurement error* =  $1 - (\text{standardized loading})^2$

Sum *standardized loading* untuk :

$$\begin{aligned} \text{Komitmen Organisasi} &= 0,639 + 0,819 + 0,664 + 0,719 + 0,700 \\ &= 3,541 \end{aligned}$$

$$\begin{aligned} \text{Komitmen Profesional} &= 0,651 + 0,858 + 0,732 + 0,912 + 0,783 + \\ &0,811 = 4,747 \end{aligned}$$

$$\text{Kepuasan Kerja} = 0,762 + 0,880 + 0,788 + 0,763 + 0,737 = 3,930$$

$$\text{Kinerja Kerja} = 0,784 + 0,596 + 0,713 + 0,748 + 0,642 = 3,483$$

Sum *measurement error* untuk :

$$\begin{aligned} \text{Komitmen Organisasi} &= 0,592 + 0,329 + 0,559 + 0,483 + 0,510 \\ &= 2,473 \end{aligned}$$

$$\begin{aligned} \text{Komitmen Profesional} &= 0,576 + 0,264 + 0,464 + 0,168 + 0,387 + \\ &0,342 = 2,201 \end{aligned}$$

$$\text{Kepuasan Kerja} = 0,419 + 0,226 + 0,379 + 0,418 + 0,457 = 1,899$$

$$\text{Kinerja Kerja} = 0,385 + 0,645 + 0,492 + 0,441 + 0,588 = 2,551$$

Perhitungan Reliabilitas :

$$\text{Komitmen Organisasi} = \frac{(3,541)^2}{(3,541)^2 + 2,473} = 0,835$$

$$\text{Komitmen Profesional} = \frac{(4,747)^2}{(4,747)^2 + 2,201} = 0,911$$

$$\text{Kepuasan Kerja} = \frac{(3,930)^2}{(3,930)^2 + 1,899} = 0,891$$

$$\text{Kinerja Kerja} = \frac{(3,483)^2}{(3,483)^2 + 2,551} = 0,826$$

Reliabilitas untuk masing-masing variabel laten semua nilainya di atas *cut-off value* 0,70.

b) *Variance Extracted*

Besarnya nilai *variance extracted* dihitung dengan rumus sebagai berikut:

$$\text{Variance Extracted} = \frac{\sum \text{standardized loading}^2}{\sum \text{standardized loading}^2 + \sum \epsilon_j}$$

*Sum of squared standardized loading :*

$$\begin{aligned} \text{Komitmen Organisasi} &= 0,639^2 + 0,819^2 + 0,664^2 + 0,719^2 + 0,700^2 \\ &= 2,527 \end{aligned}$$

$$\begin{aligned} \text{Komitmen Profesional} &= 0,6512 + 0,8582 + 0,7322 + 0,9122 + 0,7832 \\ &\quad + 0,8112 = 3,799 \end{aligned}$$

$$\begin{aligned} \text{Kepuasan Kerja} &= 0,7622 + 0,8802 + 0,7882 + 0,7632 + 0,7372 \\ &= 3,101 \end{aligned}$$

$$\begin{aligned} \text{Kinerja Kerja} &= 0,7842 + 0,5962 + 0,7132 + 0,7482 + 0,6422 \\ &= 2,450 \end{aligned}$$

Perhitungan *variance extracted* :

$$\text{Komitmen Organisasi} = \frac{2,527}{2,527 + 2,473} = 0,505$$

$$\text{Komitmen Profesional} = \frac{3,799}{3,799 + 2,201} = 0,633$$

$$\text{Kepuasan Kerja} = \frac{3,101}{3,101 + 1,899} = 0,620$$

$$\text{Kinerja Kerja} = \frac{2,450}{2,450 + 2,551} = 0,490$$

Hasil perhitungan *variance extracted* menunjukkan bahwa semua variabel laten memenuhi syarat *cut-off value* minimal 0,50, kecuali untuk variabel Kinerja Kerja dengan nilai *variance extracted* 0,490.

c) Uji *Diskriminant Validity*

Nilai akar kuadrat dari AVE variabel laten sebagai berikut :

$$\text{Komitmen Organisasi} = \sqrt{0,505} = 0,711$$

$$\text{Komitmen Profesional} = \sqrt{0,633} = 0,796$$

$$\text{Kepuasan Kerja} = \sqrt{0,620} = 0,787$$

$$\text{Kinerja Kerja} = \sqrt{0,490} = 0,700$$

Berikut ini hasil output korelasi antar variabel laten dan akar kuadrat AVE.

Tabel 4.3. Korelasi antar Variabel Laten dan Akar Kuadrat AVE

	Komitmen Profesional	Komitmen Organisasi	Kepuasan Kerja	Kinerja Kerja
Komitmen Profesional	<b>0,796</b>			
Komitmen Organisasi	0,236	<b>0,711</b>		
Kepuasan Kerja	0,221	0,261	<b>0,787</b>	
Kinerja Kerja	0,088	0,241	0,247	<b>0,700</b>

Berdasarkan tabel di atas jelas bahwa masing-masing variabel laten memiliki diskriminant *validity* yang baik, hal ini dapat dilihat dari nilai akar kuadrat AVE masing-masing variabel laten yang lebih tinggi nilainya dibandingkan dengan nilai korelasi antara variabel laten.

### 4.3 Pembahasan

Sekarang ini banyak penelitian yang menggunakan analisis SEM. Karena SEM mampu menganalisis hubungan sebab akibat antar variabel yang di dalamnya memuat variabel laten, di mana proses pengolahannya dapat melibatkan kekeliruan dalam pengukuran dari variabel indikator dan variabel laten.

Topik yang paling menarik dalam analisis SEM adalah estimasi parameter. Estimasi parameter dalam SEM yang umumnya menggunakan metode ML, di mana metode ML ini menghedaki adanya asumsi yang harus dipenuhi. Asumsi yang paling fundamental adalah distribusi dari *observed* variabel normal secara multivariat. Asumsi lainnya adalah skala pengukuran variabel harus kontinu.

Meskipun dalam berbagai penelitian banyak digunakan data hasil kuisioner yang berskala ordinal itu telah dianggap sebagai skala kontinu karena digunakan skala *Likert*, dan apabila hasil dari data tersebut menghasilkan distribusi yang mendekati normal atau non-normal, maka akan diperoleh estimasi *standard error* untuk semua parameter cenderung rendah. Hal ini tidak diharapkan oleh para peneliti karena akan menghasilkan koefisien regresi dan *error covariance* yang signifikan secara statistik, walaupun hal ini tidak terjadi pada populasinya. Jadi hasil analisa tidak memberikan hasil yang diharapkan peneliti.

Metode *bootstrap* adalah metode baru yang dikembangkan oleh Bradley Efron pada tahun 1979. Sebagai sebuah konsep, sangat elegan namun sederhana, sistem kerja *bootstrap* adalah *resampling*. *Bootstrap* dapat digunakan untuk mengatasi asumsi non-normal multivariat dalam SEM, hal ini dikarenakan bahwa *bootstrap* tidak memiliki asumsi normal multivariat.

Hasil analisis pada contoh kasus hubungan antar variabel laten Komitmen Organisasi, Kinerja Kerja, Komitmen Profesional dan Kepuasan Kerja pada para Auditor yang bekerja di Badan Pengawasan Keuangan dan Pembangunan (BPKP) menguatkan studi pustaka. Dari hasil analisis pada contoh kasus, dalam hal *bootstrap standard error* diperoleh lebih besar dari *standard error original* (ML), selisih antara *standard error bootstrap* dan *standard error* ML kecil, hal ini menunjukkan bahwa antara metode *bootstrap* dan metode ML tidak jauh berbeda, dari *standard error bootstrap* kita dapat menghitung nilai rasio kritis, dan mengujinya dengan menggunakan taraf signifikansi, jika p-nilai signifikan, model yang dihipotesiskan dapat diterima. Pada contoh kasus, digunakan taraf signifikansi 90%, dan hasilnya signifikan untuk setiap hubungan antar variabel laten. Jadi model yang dihipotesiskan diterima.

Hal ini menjadi pertimbangan untuk metode *bootstrap*, selain *bootstrap* tidak memiliki asumsi awal sebagai metode alternatif dalam mengatasi asumsi non-normal multivariat untuk mendapatkan estimasi model yang baik dalam analisis SEM ketika asumsi non-normal tidak dipenuhi oleh metode ML.



## BAB 5

### PENUTUP

#### 5.1 Simpulan

Berdasarkan hasil penelitian dan pembahasan dapat disimpulkan.

- (1) Metode *bootstrap* dapat menjadi metode alternatif bagi *Structural Equation Modeling* (SEM) dalam mengatasi asumsi non-normal multivariat, karena metode *bootstrap* tidak memiliki asumsi awal, terutama asumsi normal multivariat seperti dalam metode ML. Meskipun nilai *standard error bootstrap* lebih besar dari *standard error* ML, namun pada nilai rasio kritis yang dihasilkan oleh *bootstrap* menghasilkan nilai yang signifikan dengan taraf signifikan yang telah ditentukan. Hal ini yang menjadi pertimbangan bahwa metode *bootstrap* sebagai metode alternatif bagi SEM mampu mengatasi asumsi non-normal multivariat ketika menggunakan metode ML untuk mendapatkan estimasi model yang baik.
- (2) Langkah-langkah dalam menganalisis dengan metode *bootstrap* untuk mengatasi asumsi non-normal multivariat dalam *Structural Equation Modeling* (SEM) untuk mendapatkan estimasi model terbaik adalah sebagai berikut.
  - a. Menyusun kerangka pemikiran teoritis dalam bentuk hipotesis.
  - b. Membentuk diagram jalur hubungan kausalitas.
  - c. Menguji konfirmatori untuk variabel laten.

- d. Mengestimasi persamaan full model.
- e. Menguji evaluasi asumsi model struktural.
- f. Jika diketahui adanya pelanggaran terhadap asumsi normalitas multivariat maka dilakukan analisis menggunakan metode *bootstrap*.
- g. Menilai estimasi parameter.
- h. Pengukuran model fit.

## 5.2 Saran

Berdasarkan simpulan maka saran yang dapat disampaikan adalah sebagai berikut:

- a. Jika menjumpai data yang tidak normal secara multivariat dalam SEM tidak perlu panik, karena *bootstrap* dapat mengatasi masalah penyimpangan normalitas.
- b. Dalam mengestimasi model pada SEM perlu diperhatikan pemilihan metode estimasi yang tepat sesuai dengan data yang diperoleh dari penelitian.
- c. Dalam mengatasi masalah data yang tidak berdistribusi normal pada analisis SEM, dapat digunakan metode selain *bootstrap*, yaitu *jackknifing*, penggunaan *Scaled Chi-square*, *Robust Standard Error*, estimasi dengan WLS, dan lainnya sehingga dapat dibandingkan hasilnya.
- d. Peneliti menggunakan *software* AMOS 16.0 dalam analisis SEM ini, disarankan untuk menggunakan *software* lain seperti SAS dan CALIS, LISREL, STATISTICA, MPLUS, dan sebagainya.

## DAFTAR PUSTAKA

- Ghozali, Imam. 2005. *Aplikasi Analisis Multivariat dengan Program SPSS*. Semarang: Universitas Diponegoro.
- Ghozali, Imam. 2008. *Metode Persamaan Struktural Konsep dan Aplikasi dengan Program AMOS 16.0*. Semarang: Universitas Diponegoro.
- Ghozali, Imam. 2005. *Structural Equation Modelling Teori, Konsep dan Aplikasi dengan Program Lisrel 8.54*. Semarang: Universitas Diponegoro.
- No Name. *Amos Development Corporation*. Tersedia di: [http://www.amosdevelopment.com/support/faq/bootstrap\\_standard\\_errors.htm](http://www.amosdevelopment.com/support/faq/bootstrap_standard_errors.htm)[7 Maret 2010]
- No Name. 2010. *Bootstrap*. Tersedia di: <http://www.biostat.umn.edu/~melanie/PH7435/2002/Bootstrap/bootstrap.html>[6 April 2010]
- No Name. 2010. *Konsultan Statistik: 7 Langkah SEM*. Tersedia di: <http://www.facebook.com/notes.php?id=251613701564&start=10>[22 Februari 2010]
- No Name. 2010. *Investigation of Bootstrap Estimates of the Parameters, Their Standard Errors, and Associated Confidence Intervals of Structural Equation Modeling with Ordered Categorical Variables*. Tersedia di: <http://etd.lib.ttu.edu/theses/available/etd-0731200831295014767379/unrestricted/31295014767379.pdf> [31 Agustus 2010]
- No Name. 2010. *Structural Equation Modeling with AMOS Basic Concepts, Applications, and Programming*. Tersedia di: [http://books.google.co.id/books?id=rxViMpn\\_9oC&pg=PA270&dq=SEM,standard+error,+bootstrap&hl=id&ei=tYV8TK7-B4P0vQO17bjDAg&sa=X&oi=book\\_result&ct=result&resnum=4&ved=0CDwQ6AEwAw#v=onepage&q=SEM%2Cstandard%20error%2C%20bootstrap&f=false](http://books.google.co.id/books?id=rxViMpn_9oC&pg=PA270&dq=SEM,standard+error,+bootstrap&hl=id&ei=tYV8TK7-B4P0vQO17bjDAg&sa=X&oi=book_result&ct=result&resnum=4&ved=0CDwQ6AEwAw#v=onepage&q=SEM%2Cstandard%20error%2C%20bootstrap&f=false)[30 AGUSTUS 2010]
- Ramadiani. 2010. *Structural Equation Model untuk Analisis Multivariate menggunakan Lisrel*. Jurnal Informatika Mulawarman, 5(1): 15-18.
- Supranto, J. 2004. *Analisis Multivariat Arti dan Interpretasi*. Jakarta: Rineka Cipta.



Lampiran 1. Data- Penelitian

Komitmen Organisasi, Kinerja Kerja, Komitmen Profesional dan Kepuasan Kerja pada para Auditor yang bekerja di Badan Pengawasan Keuangan dan Pembangunan (BPKP)

No	Komitmen Organisasi									Komitmen Profesional									Kinerja Kerja				Kepuasan Kerja							
	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	X11	X12	X13	X14	X15	X16	X17	X18	X19	X20	X21	X22	X23	X24	X25	X30	X31	X32	X33	X34
1	4	4	4	2	4	4	4	2	2	4	2	1	4	4	3	1	4	2	2	3	3	2	2	4	4	2	3	5	2	3
2	4	4	2	3	4	4	4	4	3	4	2	2	4	4	3	3	4	4	2	4	3	4	4	4	2	3	2	4	3	3
3	2	5	5	2	2	2	2	2	4	3	3	1	2	2	2	3	2	4	3	4	2	4	4	5	5	2	4	4	4	3
4	3	1	1	3	3	3	3	4	1	1	3	4	3	3	4	4	3	4	4	4	4	4	2	1	1	3	1	3	1	1
5	3	4	4	3	3	3	3	5	3	2	3	4	3	3	2	2	3	4	3	4	2	4	4	5	5	5	4	4	5	5
6	3	2	2	2	3	3	3	4	2	3	3	4	3	3	3	4	3	5	4	4	3	5	5	2	2	2	2	2	2	2
7	2	4	2	3	2	2	2	2	3	3	3	4	2	2	1	1	2	1	2	2	1	1	2	4	2	3	4	4	3	2
8	2	5	3	4	2	2	2	4	2	1	2	3	2	2	1	1	2	1	4	2	1	1	3	5	3	4	3	5	2	4
9	3	2	2	2	3	3	3	2	3	3	2	3	3	3	2	3	3	1	3	3	2	1	3	2	2	2	4	2	3	2
10	2	5	5	4	2	2	2	4	4	2	4	4	2	2	4	4	2	3	4	3	4	3	3	5	5	4	5	5	4	4
11	3	4	4	3	3	3	3	4	3	2	2	1	3	3	2	3	3	1	3	1	2	1	3	4	4	3	3	4	3	2
12	3	3	3	3	3	3	3	3	3	4	3	4	3	3	3	4	3	4	4	2	3	4	3	5	5	5	3	3	5	5
13	2	2	2	2	3	3	2	3	2	4	2	1	2	3	2	3	3	1	3	2	2	1	2	2	2	2	1	2	2	2
14	5	4	2	3	1	5	2	3	3	3	2	1	5	1	1	3	5	1	3	3	1	1	4	4	2	3	3	4	3	2
15	2	5	5	4	3	2	1	3	4	2	4	4	2	3	4	5	2	2	5	4	4	2	4	5	5	4	5	5	4	4
16	3	4	1	3	4	4	5	4	3	5	2	1	3	4	2	2	4	1	2	2	2	1	1	4	1	3	3	4	3	3
17	3	4	4	3	4	1	5	2	3	5	3	1	3	4	1	3	1	1	3	3	1	1	3	4	4	3	4	4	3	2
18	3	5	5	4	4	1	5	4	4	5	4	3	3	4	3	4	1	5	4	1	3	5	2	5	5	4	5	5	4	2
19	3	1	1	1	3	3	5	2	2	3	1	1	3	3	2	2	3	2	2	4	2	2	1	1	1	1	2	1	2	2
20	1	1	1	1	1	1	2	4	2	5	5	4	1	1	4	4	1	3	4	1	4	3	2	1	1	1	3	2	2	1
21	2	2	4	2	2	2	2	5	2	1	2	1	2	2	1	3	2	2	3	1	1	2	1	4	5	4	3	2	4	5
22	3	4	4	3	3	3	4	4	3	2	3	2	3	3	3	2	3	4	2	3	3	4	1	4	4	3	4	4	3	3
23	4	4	3	3	4	4	3	4	3	2	4	3	4	4	3	3	4	4	3	2	3	4	2	4	3	3	3	4	3	3

24	1	2	3	2	1	1	1	3	3	3	4	4	1	1	4	3	1	3	3	2	4	3	1	2	3	2	3	2	3	3
25	1	2	2	2	1	1	1	1	2	1	1	2	1	1	2	1	1	2	1	3	2	2	2	1	1	1	2	2	1	1
26	4	5	5	4	4	4	1	2	4	4	2	1	4	4	1	1	4	2	2	3	1	2	1	5	5	4	5	5	4	5
27	4	2	4	5	4	4	5	3	3	4	1	2	4	4	1	1	4	1	1	4	1	1	1	2	4	5	1	2	3	4
28	1	3	3	2	1	1	2	3	3	1	2	1	1	1	2	2	1	2	2	1	2	2	2	3	3	2	3	3	3	3
29	3	4	3	2	3	3	1	1	3	3	4	4	3	3	4	4	3	4	4	2	4	4	1	5	4	3	3	4	4	5
30	3	4	3	2	3	3	3	3	2	3	2	1	3	3	2	2	3	2	2	2	2	2	3	4	3	2	3	4	2	4
31	1	2	2	1	1	1	2	2	2	1	1	2	1	1	1	2	1	2	2	2	1	2	3	2	2	1	5	2	2	1
32	1	2	1	5	1	1	2	2	2	1	1	2	1	1	1	1	1	1	1	3	1	1	3	2	1	5	2	2	2	1
33	3	4	3	2	2	3	2	4	4	3	5	4	3	2	4	4	3	4	4	3	4	4	3	4	3	2	5	4	4	4
34	3	1	1	2	3	3	2	4	1	3	1	2	3	3	2	2	3	1	2	1	2	1	1	1	1	2	1	2	1	1
35	2	4	3	3	3	3	2	3	3	3	2	1	2	3	2	1	3	1	3	4	2	1	5	4	3	3	3	4	3	1
36	3	5	4	2	3	1	2	2	3	1	4	3	3	3	3	4	1	4	1	3	3	4	3	5	4	2	4	5	3	3
37	5	3	2	5	5	4	5	5	3	4	5	5	5	5	5	5	4	5	5	3	4	4	3	3	2	5	2	3	3	4
38	4	3	3	2	5	4	5	5	5	4	1	1	4	5	2	2	4	2	1	3	2	2	3	3	3	2	5	3	5	5
39	4	2	2	5	5	2	5	5	2	2	4	4	4	5	4	4	2	4	3	3	4	4	2	2	2	5	2	2	2	2
40	2	5	5	2	3	1	3	3	5	1	5	5	2	3	5	5	1	5	4	3	5	5	4	5	2	2	5	5	5	5
41	3	4	4	2	5	2	5	5	4	2	1	2	3	5	1	1	2	1	2	5	1	1	4	4	2	2	4	4	4	4
42	2	4	4	5	1	3	1	1	4	3	4	1	2	1	2	1	3	1	3	3	2	1	4	4	5	5	2	4	4	4
43	3	3	3	2	2	4	2	2	4	4	4	1	3	2	2	2	4	2	2	4	2	2	4	2	1	1	3	3	2	1
44	3	2	1	5	2	4	2	2	1	4	4	1	3	2	2	1	4	1	2	3	2	1	4	2	5	5	1	5	1	1
45	2	4	4	4	3	4	3	3	5	4	2	2	2	3	1	1	4	1	2	4	1	1	4	4	4	4	3	2	5	4
46	2	4	3	2	3	5	3	3	4	5	4	1	2	3	3	1	5	4	2	3	3	4	4	4	2	2	3	5	4	4
47	3	1	2	5	5	1	5	5	2	1	4	3	3	5	4	4	1	4	4	3	4	4	4	1	5	5	2	5	2	2
48	2	3	2	5	2	1	2	2	2	1	2	4	2	2	4	4	1	4	3	3	4	4	3	3	5	5	2	3	2	3
49	3	5	4	2	3	5	3	3	5	5	4	5	3	3	5	5	5	5	5	2	5	5	2	5	2	2	4	2	5	5
50	2	3	3	3	2	1	2	2	3	1	2	1	2	2	4	3	1	2	2	1	4	2	1	2	2	2	3	5	2	2
51	3	4	5	4	4	1	4	4	5	1	5	4	3	4	5	4	1	5	5	3	5	5	3	4	4	4	5	3	5	4
52	4	2	1	2	3	3	4	3	1	3	3	2	4	3	1	2	3	2	3	3	1	2	3	2	2	2	2	5	1	2

53	3	4	5	4	4	2	2	1	5	2	4	1	3	4	1	4	2	5	3	3	1	5	3	4	4	4	2	5	5	5
54	2	3	3	5	3	3	3	2	4	3	1	4	2	3	2	4	3	2	4	3	2	2	3	3	5	5	4	2	4	5
55	2	1	2	2	2	2	2	2	2	2	2	1	2	2	1	2	2	2	2	2	1	2	2	1	2	2	2	5	2	2
56	1	2	2	4	1	1	1	1	3	1	5	2	1	1	1	1	1	1	2	4	1	1	3	2	4	4	2	3	3	2
57	3	5	5	5	3	3	3	3	5	3	5	4	3	3	4	4	3	4	3	3	4	4	3	5	5	5	2	3	5	5
58	2	2	1	2	2	2	2	2	2	2	5	2	2	2	1	2	2	1	2	1	1	1	1	2	2	2	2	5	2	2
59	5	2	1	2	5	5	5	5	2	5	5	1	5	5	1	1	5	5	3	4	1	5	3	2	2	2	2	5	2	1
60	3	1	1	1	3	5	3	3	2	5	2	1	3	3	3	3	5	5	2	2	3	5	2	1	1	1	5	4	2	2
61	4	3	4	4	4	4	4	4	3	4	5	4	4	4	5	5	4	5	5	4	5	5	3	3	4	4	2	3	3	5
62	1	3	4	5	1	1	1	1	4	2	1	2	1	1	1	2	1	2	1	3	1	2	3	3	5	5	5	4	4	5
63	5	3	4	5	5	5	5	5	5	1	1	3	5	5	5	4	5	5	3	3	5	5	3	3	5	5	5	4	5	5
64	3	3	3	4	3	3	3	3	3	1	4	5	3	3	4	4	3	4	5	4	4	4	3	3	4	4	3	3	3	4
65	4	3	2	4	4	4	4	4	5	4	4	1	4	4	2	1	4	1	3	5	2	1	5	3	4	4	2	5	5	2
66	4	1	1	2	4	4	4	4	2	1	5	4	4	4	1	4	4	4	5	4	1	4	4	1	2	2	4	4	2	3
67	4	3	2	4	4	4	4	4	5	4	4	1	4	4	2	1	4	1	1	4	2	1	4	3	4	4	2	3	5	4
68	5	3	3	4	5	5	5	5	4	1	2	2	5	5	1	3	5	1	3	4	1	1	3	3	4	4	4	4	4	5
69	5	3	4	5	5	5	5	5	3	5	2	1	5	5	4	2	5	2	1	4	4	2	3	3	5	5	2	3	3	5
70	3	3	4	4	1	3	4	2	5	3	3	2	3	1	5	1	3	2	2	5	5	2	5	3	4	4	2	3	5	4
71	5	3	3	4	1	1	1	1	4	2	4	3	5	1	4	3	1	5	3	1	4	5	1	5	5	5	3	4	5	5
72	5	3	5	5	5	1	4	2	4	2	4	4	5	5	5	5	1	5	5	4	5	5	3	3	5	5	1	4	4	2
73	3	2	2	2	3	3	3	3	1	3	2	1	3	3	1	2	3	2	1	3	1	2	2	2	2	2	4	2	1	1
74	3	4	5	5	2	2	1	1	5	1	5	3	3	2	2	5	2	5	5	2	2	5	3	4	5	5	1	5	5	5
75	3	3	5	5	5	3	2	4	5	2	3	1	3	5	1	2	3	5	1	3	1	5	2	3	5	5	1	5	5	4
76	5	4	4	5	5	5	5	5	4	1	4	4	5	5	4	4	5	5	4	2	4	5	2	4	5	5	3	1	4	5
77	4	4	5	4	4	4	4	4	4	2	4	4	4	4	4	4	4	5	4	4	1	5	5	4	4	4	1	3	4	5
78	5	3	3	4	5	5	5	5	4	4	4	4	5	5	4	4	5	5	3	1	3	3	3	3	4	4	3	5	4	5
79	5	4	3	5	5	5	5	5	5	1	5	5	5	5	5	5	5	5	5	3	4	4	4	4	5	5	1	3	5	5
80	4	3	4	4	4	4	4	4	4	3	1	4	4	4	4	4	4	4	4	4	4	4	5	3	4	4	3	4	4	5
81	5	3	4	4	5	5	5	5	5	5	1	2	5	5	3	4	5	5	5	3	4	4	4	3	4	4	4	2	5	5

82	4	3	3	5	4	4	4	4	4	3	5	5	4	4	4	4	4	4	4	4	4	5	3	3	5	4	4	4			
83	2	3	2	4	2	2	2	2	4	3	2	1	2	2	1	1	2	4	1	3	4	4	4	1	1	2	1	3	2	1	
84	1	4	5	5	1	1	1	1	5	1	2	1	1	1	2	1	1	4	1	3	4	4	4	4	5	5	3	1	5	5	
85	4	3	3	3	4	4	4	4	4	2	5	5	4	4	4	4	4	4	5	5	5	5	5	5	5	3	3	5	5		
86	4	3	4	4	4	4	4	4	4	1	2	1	4	4	2	1	4	1	1	4	4	4	4	3	4	4	4	1	4	5	
87	3	2	1	4	3	1	3	3	3	4	4	4	3	3	5	4	1	4	4	1	1	1	1	2	1	4	4	2	3	4	
88	1	3	3	4	1	1	1	1	4	2	5	1	1	1	1	2	1	2	2	3	3	3	3	3	3	4	3	3	4	4	
89	5	3	4	4	5	5	5	5	4	5	4	3	5	5	3	4	5	4	4	4	4	4	3	4	4	4	4	4	4	2	
90	4	1	1	1	2	2	2	1	1	5	3	4	4	2	5	4	2	4	4	1	3	3	1	1	1	1	5	1	1	1	
91	5	4	5	5	5	5	5	5	5	2	1	3	1	5	2	3	5	2	2	4	4	4	4	4	5	5	4	2	5	5	
92	4	4	4	5	1	1	1	2	5	5	2	5	4	1	4	4	1	5	5	1	1	1	1	4	4	5	1	5	5	5	
93	2	4	4	4	1	1	1	2	4	3	3	4	4	2	4	3	2	5	5	5	2	2	1	4	4	4	1	5	4	4	
94	5	2	1	2	4	2	2	4	2	5	2	3	5	4	2	2	2	5	5	3	2	2	2	2	1	2	1	5	2	2	
95	4	4	3	4	2	2	3	1	4	1	3	3	4	2	5	3	2	3	4	3	2	2	2	4	3	4	3	4	4	5	
96	5	4	5	5	4	5	5	4	5	5	1	1	5	4	2	1	5	1	3	4	1	2	1	4	5	5	5	3	5	5	
97	4	1	4	4	5	4	3	4	5	4	2	2	4	5	5	2	4	4	2	5	1	2	2	2	2	3	2	2	3	3	
98	4	1	5	2	4	3	3	3	4	4	3	3	2	4	3	4	3	4	4	4	5	2	1	3	4	4	2	4	5	5	
99	4	1	2	2	3	1	2	4	4	4	4	4	4	3	4	4	1	4	3	5	1	2	1	3	4	4	2	3	4	4	
100	4	3	5	4	2	2	3	4	1	1	2	2	4	2	1	1	2	1	2	1	5	5	2	2	4	1	2	4	5		
101	1	1	4	2	1	2	5	3	2	1	3	3	1	1	4	3	2	3	5	1	2	5	1	3	5	3	3	5	4	5	
102	2	1	4	1	4	2	3	3	1	5	2	2	2	4	1	2	2	1	2	2	2	2	1	1	1	2	1	2	1	1	
103	5	5	5	5	5	5	5	5	5	5	1	1	5	5	1	5	2	2	5	2	1	1	1	1	1	1	2	2	1	1	
104	5	5	5	5	5	5	5	5	5	4	4	4	4	5	5	4	4	5	4	2	3	2	1	1	4	4	4	4	2	5	5
105	4	4	4	4	4	4	4	2	4	2	1	1	4	4	1	2	4	2	2	1	5	1	2	4	4	5	2	2	4	4	
105	5	5	5	5	5	5	5	4	5	5	4	5	5	5	5	5	5	5	4	4	5	2	1	3	5	5	5	4	5	5	





12 3	4	5	4	4	2	4	1	5	2	1	2	4	4	2	4	2	4	4	2	2	4	5	2	4	2	4	4	2	2	4	
12 4	4	1	1	1	4	5	5	4	4	3	2	3	3	3	3	2	4	4	2	2	4	2	3	4	5	5	4	2	4	1	
12 5	5	5	4	3	4	5	4	4	2	2	4	1	5	4	4	3	5	2	1	4	1	2	4	4	3	4	2	1	3	4	
12 6	4	1	3	3	4	3	2	4	5	3	1	2	4	4	1	2	3	3	2	5	4	2	5	4	4	4	3	2	5	4	
12 7	1	2	2	2	2	5	4	4	4	3	1	2	1	2	3	3	5	4	2	3	5	5	3	4	4	4	3	4	4	3	
12 8	2	5	5	4	4	3	5	2	5	5	4	4	2	4	4	5	3	5	2	4	5	2	5	4	4	4	4	5	4	5	
12 9	4	2	4	3	2	5	5	4	4	4	5	5	4	2	5	5	5	5	5	5	5	5	5	2	2	4	5	5	4	2	
13 0	1	5	5	4	4	3	3	4	2	2	5	5	1	4	5	5	3	5	5	4	4	4	4	4	2	4	4	2	4	1	
13 1	2	3	4	1	4	4	5	5	5	2	5	4	2	4	4	4	4	4	4	1	1	1	1	1	2	2	1	1	2	2	
13 2	4	1	2	3	2	2	2	5	3	1	2	4	4	2	4	4	2	4	2	5	4	4	5	4	3	3	5	5	4	2	
13 3	2	5	2	2	4	5	1	5	4	5	5	5	2	4	5	5	5	5	5	4	4	4	4	4	2	4	4	4	3	4	
13 4	5	2	5	4	5	5	3	5	1	2	1	1	5	5	2	1	5	1	1	4	4	4	4	4	4	4	4	4	3	3	5
13 5	2	3	1	2	2	5	5	2	4	2	3	1	2	2	3	3	5	5	1	2	4	3	2	2	2	2	2	2	4	2	5
13 6	5	5	1	4	5	5	1	5	4	2	4	4	4	4	4	5	3	5	5	4	5	4	4	5	5	5	4	4	4	5	
13 7	1	5	4	3	2	2	3	2	2	2	4	5	2	3	5	5	4	5	4	4	2	2	2	1	1	2	4	2	2	2	
13 8	3	2	1	4	1	3	2	3	5	4	3	3	2	2	1	2	1	5	2	2	4	4	4	5	3	4	2	4	4	4	
13	5	5	1	4	1	1	5	5	5	5	3	2	1	1	2	1	2	1	1	5	5	5	4	4	4	4	5	5	4	3	



15 6	5	5	5	5	1	1	1	1	3	2	2	1	4	2	2	1	3	3	1	2	2	2	1	2	1	2	2	2	2	2	2
15 7	5	5	4	4	5	1	4	2	3	2	4	4	3	4	5	5	2	5	5	5	3	3	4	4	5	5	5	5	5	4	2
15 8	1	1	4	2	1	1	1	1	2	3	1	2	4	4	2	1	1	1	2	4	4	3	4	2	2	2	4	4	1	1	
15 9	5	4	3	5	2	4	1	1	1	1	5	3	4	5	2	5	3	5	5	3	4	2	3	5	5	5	3	2	5	5	
16 0	1	3	4	5	5	5	2	4	3	2	3	1	3	4	1	2	3	5	1	4	5	3	4	4	5	5	4	4	5	4	
16 1	3	3	3	3	3	5	3	3	3	1	1	1	4	1	1	1	3	1	1	1	1	1	1	4	3	4	1	1	3	4	
16 2	5	4	5	4	5	4	5	4	5	4	1	1	2	2	1	2	2	2	2	4	5	5	5	1	2	1	4	5	1	2	
16 3	4	4	4	4	4	4	4	5	4	3	4	4	3	4	3	4	4	4	3	5	4	4	3	4	5	5	5	2	5	5	
16 4	4	4	4	4	4	4	4	5	4	5	5	5	3	4	3	5	4	5	4	5	5	2	4	4	4	4	5	4	4	4	
16 5	5	4	1	4	5	2	3	5	4	4	4	3	4	3	4	4	3	4	4	1	5	5	2	1	1	1	1	1	2	2	
16 6	1	4	5	4	5	5	3	2	2	4	1	1	2	1	2	1	3	1	2	5	5	2	5	4	1	4	5	5	4	5	
16 7	2	2	2	1	2	2	5	2	4	4	2	2	2	1	2	1	2	1	2	2	2	2	4	1	1	2	1	2	1	1	
16 8	2	2	2	1	4	5	3	4	1	1	1	2	2	1	2	1	3	2	2	1	2	5	1	3	4	4	2	2	4	4	
16 9	1	2	5	3	5	1	5	1	4	4	4	5	2	3	4	4	2	5	4	4	4	5	4	4	2	4	2	4	4	5	
17 0	4	5	4	4	2	4	1	5	2	1	2	4	2	4	4	2	4	4	2	2	4	5	2	4	2	4	3	4	2	4	

No	Kineja Keja								Kepuasan Kerja							
	X20	X21	X22	X23	X24	X25	X26	X27	X28	X29	X30	X31	X32	X33	X34	
1	3	1	3	3	3	1	2	2	4	4	2	3	5	2	3	
2	4	4	3	2	4	3	4	4	4	2	3	2	4	3	3	
3	4	4	2	4	3	3	4	4	5	5	2	4	4	4	3	
4	4	2	4	2	2	4	4	2	1	1	3	1	3	1	1	
5	4	4	2	3	4	2	4	4	5	5	5	4	4	5	5	
6	4	5	3	5	5	4	5	5	2	2	2	2	2	2	2	
7	2	4	1	3	4	1	1	2	4	2	3	4	4	3	2	
8	2	4	1	4	2	1	1	3	5	3	4	3	5	2	4	
9	3	4	2	4	4	3	1	3	2	2	2	4	2	3	2	
10	3	4	4	4	4	4	3	3	5	5	4	5	5	4	4	
11	1	5	2	5	3	3	1	3	4	4	3	3	4	3	2	
12	2	4	3	4	4	4	4	3	5	5	5	3	3	5	5	
13	2	2	2	4	1	1	1	2	2	2	2	1	2	2	2	
14	3	4	1	3	3	1	1	4	4	2	3	3	4	3	2	
15	4	4	4	4	2	2	2	4	5	5	4	5	5	4	4	
16	2	4	2	4	3	1	1	1	4	1	3	3	4	3	3	
17	3	4	1	4	4	5	1	3	4	4	3	4	4	3	2	
18	1	2	3	2	2	5	5	2	5	5	4	5	5	4	2	
19	4	5	2	5	5	5	2	1	1	1	1	2	1	2	2	
20	1	2	4	3	2	5	3	2	1	1	1	3	2	2	1	
21	1	1	1	4	3	5	2	1	4	5	4	3	2	4	5	
22	3	4	3	4	4	5	4	1	4	4	3	4	4	3	3	
23	2	4	3	3	4	5	4	2	4	3	3	3	4	3	3	
24	2	2	4	3	2	5	3	1	2	3	2	3	2	3	3	
25	3	2	2	4	2	5	2	2	1	1	1	2	2	1	1	
26	3	2	1	2	2	1	2	1	5	5	4	5	5	4	5	
27	4	5	1	5	5	1	1	1	2	4	5	1	2	3	4	
28	1	1	2	2	1	2	2	2	3	3	2	3	3	3	3	
29	2	3	4	3	3	4	4	1	5	4	3	3	4	4	5	
30	2	4	2	4	4	2	2	3	4	3	2	3	4	2	4	
31	2	3	1	3	3	2	2	3	2	2	1	5	2	2	1	

43	4	2	2	4	4	2	2	4	2	1	1	3	3	2	1
44	3	2	2	4	4	1	1	4	2	5	5	1	5	1	1
45	4	4	1	4	4	1	1	4	4	4	4	3	2	5	4
46	3	4	3	4	4	1	4	4	4	2	2	3	5	4	4
47	3	4	4	4	4	4	4	4	1	5	5	2	5	2	2
48	3	5	4	3	3	4	4	3	3	5	5	2	3	2	3
49	2	4	5	2	2	5	5	2	5	2	2	4	2	5	5
50	1	3	4	1	1	3	2	1	2	2	2	3	5	2	2
51	3	5	5	3	3	4	5	3	4	4	4	5	3	5	4
52	3	5	1	2	3	2	2	3	2	2	2	2	5	1	2
53	3	5	1	3	3	4	5	3	4	4	4	2	5	5	5
54	3	5	2	3	3	4	2	3	3	5	5	4	2	4	5
55	2	2	1	1	2	2	2	2	1	2	2	2	5	2	2
56	4	5	1	3	3	1	1	3	2	4	4	2	3	3	2
57	3	5	4	3	3	4	4	3	5	5	5	2	3	5	5
58	1	3	1	1	1	2	1	1	2	2	2	2	5	2	2
59	4	5	1	3	3	1	5	3	2	2	2	2	5	2	1
60	2	2	3	1	2	3	5	2	1	1	1	5	4	2	2
61	4	1	5	3	3	5	5	3	3	4	4	2	3	3	5
62	3	1	1	3	3	2	2	3	3	5	5	5	4	4	5
63	3	4	5	3	3	4	5	3	3	5	5	5	4	5	5
64	4	3	4	1	3	4	4	3	3	4	4	3	3	3	4
65	5	5	2	5	5	1	1	5	3	4	4	2	5	5	2
66	4	4	1	4	4	4	4	4	1	2	2	4	4	2	3
67	4	4	2	4	4	1	1	4	3	4	4	2	3	5	4
68	4	4	1	1	3	3	1	3	3	4	4	4	4	4	5
69	4	3	4	3	4	2	2	3	3	5	5	2	3	3	5
70	5	5	5	5	4	1	2	5	3	4	4	2	3	5	4
71	1	1	4	1	1	3	5	1	5	5	5	3	4	5	5
72	4	3	5	4	3	5	5	3	3	5	5	1	4	4	2
73	3	5	1	2	3	2	2	2	2	2	2	4	2	1	1
74	2	2	2	3	3	5	5	3	4	5	5	1	5	5	5
75	3	4	1	3	1	2	5	2	3	5	5	1	5	5	4
76	2	2	4	2	2	4	5	2	4	5	5	3	1	4	5
77	4	5	1	4	4	4	5	5	4	4	4	1	3	4	5
78	1	3	3	5	3	3	3	3	3	4	4	3	5	4	5
79	3	4	4	3	3	4	4	4	4	5	5	1	3	5	5
80	4	5	4	4	4	4	4	5	3	4	4	3	4	4	5
81	3	4	4	3	2	4	4	4	3	4	4	4	2	5	5
82	4	5	4	5	4	4	4	5	3	3	5	4	4	4	4
83	3	4	4	4	3	4	4	4	1	1	2	1	3	2	1
84	3	4	4	4	3	4	4	4	4	5	5	3	1	5	5
85	5	5	5	5	4	5	5	5	5	5	5	3	3	5	5
86	4	4	4	4	4	4	4	4	3	4	4	4	1	4	5
87	1	1	1	1	1	1	1	1	2	1	4	4	2	3	4
88	3	3	3	3	3	3	3	3	3	3	4	3	3	4	4
89	4	4	4	4	4	4	4	4	3	4	4	4	4	4	2
90	1	1	3	1	1	3	3	1	1	1	1	5	1	1	1

91	4	4	4	4	4	4	4	4	4	5	5	4	2	5	5
92	1	1	1	1	1	1	1	1	4	4	5	1	5	5	5
93	5	4	2	4	4	4	2	1	4	4	4	1	5	4	4
94	3	3	2	4	4	3	2	2	2	1	2	1	5	2	2
95	3	5	2	5	4	3	2	2	4	3	4	3	4	4	5
96	4	5	1	5	5	5	2	1	4	5	5	5	3	5	5
97	5	5	1	3	4	3	2	2	2	2	3	2	2	3	3
98	4	5	5	4	4	3	2	1	3	4	4	2	4	5	5
99	5	5	1	5	5	5	2	1	3	4	4	2	3	4	4
100	1	5	5	1	1	1	5	2	2	2	4	1	2	4	5
101	1	2	2	1	1	1	5	1	3	5	3	3	5	4	5
102	2	1	2	3	3	4	2	1	1	1	2	1	2	1	1
103	5	2	2	4	5	4	1	1	1	1	1	2	2	1	1
104	3	2	2	4	4	4	1	1	4	4	4	4	2	5	5
105	1	5	5	1	2	1	1	2	4	4	5	2	2	4	4
106	4	2	5	4	1	3	2	1	3	5	5	5	4	5	5
107	4	5	5	5	4	2	2	2	5	1	4	1	2	4	5
108	4	2	4	2	4	2	2	1	2	1	3	2	3	4	4
109	5	2	5	5	1	5	5	2	4	1	3	4	5	4	4
110	4	2	5	5	4	4	4	1	4	5	5	4	5	5	5
111	1	2	3	2	2	2	1	1	4	2	2	4	4	2	5
112	4	5	4	4	4	4	4	1	5	4	2	5	4	2	5
113	4	5	5	5	1	4	5	2	1	2	1	2	2	1	2
114	5	2	4	4	5	5	4	1	4	5	5	4	3	5	5
115	5	4	5	4	4	4	2	4	4	1	1	4	3	1	1
116	4	4	5	4	1	5	2	1	2	1	2	1	2	1	2
117	4	3	4	5	5	4	2	5	4	1	2	1	3	2	3
118	2	2	5	1	3	3	5	3	1	1	1	4	4	2	2
119	5	5	5	5	5	5	2	5	4	1	4	1	2	4	5
120	2	4	2	4	4	4	2	4	1	1	2	1	1	1	1
121	1	4	2	1	1	1	5	1	1	2	2	5	4	2	2
122	4	4	4	2	4	2	5	4	4	2	4	4	2	4	5
123	2	4	4	1	2	1	5	2	4	2	4	4	2	2	4
124	2	5	4	3	4	3	2	3	4	5	5	4	2	4	1
125	4	3	1	4	4	3	2	4	4	3	4	2	1	3	4
126	5	2	4	4	4	4	2	5	4	4	4	3	2	5	4
127	3	4	5	3	3	3	5	3	4	4	4	3	4	4	3
128	4	5	5	5	5	4	2	5	4	4	4	4	5	4	5
129	5	5	5	5	5	5	5	5	2	2	4	5	5	4	2
130	4	2	4	2	4	2	4	4	4	2	4	4	2	4	1
131	1	1	1	2	2	1	1	1	1	2	2	1	1	2	2
132	5	5	4	4	5	4	4	5	4	3	3	5	5	4	2
133	4	4	4	3	4	4	4	4	4	2	4	4	4	3	4
134	4	3	4	3	3	3	4	4	4	4	4	4	3	3	5
135	2	4	4	2	1	2	3	2	2	2	2	2	4	2	5
136	4	4	5	4	3	4	4	4	5	5	5	4	4	4	5
137	4	2	2	2	2	2	2	2	1	1	2	4	2	2	2
138	2	4	4	3	4	4	4	4	5	3	4	2	4	4	4

139	5	5	5	4	1	5	5	4	4	4	4	5	5	4	3
140	2	4	5	3	5	5	4	3	4	3	4	2	4	4	5
141	2	5	5	3	5	5	5	2	5	4	5	2	5	5	5
142	4	4	4	2	2	2	4	3	4	2	3	4	4	4	2
143	4	4	4	2	4	2	4	3	4	4	4	4	4	4	4
144	3	4	4	3	4	5	4	4	1	1	1	3	4	2	2
145	4	5	2	3	4	2	3	5	4	3	5	4	5	5	5
146	5	4	4	3	3	4	3	4	4	4	4	5	4	4	5
147	4	4	5	4	5	4	5	4	5	4	4	4	4	4	1
148	4	2	3	2	2	2	2	2	4	5	4	4	2	4	4
149	2	5	5	3	4	5	5	5	4	4	4	2	5	4	5
150	5	5	4	4	5	3	4	5	5	3	4	5	5	3	4
151	5	5	5	4	5	5	5	5	1	1	2	5	5	2	3
152	4	4	4	3	4	4	4	4	3	2	4	4	4	5	4
153	4	5	4	3	4	4	3	5	2	1	2	4	5	2	3
154	5	4	3	3	5	3	4	4	4	4	5	5	4	3	3
155	4	4	4	3	2	1	4	4	4	4	4	4	4	5	4
156	2	2	2	1	1	5	2	1	2	1	2	2	2	2	2
157	5	5	3	5	4	4	3	4	4	5	5	5	5	4	2
158	4	4	4	3	4	5	3	4	2	2	2	4	4	1	1
159	3	2	4	4	4	4	2	3	5	5	5	3	2	5	5
160	4	4	5	4	1	4	3	4	4	5	5	4	4	5	4
161	1	1	1	1	1	1	1	1	4	3	4	1	1	3	4
162	4	5	5	5	1	4	5	5	1	2	1	4	5	1	2
163	5	2	4	4	5	5	4	3	4	5	5	5	2	5	5
164	5	4	5	4	4	4	2	4	4	4	4	5	4	4	4
165	1	1	5	1	2	3	5	2	1	1	1	1	1	2	2
166	5	5	5	5	5	5	2	5	4	1	4	5	5	4	5
167	2	4	2	4	4	4	2	4	1	1	2	1	2	1	1
168	1	2	2	1	1	1	5	1	3	4	4	2	2	4	4
169	4	2	4	2	4	2	5	4	4	2	4	2	4	4	5
170	2	2	4	1	2	1	5	2	4	2	4	3	4	2	4



Lampiran 2a. *Output* Estimasi Variabel Laten Eksogen 1**Regression Weights: (Group number 1 - Default model)**

		Estimate	S.E.	C.R.	P	Label
x19 <---	Komitmen_Professional	1.000				
x18 <---	Komitmen_Professional	1.139	.100	11.436	***	par_1
x17 <---	Komitmen_Professional	.187	.099	1.896	.058	par_2
x16 <---	Komitmen_Professional	1.217	.085	14.329	***	par_3
x15 <---	Komitmen_Professional	.971	.093	10.461	***	par_4
x14 <---	Komitmen_Professional	.435	.097	4.508	***	par_5
x13 <---	Komitmen_Professional	.314	.090	3.492	***	par_6
x12 <---	Komitmen_Professional	1.138	.087	13.071	***	par_7
x11 <---	Komitmen_Professional	.848	.093	9.076	***	par_8

**Standardized Regression Weights: (Group number 1 - Default model)**

		Estimate
x19 <---	Komitmen_Professional	.810
x18 <---	Komitmen_Professional	.786
x17 <---	Komitmen_Professional	.151
x16 <---	Komitmen_Professional	.915
x15 <---	Komitmen_Professional	.733
x14 <---	Komitmen_Professional	.351
x13 <---	Komitmen_Professional	.274
x12 <---	Komitmen_Professional	.850
x11 <---	Komitmen_Professional	.649

Lampiran 2b. *Output Model Fit Variabel Laten Eksogen 1***CMIN**

Model	NPAR	CMIN	DF	P	CMIN/DF
Default model	27	131.642	27	.000	4.876
Saturated model	54	.000	0		
Independence model	18	809.448	36	.000	22.485

**Baseline Comparisons**

Model	NFI Delta1	RFI rho1	IFI Delta2	TLI rho2	CFI
Default model	.837	.783	.866	.820	.865
Saturated model	1.000		1.000		1.000
Independence model	.000	.000	.000	.000	.000

**RMSEA**

Model	RMSEA	LO 90	HI 90	PCLOSE
Default model	.151	.126	.178	.000
Independence model	.357	.335	.378	.000

Lampiran 3a. *Output* Estimasi Variabel Laten Eksogen 2**Regression Weights: (Group number 1 - Default model)**

		Estimate	S.E.	C.R.	P	Label
x19 <---	Komitmen_Professional	1.000				
x18 <---	Komitmen_Professional	1.130	.099	11.357	***	par_1
x16 <---	Komitmen_Professional	1.210	.085	14.273	***	par_2
x15 <---	Komitmen_Professional	.968	.093	10.450	***	par_3
x12 <---	Komitmen_Professional	1.148	.086	13.269	***	par_4
x11 <---	Komitmen_Professional	.850	.093	9.132	***	par_5

**Standardized Regression Weights: (Group number 1 - Default model)**

		Estimate
x19 <---	Komitmen_Professional	.812
x18 <---	Komitmen_Professional	.781
x16 <---	Komitmen_Professional	.911
x15 <---	Komitmen_Professional	.732
x12 <---	Komitmen_Professional	.859
x11 <---	Komitmen_Professional	.652

Lampiran 3b. *Output Model Fit Variabel Laten Eksogen 2***CMIN**

Model	NPAR	CMIN	DF	P	CMIN/DF
Default model	18	18.133	9	.034	2.015
Saturated model	27	.000	0		
Independence model	12	662.017	15	.000	44.134

**Baseline Comparisons**

Model	NFI Delta1	RFI rho1	IFI Delta2	TLI rho2	CFI
Default model	.973	.954	.986	.976	.986
Saturated model	1.000		1.000		1.000
Independence model	.000	.000	.000	.000	.000

**RMSEA**

Model	RMSEA	LO 90	HI 90	PCLOSE
Default model	.077	.021	.129	.168
Independence model	.505	.473	.538	.000

Lampiran 4a. *Output* Estimasi Variabel Laten Endogen 1**Regression Weights: (Group number 1 - Default model)**

		Estimate	S.E.	C.R.	P	Label
x1	<--- Komitmen_Organisasi	1.000				
x2	<--- Komitmen_Organisasi	.491	.128	3.850	***	par_1
x3	<--- Komitmen_Organisasi	.464	.140	3.314	***	par_2
x4	<--- Komitmen_Organisasi	.582	.127	4.586	***	par_3
x5	<--- Komitmen_Organisasi	1.275	.158	8.048	***	par_4
x6	<--- Komitmen_Organisasi	1.061	.148	7.178	***	par_5
x7	<--- Komitmen_Organisasi	1.087	.149	7.319	***	par_6
x8	<--- Komitmen_Organisasi	1.033	.144	7.154	***	par_7
x9	<--- Komitmen_Organisasi	.586	.130	4.518	***	par_8
x10	<--- Komitmen_Organisasi	.469	.134	3.508	***	par_9
x20	<--- Kinerja_Kerja	1.000				
x21	<--- Kinerja_Kerja	.833	.121	6.861	***	par_10
x22	<--- Kinerja_Kerja	.413	.131	3.160	.002	par_11
x23	<--- Kinerja_Kerja	.954	.112	8.520	***	par_12
x24	<--- Kinerja_Kerja	.989	.116	8.502	***	par_13
x25	<--- Kinerja_Kerja	.527	.127	4.132	***	par_14
x26	<--- Kinerja_Kerja	.158	.134	1.185	.236	par_15
x27	<--- Kinerja_Kerja	.910	.118	7.698	***	par_16
x34	<--- Kepuasan_Kerja	1.000				
x33	<--- Kepuasan_Kerja	1.024	.085	12.004	***	par_17
x32	<--- Kepuasan_Kerja	.228	.092	2.494	.013	par_18
x31	<--- Kepuasan_Kerja	.283	.097	2.922	.003	par_19
x30	<--- Kepuasan_Kerja	.915	.091	10.075	***	par_20
x29	<--- Kepuasan_Kerja	1.006	.103	9.742	***	par_21
x28	<--- Kepuasan_Kerja	.859	.087	9.853	***	par_22

**Standardized Regression Weights: (Group number 1 - Default model)**

		Estimate
x1	<--- Komitmen_Organisasi	.653
x2	<--- Komitmen_Organisasi	.338
x3	<--- Komitmen_Organisasi	.294
x4	<--- Komitmen_Organisasi	.403
x5	<--- Komitmen_Organisasi	.800
x6	<--- Komitmen_Organisasi	.649
x7	<--- Komitmen_Organisasi	.694
x8	<--- Komitmen_Organisasi	.653
x9	<--- Komitmen_Organisasi	.403
x10	<--- Komitmen_Organisasi	.299
x20	<--- Kinerja_Kerja	.755
x21	<--- Kinerja_Kerja	.585
x22	<--- Kinerja_Kerja	.271
x23	<--- Kinerja_Kerja	.718
x24	<--- Kinerja_Kerja	.724
x25	<--- Kinerja_Kerja	.352
x26	<--- Kinerja_Kerja	.103
x27	<--- Kinerja_Kerja	.644
x34	<--- Kepuasan_Kerja	.762
x33	<--- Kepuasan_Kerja	.881
x32	<--- Kepuasan_Kerja	.202
x31	<--- Kepuasan_Kerja	.236
x30	<--- Kepuasan_Kerja	.778
x29	<--- Kepuasan_Kerja	.762
x28	<--- Kepuasan_Kerja	.746

Lampiran 4b. *Output Model Fit Variabel Laten Endogen 1***CMIN**

Model	NPAR	CMIN	DF	P	CMIN/DF
Default model	78	894.663	272	.000	3.289
Saturated model	350	.000	0		
Independence model	50	2038.863	300	.000	6.796

**Baseline Comparisons**

Model	NFI Delta1	RFI rho1	IFI Delta2	TLI rho2	CFI
Default model	.561	.516	.648	.605	.642
Saturated model	1.000		1.000		1.000
Independence model	.000	.000	.000	.000	.000

**RMSEA**

Model	RMSEA	LO 90	HI 90	PCLOSE
Default model	.116	.108	.125	.000
Independence model	.185	.178	.193	.000

Lampiran 5a. *Output* Estimasi Variabel Laten Endogen 2**Regression Weights: (Group number 1 - Default model)**

		Estimate	S.E.	C.R.	P	Label
x1	<---	Komitmen_Organisasi	1.000			
x5	<---	Komitmen_Organisasi	1.330	.168	7.896	*** par_1
x6	<---	Komitmen_Organisasi	1.124	.155	7.235	*** par_2
x7	<---	Komitmen_Organisasi	1.156	.157	7.381	*** par_3
x8	<---	Komitmen_Organisasi	1.126	.153	7.371	*** par_4
x20	<---	Kinerja_Kerja	1.000			
x21	<---	Kinerja_Kerja	.856	.124	6.903	*** par_5
x23	<---	Kinerja_Kerja	.957	.113	8.430	*** par_6
x24	<---	Kinerja_Kerja	1.032	.121	8.558	*** par_7
x27	<---	Kinerja_Kerja	.915	.120	7.615	*** par_8
x34	<---	Kepuasan_Kerja	1.000			
x33	<---	Kepuasan_Kerja	1.022	.085	11.978	*** par_9
x30	<---	Kepuasan_Kerja	.926	.091	10.138	*** par_10
x29	<---	Kepuasan_Kerja	1.007	.104	9.706	*** par_11
x28	<---	Kepuasan_Kerja	.848	.087	9.734	*** par_12

**Standardized Regression Weights: (Group number 1 - Default model)**

		Estimate	
x1	<---	Komitmen_Organisasi	.638
x5	<---	Komitmen_Organisasi	.816
x6	<---	Komitmen_Organisasi	.671
x7	<---	Komitmen_Organisasi	.721
x8	<---	Komitmen_Organisasi	.696
x20	<---	Kinerja_Kerja	.748
x21	<---	Kinerja_Kerja	.596
x23	<---	Kinerja_Kerja	.713
x24	<---	Kinerja_Kerja	.748
x27	<---	Kinerja_Kerja	.642
x34	<---	Kepuasan_Kerja	.762
x33	<---	Kepuasan_Kerja	.880
x30	<---	Kepuasan_Kerja	.788



	Estimate
x29 <--- Kepuasan_Kerja	.762
x28 <--- Kepuasan_Kerja	.737

Lampiran 5b. *Output Model Fit Variabel Laten Endogen 2*

### CMIN

Model	NPAR	CMIN	DF	P	CMIN/DF
Default model	48	98.601	87	.186	1.133
Saturated model	135	.000	0		
Independence model	30	1129.678	105	.000	10.759

### Baseline Comparisons

Model	NFI Delta1	RFI rho1	IFI Delta2	TLI rho2	CFI
Default model	.913	.895	.989	.986	.989
Saturated model	1.000		1.000		1.000
Independence model	.000	.000	.000	.000	.000

### RMSEA

Model	RMSEA	LO 90	HI 90	PCLOSE
Default model	.028	.000	.052	.928
Independence model	.240	.228	.253	.000

Lampiran 6a. *Output Estimasi Full Model Structural***Regression Weights: (Group number 1 - Default model)**

			Estimate	S.E.	C.R.	P	Label
Komitmen_Organisasi	<---	Komitmen_Professional	.224	.087	2.590	.010	par_18
Kepuasan_Kerja	<---	Komitmen_Professional	.205	.104	1.963	.050	par_19
Kepuasan_Kerja	<---	Komitmen_Organisasi	.282	.117	2.414	.016	par_22
Kinerja_Kerja	<---	Komitmen_Organisasi	.204	.104	1.960	.050	par_20
Kinerja_Kerja	<---	Kepuasan_Kerja	.166	.078	2.138	.033	par_21
x1	<---	Komitmen_Organisasi	1.000				
x5	<---	Komitmen_Organisasi	1.332	.168	7.927	***	par_1
x6	<---	Komitmen_Organisasi	1.110	.154	7.194	***	par_2
x7	<---	Komitmen_Organisasi	1.151	.156	7.394	***	par_3
x8	<---	Komitmen_Organisasi	1.130	.152	7.419	***	par_4
x11	<---	Komitmen_Professional	1.000				
x12	<---	Komitmen_Professional	1.350	.142	9.509	***	par_5
x15	<---	Komitmen_Professional	1.141	.137	8.350	***	par_6
x16	<---	Komitmen_Professional	1.426	.145	9.824	***	par_7
x18	<---	Komitmen_Professional	1.334	.151	8.818	***	par_8
x19	<---	Komitmen_Professional	1.176	.129	9.108	***	par_9
x20	<---	Kinerja_Kerja	1.000				
x21	<---	Kinerja_Kerja	.856	.124	6.899	***	par_10
x23	<---	Kinerja_Kerja	.957	.113	8.430	***	par_11
x24	<---	Kinerja_Kerja	1.032	.121	8.556	***	par_12
x27	<---	Kinerja_Kerja	.915	.120	7.615	***	par_13
x34	<---	Kepuasan_Kerja	1.000				
x33	<---	Kepuasan_Kerja	1.022	.085	11.989	***	par_14
x30	<---	Kepuasan_Kerja	.926	.091	10.147	***	par_15
x29	<---	Kepuasan_Kerja	1.007	.104	9.720	***	par_16
x28	<---	Kepuasan_Kerja	.848	.087	9.742	***	par_17

Lampiran 6b. *Output Model Fit Full Model Structural***CMIN**

Model	NPAR	CMIN	DF	P	CMIN/DF
Default model	68	208.784	184	.102	1.135
Saturated model	252	.000	0		
Independence model	42	1895.795	210	.000	9.028

**Baseline Comparisons**

Model	NFI Delta1	RFI rho1	IFI Delta2	TLI rho2	CFI
Default model	.890	.874	.986	.983	.985
Saturated model	1.000		1.000		1.000
Independence model	.000	.000	.000	.000	.000

**RMSEA**

Model	RMSEA	LO 90	HI 90	PCLOSE
Default model	.028	.000	.046	.984
Independence model	.218	.209	.227	.000

Lampiran 7. *Output* Normalitas**Assessment of normality (Group number 1)**

Variable	min	max	skew	c.r.	kurtosis	c.r.
x28	1.000	5.000	-.442	-2.352	-.953	-2.537
x29	1.000	5.000	-.116	-.615	-1.422	-3.785
x30	1.000	5.000	-.387	-2.058	-1.125	-2.995
x33	1.000	5.000	-.331	-1.763	-1.065	-2.833
x34	1.000	5.000	-.367	-1.953	-1.314	-3.497
x27	1.000	5.000	-.051	-.271	-1.177	-3.134
x24	1.000	5.000	-.400	-2.127	-.958	-2.549
x23	1.000	5.000	-.412	-2.195	-.783	-2.084
x21	1.000	5.000	-.495	-2.636	-1.077	-2.866
x20	1.000	5.000	-.323	-1.720	-.911	-2.426
x19	1.000	5.000	.222	1.180	-1.144	-3.044
x18	1.000	5.000	-.169	-.897	-1.551	-4.127
x16	1.000	5.000	.060	.317	-1.400	-3.726
x15	1.000	5.000	.135	.721	-1.361	-3.622
x12	1.000	5.000	.199	1.061	-1.398	-3.721
x11	1.000	5.000	.024	.129	-1.352	-3.598
x8	1.000	5.000	-.325	-1.729	-1.218	-3.243
x7	1.000	5.000	-.112	-.596	-1.253	-3.335
x6	1.000	5.000	-.100	-.532	-1.335	-3.552
x5	1.000	5.000	-.239	-1.272	-1.251	-3.328
x1	1.000	5.000	-.298	-1.588	-1.112	-2.960
Multivariate					12.435	2.608

*Lampiran 8. Output Outlier*

**Observations farthest from the centroid (Mahalanobis distance) (Group number 1)**

Observation number	Mahalanobis d-squared	p1	p2
150	43.319	.003	.386
139	42.549	.004	.125
160	39.679	.008	.162
101	37.668	.014	.219
135	36.202	.021	.279
59	34.678	.031	.421
169	34.295	.034	.349
44	34.123	.035	.250
39	33.569	.040	.248
112	32.068	.058	.519
162	31.703	.063	.502
122	31.672	.063	.389
149	31.438	.067	.346
130	31.031	.073	.363
47	30.646	.080	.381
75	30.327	.086	.384
8	30.093	.090	.364
94	29.702	.098	.404
109	29.690	.098	.314
108	29.618	.100	.254
159	29.009	.114	.379
21	28.685	.122	.415
124	28.617	.123	.353
166	28.382	.130	.360
14	28.230	.134	.337
117	27.837	.145	.414
100	27.803	.146	.347
36	27.740	.148	.296
155	27.654	.150	.258
146	27.354	.159	.302
148	27.296	.161	.256

Observation number	Mahalanobis d-squared	p1	p2
93	26.774	.178	.400
123	26.739	.180	.341
129	26.724	.180	.279
18	26.136	.201	.471
103	26.026	.205	.450
40	25.556	.224	.607
32	25.529	.225	.548
81	25.459	.228	.510
1	25.357	.232	.490
70	25.295	.235	.449
157	25.226	.238	.414
53	25.210	.238	.354
119	24.980	.248	.401
15	24.761	.258	.446
115	24.638	.263	.442
170	24.626	.264	.381
142	24.476	.271	.393
68	24.285	.279	.428
132	24.088	.289	.468
99	24.066	.290	.414
49	24.045	.291	.361
151	23.904	.298	.372
37	23.822	.302	.353
118	23.619	.312	.399
113	23.552	.315	.373
71	23.540	.316	.319
145	23.535	.316	.266
133	23.314	.327	.319
121	23.238	.331	.301
92	23.198	.334	.266
78	23.059	.341	.280
72	23.021	.343	.246
128	23.007	.344	.205
11	22.985	.345	.171
27	22.973	.345	.137
116	22.877	.351	.134
7	22.814	.354	.121
147	22.684	.361	.128
165	22.611	.365	.118
97	22.481	.372	.126

Observation number	Mahalanobis d-squared	p1	p2
152	22.244	.386	.174
107	22.008	.399	.232
17	21.862	.408	.254
38	21.807	.411	.232
127	21.792	.412	.194
56	21.588	.424	.242
46	21.554	.426	.212
156	21.464	.431	.208
54	21.441	.432	.176
62	21.332	.439	.181
66	21.234	.445	.181
41	21.182	.448	.163
96	21.082	.454	.165
19	20.965	.461	.173
126	20.938	.463	.147
42	20.781	.472	.171
114	20.649	.481	.186
48	20.635	.481	.153
95	20.546	.487	.151
138	20.383	.497	.179
16	20.151	.512	.245
125	20.007	.521	.272
26	19.980	.523	.237
136	19.877	.529	.242
74	19.872	.529	.199
106	19.828	.532	.177
3	19.669	.542	.207
69	19.565	.549	.213
65	19.518	.552	.191

## Lampiran 9. Output Multikolinieritas

### Sample Covariances (Group number 1)

	x28	x29	x30	x33	x34	x27	x24	x23	x21	x20	x19	x18	x16	x15	x12	x11	x8	x7	x6	x5	x1	
x28	1.609																					
x29	1.041	2.118																				
x30	.871	1.350	1.679																			
x33	1.069	1.199	1.120	1.638																		
x34	1.088	1.085	1.058	1.312	2.091																	
x27	.296	.133	.260	.289	.026	1.751																
x24	.351	.150	.237	.333	.141	.799	1.639															
x23	.263	.242	.187	.277	.097	.671	.883	1.550														
x21	.256	.166	.196	.272	.129	.808	.776	.680	1.779													
x20	.229	.168	.292	.323	.138	.828	.863	.855	.667	1.541												
x19	.172	.224	.182	.233	.259	-.104	-.061	.083	-.169	-.038	1.735											
x18	.319	.416	.301	.422	.459	-.071	-.148	-.128	-.178	.012	1.179	2.391										
x16	.247	.382	.213	.273	.326	-.120	-.110	.037	-.258	.018	1.400	1.631	2.016									
x15	.177	.185	.243	.236	.274	-.158	-.134	-.020	-.285	.088	1.008	1.276	1.347	2.000								
x12	.279	.243	.377	.299	.373	-.137	-.043	.013	-.198	.055	1.378	1.438	1.550	1.328	2.040							
x11	.220	.307	.221	.305	.145	.088	-.046	.141	-.186	.100	1.028	1.126	1.131	.923	1.142	1.943						
x8	.237	.188	.254	.201	.270	.006	.182	.215	.048	.260	.308	.382	.459	.445	.430	.198	1.941					
x7	.023	.186	.210	.199	.256	.075	.293	.337	.332	.312	.115	.194	.283	.347	.172	.012	.919	1.906				
x6	.325	.316	.371	.334	.588	.118	.222	.175	.271	.263	-.010	.180	.099	.137	-.069	-.060	.976	.898	2.077			
x5	.206	.278	.353	.291	.475	.083	.294	.296	.173	.395	.341	.468	.475	.310	.263	.178	1.105	1.219	1.062	1.967		
x1	.298	.354	.375	.294	.356	-.058	.089	.150	.144	.249	.301	.408	.367	.392	.237	.165	.886	.814	.946	.925	1.821	

Condition number = 34.731

Eigenvalues

10.231 6.819 4.705 3.941 1.316 1.233 1.188 1.085 1.044 .976 .926 .861 .804 .739 .703 .587 .528 .492 .429 .331 .295

Determinant of sample covariance matrix = 5.856

PERPUSTAKAAN  
UNNES



Lampiran 10a. *Output Estimasi Bootstrap***Regression Weights: (Group number 1 - Default model)**

		Estimate	S.E.	C.R.	P	Label
Komitmen_Organisasi	<--- Komitmen_Professional	.224	.087	2.590	.010	par_18
Kepuasan_Kerja	<--- Komitmen_Professional	.205	.104	1.963	.050	par_19
Kepuasan_Kerja	<--- Komitmen_Organisasi	.282	.117	2.414	.016	par_22
Kinerja_Kerja	<--- Komitmen_Organisasi	.204	.104	1.960	.050	par_20
Kinerja_Kerja	<--- Kepuasan_Kerja	.166	.078	2.138	.033	par_21
x1	<--- Komitmen_Organisasi	1.000				
x5	<--- Komitmen_Organisasi	1.332	.168	7.927	***	par_1
x6	<--- Komitmen_Organisasi	1.110	.154	7.194	***	par_2
x7	<--- Komitmen_Organisasi	1.151	.156	7.394	***	par_3
x8	<--- Komitmen_Organisasi	1.130	.152	7.419	***	par_4
x11	<--- Komitmen_Professional	1.000				
x12	<--- Komitmen_Professional	1.350	.142	9.509	***	par_5
x15	<--- Komitmen_Professional	1.141	.137	8.350	***	par_6
x16	<--- Komitmen_Professional	1.426	.145	9.824	***	par_7
x18	<--- Komitmen_Professional	1.334	.151	8.818	***	par_8
x19	<--- Komitmen_Professional	1.176	.129	9.108	***	par_9
x20	<--- Kinerja_Kerja	1.000				
x21	<--- Kinerja_Kerja	.856	.124	6.899	***	par_10
x23	<--- Kinerja_Kerja	.957	.113	8.430	***	par_11
x24	<--- Kinerja_Kerja	1.032	.121	8.556	***	par_12
x27	<--- Kinerja_Kerja	.915	.120	7.615	***	par_13
x34	<--- Kepuasan_Kerja	1.000				
x33	<--- Kepuasan_Kerja	1.022	.085	11.989	***	par_14
x30	<--- Kepuasan_Kerja	.926	.091	10.147	***	par_15
x29	<--- Kepuasan_Kerja	1.007	.104	9.720	***	par_16
x28	<--- Kepuasan_Kerja	.848	.087	9.742	***	par_17

**Standardized Regression Weights: (Group number 1 - Default model)**

		Estimate
Komitmen_Organisasi	<--- Komitmen_Professional	.236

		Estimate
Kepuasan_Kerja	<--- Komitmen_Professional	.169
Kepuasan_Kerja	<--- Komitmen_Organisasi	.221
Kinerja_Kerja	<--- Komitmen_Organisasi	.189
Kinerja_Kerja	<--- Kepuasan_Kerja	.197
x1	<--- Komitmen_Organisasi	.639
x5	<--- Komitmen_Organisasi	.819
x6	<--- Komitmen_Organisasi	.664
x7	<--- Komitmen_Organisasi	.719
x8	<--- Komitmen_Organisasi	.700
x11	<--- Komitmen_Professional	.651
x12	<--- Komitmen_Professional	.858
x15	<--- Komitmen_Professional	.732
x16	<--- Komitmen_Professional	.912
x18	<--- Komitmen_Professional	.783
x19	<--- Komitmen_Professional	.811
x20	<--- Kinerja_Kerja	.748
x21	<--- Kinerja_Kerja	.596
x23	<--- Kinerja_Kerja	.713
x24	<--- Kinerja_Kerja	.748
x27	<--- Kinerja_Kerja	.642
x34	<--- Kepuasan_Kerja	.762
x33	<--- Kepuasan_Kerja	.880
x30	<--- Kepuasan_Kerja	.788
x29	<--- Kepuasan_Kerja	.763
x28	<--- Kepuasan_Kerja	.737



Lampiran 10b. *Output Model Fit Bootstrap***CMIN**

Model	NPAR	CMIN	DF	P	CMIN/DF
Default model	68	208.784	184	.102	1.135
Saturated model	252	.000	0		
Independence model	42	1895.795	210	.000	9.028

**Baseline Comparisons**

Model	NFI	RFI	IFI	TLI	CFI
	Delta1	rho1	Delta2	rho2	
Default model	.890	.874	.986	.983	.985
Saturated model	1.000		1.000		1.000
Independence model	.000	.000	.000	.000	.000

**RMSEA**

Model	RMSEA	LO 90	HI 90	PCLOSE
Default model	.028	.000	.046	.984
Independence model	.218	.209	.227	.000

Lampiran 10c. *Output Bootstrap Standard Error***Regression Weights: (Group number 1 - Default model)**

Parameter		SE	SE-SE	Mean	Bias	SE-Bias
Komitmen_Organisasi	<--- Komitmen_Professional	.091	.003	.222	-.003	.004
Kepuasan_Kerja	<--- Komitmen_Professional	.107	.003	.205	.000	.005
Kepuasan_Kerja	<--- Komitmen_Organisasi	.130	.004	.276	-.006	.006
Kinerja_Kerja	<--- Komitmen_Organisasi	.125	.004	.217	.013	.006
Kinerja_Kerja	<--- Kepuasan_Kerja	.085	.003	.168	.001	.004
x1	<--- Komitmen_Organisasi	.000	.000	1.000	.000	.000
x5	<--- Komitmen_Organisasi	.179	.006	1.349	.017	.008
x6	<--- Komitmen_Organisasi	.135	.004	1.116	.006	.006
x7	<--- Komitmen_Organisasi	.179	.006	1.163	.012	.008
x8	<--- Komitmen_Organisasi	.160	.005	1.144	.014	.007
x11	<--- Komitmen_Professional	.000	.000	1.000	.000	.000
x12	<--- Komitmen_Professional	.139	.004	1.358	.008	.006
x15	<--- Komitmen_Professional	.131	.004	1.141	.001	.006
x16	<--- Komitmen_Professional	.143	.005	1.434	.008	.006
x18	<--- Komitmen_Professional	.144	.005	1.340	.007	.006
x19	<--- Komitmen_Professional	.124	.004	1.188	.012	.006
x20	<--- Kinerja_Kerja	.000	.000	1.000	.000	.000
x21	<--- Kinerja_Kerja	.126	.004	.867	.011	.006
x23	<--- Kinerja_Kerja	.105	.003	.961	.004	.005
x24	<--- Kinerja_Kerja	.116	.004	1.038	.006	.005
x27	<--- Kinerja_Kerja	.117	.004	.921	.006	.005
x34	<--- Kepuasan_Kerja	.000	.000	1.000	.000	.000
x33	<--- Kepuasan_Kerja	.064	.002	1.025	.004	.003
x30	<--- Kepuasan_Kerja	.102	.003	.931	.005	.005
x29	<--- Kepuasan_Kerja	.103	.003	1.012	.005	.005
x28	<--- Kepuasan_Kerja	.077	.002	.852	.004	.003

Lampiran 10d. *Output Bias-corrected percentile method*Regression Weights: (Group number 1 - Default model)

Parameter		Estimate	Lower	Upper	P
Komitmen_Organisasi	<--- Komitmen_Professional	.224	.075	.376	.006
Kepuasan_Kerja	<--- Komitmen_Professional	.205	.033	.374	.053
Kepuasan_Kerja	<--- Komitmen_Organisasi	.282	.096	.517	.019
Kinerja_Kerja	<--- Komitmen_Organisasi	.204	.032	.433	.055
Kinerja_Kerja	<--- Kepuasan_Kerja	.166	.027	.307	.058
x1	<--- Komitmen_Organisasi	1.000	1.000	1.000	...
x5	<--- Komitmen_Organisasi	1.332	1.103	1.655	.003
x6	<--- Komitmen_Organisasi	1.110	.918	1.366	.003
x7	<--- Komitmen_Organisasi	1.151	.927	1.518	.002
x8	<--- Komitmen_Organisasi	1.130	.934	1.490	.002
x11	<--- Komitmen_Professional	1.000	1.000	1.000	...
x12	<--- Komitmen_Professional	1.350	1.151	1.603	.004
x15	<--- Komitmen_Professional	1.141	.972	1.420	.002
x16	<--- Komitmen_Professional	1.426	1.238	1.702	.003
x18	<--- Komitmen_Professional	1.334	1.132	1.595	.003
x19	<--- Komitmen_Professional	1.176	1.015	1.428	.003
x20	<--- Kinerja_Kerja	1.000	1.000	1.000	...
x21	<--- Kinerja_Kerja	.856	.653	1.051	.007
x23	<--- Kinerja_Kerja	.957	.801	1.146	.004
x24	<--- Kinerja_Kerja	1.032	.853	1.225	.005
x27	<--- Kinerja_Kerja	.915	.748	1.123	.004
x34	<--- Kepuasan_Kerja	1.000	1.000	1.000	...
x33	<--- Kepuasan_Kerja	1.022	.938	1.145	.003
x30	<--- Kepuasan_Kerja	.926	.781	1.124	.003
x29	<--- Kepuasan_Kerja	1.007	.855	1.188	.004
x28	<--- Kepuasan_Kerja	.848	.726	.974	.005