

BAB II

TINJAUAN PUSTAKA

2.1 Pendahuluan

Dalam penelitian yang berhubungan dengan ilmu sosial banyak sekali variabel yang tidak dapat diukur secara langsung (variabel laten). Dimana peneliti harus menggunakan indikator-indikator lagi untuk mengukur variabel yang tidak dapat diukur secara langsung tersebut (variabel laten) dimana indikator tersebut adalah sebuah variabel yang bisa diukur secara langsung (variabel manifest). Yang mempunyai tujuan untuk bisa mengetahui apakah indikator tersebut memang sudah benar untuk digunakan sebagai alat ukur dari variabel yang tidak bisa diukur secara langsungnya (variabel laten).

Setyo (2008) menyebutkan model pengukuran memodelkan hubungan antara variabel yang tidak bisa diukur secara langsung (variabel laten) dengan variabel-variabel teramati (*observed/measured variables*). Hubungan tersebut bersifat reflektif, dimana variabel-variabel teramati merupakan refleksi dari variabel laten terkait. Penerapan variabel-variabel teramati yang merefleksikan sebuah variabel laten dilakukan berdasarkan substansi dari studi yang bersangkutan. Kemudian model pengukuran berusaha untuk mengkonfirmasi apakah variabel-variabel teramati tersebut memang merupakan ukuran / refleksi dari sebuah variabel laten. Oleh karena itu, analisis model pengukuran ini disebut juga sebagai Konfirmatori Faktor Analisis (*confirmatory factor analysis*, CFA). Hasil akhir Konfirmatori Faktor Analisis (*confirmatory factor analysis*, CFA) diperoleh melalui uji kecocokan keseluruhan model, analisis validitas model dan analisis reliabilitas model.

2.2 Model Analisis Konfirmatori (*Confirmatory Factor Analysis, CFA*)

Hajarisman (2014) menyebutkan vektor acak pengamatan \mathbf{X} , dengan p buah komponen, mempunyai rata-rata μ dan matriks kovarians Σ . Model faktor menyatakan bahwa \mathbf{X} akan bergantung linier di bawah variabel acak yang tidak teramati F_1, F_2, \dots, F_m yang disebut dengan faktor umum (*common factor*), serta p buah sumber variasi tambahan $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_p$ yang disebut galat atau faktor spesifik.

Model faktor ini dapat ditulis dalam bentuk :

$$\begin{aligned} X_1 - \mu_1 &= l_{11}F_1 + l_{12}F_2 + \dots + l_{1m}F_m + \varepsilon_1 \\ X_2 - \mu_2 &= l_{21}F_1 + l_{22}F_2 + \dots + l_{2m}F_m + \varepsilon_2 \\ &\vdots \\ X_p - \mu_p &= l_{p1}F_1 + l_{p2}F_2 + \dots + l_{pm}F_m + \varepsilon_p \end{aligned} \quad (2.1)$$

atau dalam notasi matriks dapat ditulis sebagai :

$$\underset{(p \times 1)}{\mathbf{X} - \mu} = \underset{(p \times m)}{\mathbf{L}} \underset{(m \times 1)}{\mathbf{F}} + \underset{(p \times 1)}{\boldsymbol{\varepsilon}} \quad (2.2)$$

Koefisien l_{ij} disebut muatan variabel ke- i pada faktor ke- j sehingga matriks \mathbf{L} disebut sebagai matriks muatan faktor. Perlu dicatat bahwa faktor spesifik ke- i (ε_i) hanya berhubungan dengan respons ke- i (X_i). Untuk p buah simpangan $X_1 - \mu_1, X_2 - \mu_2, \dots, X_p - \mu_p$, yang dinyatakan dalam bentuk $(p + m)$ variabel acak $F_1, F_2, \dots, F_m, \varepsilon_1, \varepsilon_2, \dots, \varepsilon_p$ yang semuanya tidak teramati. Perbedaan antara model faktor (2.2) dengan model regresi multivariat adalah variabel bebasnya [dimana dalam model (2.2) ditulis sebagai \mathbf{F}] dapat diamati sedangkan dalam model faktor, variabel bebasnya tidak teramati.

Oleh karena begitu banyak besaran yang tidak teramati, maka akan sulit sekali mendapatkan model faktor langsung dari variabel X_1, X_2, \dots, X_p . akan tetapi,

dengan beberapa asumsi tambahan mengenai vektor acak \mathbf{F} dan $\boldsymbol{\varepsilon}$, model dalam (2.2) dapat ditulis melalui hubungan kovarians.

Diasumsikan bahwa :

$$E(\boldsymbol{\varepsilon}) = \mathbf{0}_{(p \times 1)}, \quad \text{Cov}(\mathbf{F}) = E[\mathbf{F}\mathbf{F}'] = \mathbf{I}_{(m \times m)}$$

$$E(\boldsymbol{\varepsilon}) = \mathbf{0}_{(p \times 1)}, \quad \text{Cov}(\boldsymbol{\varepsilon}) = E[\boldsymbol{\varepsilon}\boldsymbol{\varepsilon}'] = \boldsymbol{\psi} = \begin{pmatrix} \psi_1 & 0 & \dots & 0 \\ 0 & \psi_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \psi_p \end{pmatrix} \quad (2.3)$$

Dan bahwa \mathbf{F} dan $\boldsymbol{\varepsilon}$ saling bebas, maka

$$\text{Cov}(\boldsymbol{\varepsilon}, \mathbf{F}) = E(\boldsymbol{\varepsilon}\mathbf{F}') = \mathbf{0}_{(p \times m)}$$

Asumsi tersebut dan hubungannya dengan (2.2) dapat membentuk model faktor ortogonal. Jadi, model faktor ortogonal dengan m faktor umum adalah

$$\mathbf{X}_{(p \times 1)} = \boldsymbol{\mu}_{(p \times 1)} + \mathbf{L}_{(p \times m)} \mathbf{F}_{(m \times 1)} + \boldsymbol{\varepsilon}_{(p \times 1)} \quad (2.4)$$

Dimana μ_i = rata-rata variabel ke- i , ε_i = faktor spesifik ke- i , \mathbf{F}_i = faktor umum ke- j , dan l_{ij} = muatan dari variabel ke- i pada faktor ke- j . kemudian, vektor acak yang tidak teramati \mathbf{F} dan $\boldsymbol{\varepsilon}$ akan memenuhi sifat-sifat bahwa :

1. \mathbf{F} dan $\boldsymbol{\varepsilon}$ adalah saling bebas
2. $E(\mathbf{F})$ dan $\text{Cov}(\mathbf{F}) = \mathbf{I}$
3. $E(\boldsymbol{\varepsilon})$ dan $\text{Cov}(\boldsymbol{\varepsilon}) = \boldsymbol{\psi}$, dimana $\boldsymbol{\psi}$ merupakan matriks diagonal

Model faktor ortogonal menunjukkan struktur kovarians dari \mathbf{X} . Berdasarkan model (2.4) dapat diketahui bahwa :

$$(\mathbf{X} - \boldsymbol{\mu})(\mathbf{X} - \boldsymbol{\mu})' = (\mathbf{L}\mathbf{F} + \boldsymbol{\varepsilon})(\mathbf{L}\mathbf{F} + \boldsymbol{\varepsilon})'$$

$$\begin{aligned}
&= (\mathbf{LF} + \boldsymbol{\varepsilon})(\mathbf{LF})' + \boldsymbol{\varepsilon}\boldsymbol{\varepsilon}' \\
&= \mathbf{LF}(\mathbf{LF})' + \boldsymbol{\varepsilon}(\mathbf{LF})' + \mathbf{LF}\boldsymbol{\varepsilon}' + \boldsymbol{\varepsilon}\boldsymbol{\varepsilon}'
\end{aligned}$$

Sehingga

$$\begin{aligned}
\Sigma = \text{Cov}(\mathbf{X}) &= E(\mathbf{X} - \mu)(\mathbf{X} - \mu)' \\
&= E(\mathbf{LF} + \boldsymbol{\varepsilon})(\mathbf{LF} + \boldsymbol{\varepsilon})' \\
&= \mathbf{LF}(\mathbf{LF})' + \boldsymbol{\varepsilon}(\mathbf{LF})' + \mathbf{LF}\boldsymbol{\varepsilon}' + \boldsymbol{\varepsilon}\boldsymbol{\varepsilon}' \\
&= \mathbf{LL}' + \psi
\end{aligned} \tag{2.5}$$

dapat dicatat bahwa $(\mathbf{X} - \mu)\mathbf{F}' = (\mathbf{LF} + \boldsymbol{\varepsilon})\mathbf{F}' = \mathbf{LFF}' + \boldsymbol{\varepsilon}\mathbf{F}'$, sehingga $\text{Cov}(\mathbf{X}, \mathbf{F}) = E(\mathbf{X} - \mu)\mathbf{F}' = \mathbf{LE}(\mathbf{FF}') + E(\boldsymbol{\varepsilon}\mathbf{F}') = \mathbf{L}$. Dengan demikian dapat diringkas bahwa struktur kovarians untuk model faktor ortogonal adalah :

1. $\text{Cov}(\mathbf{X}) = \mathbf{LL}' + \psi$ atau $\text{Var}(X_i) = l_{i1}^2 + l_{i2}^2 + \dots + l_{im}^2 + \psi_i$, dan $\text{Cov}(X_i, X_k) = l_{i1}l_{k1} + l_{i2}l_{k2} + \dots + l_{im}l_{km}$
2. $\text{Cov}(\mathbf{X}, \mathbf{F}) = \mathbf{L}$ atau $\text{Cov}(X_i, F_j) = l_{ij}$.

Model $\mathbf{X} - \mu = \mathbf{LF} + \boldsymbol{\varepsilon}$ adalah linier dalam faktor umum. Apabila p buah respons \mathbf{X} berhubungan dengan faktor secara tidak linier, maka struktur kovarians $\mathbf{LL}' + \psi$ yang diberikan dalam (2.5) menjadi tidak tepat. Asumsi kelinieran ini adalah sangat penting terutama dalam pembentuksn model faktor ortogonal.

Porsi varians dari variabel ke- i yang dikontribusikan oleh m buah faktor umum disebut sebagai komunitas ke- i . porsi $\text{Var}(X_i) = \sigma_{ii}$ yang akan disebabkan oleh faktor spesiifik disebut juga sebagai varians spesifik. Misalkan komunitas ke- i dinyatakan dengan h_i^2 , maka menurut (2.5) dapat diketahui bahwa :

$$\text{Var}(X_i) = \text{komunitas} + \text{variens spesifik}$$

$$\sigma_{ii} = l_{i1}^2 + l_{i2}^2 + \dots + l_{im}^2 + \psi_i = h_i^2 + \psi_i, \text{ untuk } i = 1, 2, \dots, p \quad (2.6)$$

dimana $h_i^2 = l_{i1}^2 + l_{i2}^2 + \dots + l_{im}^2$.

Komunitas ke- i merupakan jumlah kuadrat dari muatan variabel ke- i pada m buah faktor umum.

2.3 Metode Penaksiran

Hajarisman (2014) pengamatan X_1, X_2, \dots, X_p pada p buah variabel yang secara umum berkorelasi, analisis faktor akan menjawab pertanyaan “apakah model faktor dalam (2.4), dengan sejumlah kecil faktor, cukup layak untuk menggambarkan data?” intinya masalah pembentukan model statistik ini akan ditentukan dengan cara mempelajari struktur kovarians dalam (2.5).

Matriks kovarians sampel S merupakan penaksiran bagi matriks kovarians populasi Σ . Apabila unsur-unsur diagonal utama S bernilai kecil atau unsur-unsur dalam matriks korelasi sample R mendekati nol, maka variabel-variabel tersebut tidak berhubungan dan analisis faktor menjadi tidak bermanfaat. Dalam keadaan demikian, faktor spesifik akan memegang peranan penting, padahal tujuan utama dari analisis faktor adalah untuk menentukan sejumlah kecil faktor-faktor yang penting.

Apabila Σ menyimpang secara nyata dari matriks diagonal, maka model faktor dapat dianalisis dan untuk itu perlu menaksir muatan faktor l_{ij} serta varians spesifik ψ_i . Pada bagian ini akan dibahas metode yang paling banyak digunakan yaitu metode penaksiran kemungkinan maksimum.

Hajarisman (2014) menyebutkan apabila faktor umum \mathbf{F} dan $\boldsymbol{\varepsilon}$ faktor spesifik diasumsikan berdistribusi normal, maka parameter kemungkinan maksimum bagi

muatan faktor dan varians spesifik dapat diperoleh. Jika \mathbf{F}_j dan $\boldsymbol{\varepsilon}_j$ keduanya normal, maka observasi $\mathbf{X}_j - \boldsymbol{\mu} = \mathbf{L}\mathbf{F}_j + \boldsymbol{\varepsilon}_j$ juga akan normal, sehingga fungsi kemungkinannya adalah

$$\begin{aligned} L[\boldsymbol{\mu}, \boldsymbol{\Sigma}] &= (2\pi)^{-\frac{np}{2}} |\boldsymbol{\Sigma}|^{-\frac{n}{2}} e^{-\left(\frac{1}{2}\right)tr[\boldsymbol{\Sigma}^{-1}(\sum_{j=1}^n (x_j - \bar{x})(x_j - \bar{x}) + n(\bar{x} - \boldsymbol{\mu})(\bar{x} - \boldsymbol{\mu}))]} \\ &= (2\pi)^{-\frac{(n-1)p}{2}} |\boldsymbol{\Sigma}|^{-\frac{(n-1)}{2}} e^{-\left(\frac{1}{2}\right)tr[\boldsymbol{\Sigma}^{-1}(\sum_{j=1}^n (x_j - \bar{x})(x_j - \bar{x}))]} \\ &\quad + (2\pi)^{\frac{p}{2}} |\boldsymbol{\Sigma}|^{-\frac{1}{2}} e^{-\left(\frac{1}{2}\right)(\bar{x} - \boldsymbol{\mu})\boldsymbol{\Sigma}^{-1}(\bar{x} - \boldsymbol{\mu})} \end{aligned} \quad (2.7)$$

yang bergantung pada \mathbf{L} dan $\boldsymbol{\psi}$ melalui $\boldsymbol{\Sigma} = \mathbf{L}\mathbf{L}' + \boldsymbol{\psi}$. Model ini masih tidak terdefinisi dengan baik karena banyaknya pilihan bagi \mathbf{L} yang mungkin melalui transformasi ortogonal. Diinginkan untuk membuat \mathbf{L} didefinisikan melalui

$$\mathbf{L}'\boldsymbol{\psi}^{-1}\mathbf{L} = \boldsymbol{\Delta} \quad (2.8)$$

Penaksiran kemungkinan maksimum $\hat{\mathbf{L}}$ dan $\hat{\boldsymbol{\psi}}$ harus dikerjakan secara numerik dalam persamaan (2.7). Tentu saja program komputer lebih efisien diperlukan untuk membantu memperoleh penaksiran kemungkinan maksimum. Dalam hal ini program komputer yang digunakan adalah dengan menggunakan program SAS.

Misalnya X_1, X_2, \dots, X_p adalah sebuah sampel acak dari $N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ dimana $\boldsymbol{\Sigma} = \mathbf{L}\mathbf{L}' + \boldsymbol{\psi}$ adalah matriks kovarians untuk model dengan m faktor umum pada (2.4). Penaksir kemungkinan maksimum $\hat{\mathbf{L}}$, $\hat{\boldsymbol{\psi}}$, dan $\hat{\boldsymbol{\mu}} = \bar{x}$ akan memaksimumkan (2.7) terhadap $\hat{\mathbf{L}}'\hat{\boldsymbol{\psi}}^{-1}\hat{\mathbf{L}}$. Penaksir kemungkinan maksimum bagi komunitas adalah

$$\hat{h}_i^2 = \hat{l}_{i1}^2 + \hat{l}_{i2}^2 + \dots + \hat{l}_{im}^2, \text{ untuk } i = 1, 2, \dots, p \quad (2.9)$$

Sehingga proporsi varians sampel total yang disebutkan oleh faktor ke- j adalah

$$\frac{\hat{l}_{1j}^2 + \hat{l}_{2j}^2 + \dots + \hat{l}_{pj}^2}{s_{11} + s_{22} + \dots + s_{pp}} \quad (2.10)$$

Apabila variabel dibakukan sehingga $Z = V^{-1/2}(X - \mu)$, matriks kovarians ρ dari variabel Z adalah

$$\rho = V^{-1/2}\Sigma V^{-1/2} = (V^{-1/2}\mathbf{L})(V^{-1/2}\mathbf{L})' + V^{-1/2}\psi V^{-1/2} \quad (2.11)$$

Jadi ρ mempunyai suatu faktorisasi yang analog pada (2.5) dengan matriks muatan faktor $L_z = V^{-1/2}\mathbf{L}$ dan matriks varians spesifik $\psi_z = V^{-1/2}\psi V^{-1/2}$. Berdasarkan sifat-sifat invarians dari penaksir kemungkinan maksimum, maka penaksiran kemungkinan maksimum bagi ρ adalah

$$\begin{aligned} \hat{\rho} &= (\hat{V}^{-1/2}\hat{\mathbf{L}})(\hat{V}^{-1/2}\hat{\mathbf{L}})' + \hat{V}^{-1/2}\hat{\psi}\hat{V}^{-1/2} \\ &= \hat{\mathbf{L}}_z\hat{\mathbf{L}}_z' + \hat{\psi}_z \end{aligned} \quad (2.12)$$

dimana $\hat{V}^{-1/2}$ dan $\hat{\mathbf{L}}$ masing-masing merupakan penaksir kemungkinan maksimum bagi $V^{-1/2}$ dan \mathbf{L} . Sebagai akibat dari faktorisasi pada persamaan (2.12), maka penaksiran kemungkinan maksimum bagi komunalitas akan diberikan oleh :

$$\hat{h}_i^2 = \hat{l}_{i1}^2 + \hat{l}_{i2}^2 + \dots + \hat{l}_{im}^2, \text{ untuk } i = 1, 2, \dots, p \quad (2.13)$$

Kemudian, proporsi varians (yang dibakukan) sampel total yang disebabkan oleh faktor ke- j adalah

$$\frac{\hat{l}_{1j}^2 + \hat{l}_{2j}^2 + \dots + \hat{l}_{pj}^2}{2} \quad (2.14)$$

dimana notasi \hat{l}_{pj}^2 menyatakan unsur – unsur dari matriks \hat{L}_z .

2.4. Ukuran Kecocokan Model

Tahapan penaksiran di atas menghasilkan solusi yang bernilai akhir dari parameter-parameter yang ditaksir. Dalam tahap ini, akan memeriksa tingkat kecocokan antara data dengan model.

Tahap pertama dari uji kecocokan ini ditunjukkan untuk mengevaluasi secara umum derajat kecocokan atau *goodness of fit* (GOF) antara data dengan model. Menilai GOF secara menyeluruh (*overall*) tidak dapat dilakukan secara langsung seperti pada teknik multivariat yang lain (*multiple regression, discriminant analysis, MANOVA* dan lain-lain). SEM tidak mempunyai satu uji statistik terbaik yang dapat menjelaskan “kekuatan” prediksi model, sebagai gantinya, para peneliti telah mengembangkan beberapa ukuran GOF atau *goodness of fit indices* (GOFI) yang dapat digunakan secara bersama-sama atau kombinasi.

2.4.1. Statistik Chi-Kuadrat Rasio Kemungkinan

Hipotesis yang diajukan untuk penentuan model analisis faktor konfirmatori (*Confirmatory Factor Analysis, CFA*) itu cocok atau tidak, dinyatakan sebagai berikut :

H_0 : Model analisis faktor konfirmatori (CFA) *fit* (cocok)

H_1 : Model analisis faktor konfirmatori (CFA) tidak *fit* (tidak cocok)

Ukuran yang mendasar mengenai kecocokan model adalah statistik chi-kuadrat rasio kemungkinan (*likelihood ratio chi-square statistics, χ^2*).

$$\chi^2 = (n - 1)F(S, \Sigma(\theta)) \quad (2.15)$$

dengan *degree of freedom* (df) sebesar $c - p$; dalam hal ini, $c = (nx + ny) (nx + ny + 1)/2$ adalah kebanyakan matriks varians-kovarians *non-redundan* dari variabel terukur, dimana

nx : banyaknya variabel terukur x (variabel eksogen atau F2 dan F3)

ny : banyaknya variabel terukur y (variabel endogen atau F1)

p : banyak parameter yang ditaksir

n : ukuran sampel

Nilai chi-kuadrat yang besar menunjukkan ada perbedaan yang nyata antara matriks pengamatan dengan matriks taksiran. Taraf signifikansi ini mengindikasikan peluang bahwa perbedaan ini betul-betul disebabkan oleh variansi sampling. Jadi, nilai χ^2 yang kecil, dengan taraf signifikansi lebih besar atau $> 0,05$ atau $0,01$, menunjukkan bahwa matriks aktual dan matriks prediksi tidak berbeda secara statistik. Namun demikian, walupun secara statistik dinyatakan tidak signifikan, hal ini bukan merupakan jaminan bahwa kita telah mengidentifikasi model yang “benar”, tetapi hanya menunjukkan bahwa model yang diusulkan ini cocok dengan matriks kovarians atau korelasi yang diamati. Juga, hal ini tidak menjamin bahwa model lainnya bukan merupakan model yang tidak lebih baik menurut Hair, dkk (1990) merekomendasikan agar taraf signifikan pada $0,05$ merupakan taraf minimum yang dapat diterima.

Hal yang paling kritis dari χ^2 adalah ukuran ini terlalu sensitif terhadap perbedaan ukuran sampel, khususnya dimana ukuran sampel itu lebih besar dari 200 responden. Dengan meningkatnya ukuran sampel, maka statistik ini lebih cenderung untuk memberikan indikasi perbedaan yang signifikan. Lebih jauh, untuk ukuran

sampel 100, maka chi-kuadrat akan menunjukkan kecocokan yang dapat diterima (perbedaan yang non signifikan dalam matriks pengamatan dan matriks prediksi) bahkan ketika tidak ada model hubungan yang secara statistik signifikan. Jadi, statistik chi-kuadrat ini agak sensitif dengan cara yang berbeda baik untuk ukuran sampel kecil maupun besar, dan peneliti harus menyatakan ukuran kecocokan lainnya.

2.4.2. *Goodness of Fit Index (GFI)*

Ukuran kecocokan lainnya yang diberikan oleh LISREL maupun PROC CALIS adalah indeks kecocokan model (*goodness of fit index*, GFI) yang pada awalnya diusulkan oleh Joreskog dan Sorborn (1989).

$$GFI = 1 - \frac{\hat{F}}{F_0} \quad (2.16)$$

dimana : \hat{F} : Nilai minimum dari F untuk model yang dihipotesiskan

F_0 : Nilai minimum dari F ketika ada model yang dihipotesiskan

Nilai GFI berkisar antara 0 (*poor fit*) sampai 1 (*perfect fit*) dan nilai GFI $\geq 0,90$ merupakan *good fit* (kecocokan yang baik), sedangkan $0,80 \leq GFI \leq 0,90$ sering disebut sebagai *margin fit* dan $GFI \leq 0,80$ sering disebut sebagai *close fit*.

2.4.3. *Root Mean Square Error of Approximation (RMSEA)*

Indeks ini pertama kali diusulkan oleh Steiger dan Lind (1980) dan dewasa ini merupakan salah satu indeks yang informatif. Rumus perhitungan RMSEA adalah sebagai berikut :

$$RMSEA = \sqrt{\frac{\hat{F}_0}{df}} \quad (2.17)$$

dimana : $\hat{F}_0 : \max \left\{ \hat{F} - \frac{df}{n-1}, 0 \right\}$

Nilai RMSEA $\leq 0,05$ menandakan *close fit*, sedangkan $0,05 \leq \text{RMSEA} \leq 0,08$ menunjukkan *good fit* (Brown dan Cudeck, 1993). McCallum (1996) mengelaborasi lebih jauh berkaitan dengan *cut point* ini dengan menambahkan bahwa nilai RMSEA antara 0,08 sampai 0,10 menunjukkan *mediocre (marginal) fit*, serta nilai RMSEA $\geq 0,10$ menunjukkan *poor fit*.

2.4.4. Normed Fit Index (NFI)

Salah satu ukuran yang lebih populer adalah *normed fit index* (NFI), menurut Bentler dan Bonnet (1980) dimana nilai NFI berada diantara 0 sampai dengan 1,0. sekali lagi, ukuran ini merupakan perbandingan relatif dari model yang diusulkan terhadap model nol. Untuk memperoleh nilai NFI dapat dihitung dengan menggunakan rumus :

$$\text{NFI} = \frac{\chi_i^2 - \chi_h^2}{\chi_i^2} \quad (2.18)$$

Dimana : χ_i^2 : chi-kuadrat dari null independence model

χ_h^2 : chi-kuadrat dari model yang dihipotesiskan

Nilai NFI $\geq 0,90$ merupakan *good fit* (kecocokan yang baik), sedangkan $0,80 \leq \text{NFI} \leq 0,90$ sering disebut sebagai *margin fit* dan NFI $\leq 0,80$ sering disebut sebagai *close fit*.

2.4.5. Adjusted Goodness of Fit Index (AGFI)

Ukuran pertama dari jenis ukuran ini yang diberikan oleh program LISREL maupun PROC CALIS adalah *adjusted goodness of fit index* (AGFI), yang

merupakan perluasan dari indeks GFI, tetapi menurut Joreskog dan Sorborn (1989) ukuran ini disesuaikan dengan rasio dari derajat bebas untuk model yang diusulkan terhadap derajat bebas untuk model nol.

$$AGFI = 1 - \frac{df_0}{df_h} (1 - GFI) = 1 - \frac{p}{df_h} (1 - GFI) \quad (2.19)$$

dimana : df_0 : *degree of freedom* dari tidak ada model = p

p : jumlah varians dan kovarians dari variabel teramati

df_h : *degree of freedom* dari model yang dihipotesiskan

Seperti halnya GFI, nilai AGFI $\geq 0,90$ merupakan *good fit* (kecocokan yang baik), sedangkan $0,80 \leq AGFI \leq 0,90$ sering disebut sebagai *margin fit* dan AGFI $\leq 0,80$ sering disebut sebagai *close fit*.

2.5 Penaksir Reliabilitas

Reliabilitas mengacu pada akurasi dan ketepatan prosedur pengukuran (Thorndike, Cunningham, Thorndike, & Hagen, 1991). Ini berarti bahwa reliabilitas mengukur sejauh mana sebuah indikator tepat dan yang tidak tepat yang bisa digunakan dalam mengukur sebuah variabel yang tidak bisa diukur secara langsungnya (variabel laten). Dalam penelitian ini ada dua reliabilitas yang digunakan sebagai alat untuk melihat keandalan dari sebuah indikator, yang terdiri dari reliabilitas komposit dan reliabilitas maksimum.

2.5.1 Reliabilitas Komposit

Reliabilitas komposit telah dibahas oleh beberapa penulis (misalnya, Bentler, 2007; McDonald, 1970, 1999; Raykov, 1997; Werts, Linn, & Joreskog, 1974) dan konsep dasarnya mirip dengan α yang di dalamnya merupakan rasio taksiran skor

varians sejati skala relatif terhadap total variannya. Tidak seperti Cronbach's α , reliabilitas komposit (ω) memungkinkan terjadinya kemungkinan item yang membangun korelasi heterogen dan taksiran skor varians benar sebagai fungsi untuk item dari muatan faktor (l_i) dalam matriks yang berisikan elemen-elemen dari muatan faktor (Λ). Dengan asumsi dapat membangun faktor yang tidak bisa diamati secara langsung atau faktor laten (yaitu, dengan varians tetap), reliabilitas komposit atau ω dapat diperkirakan sebagai berikut :

$$\omega = \frac{(\sum_{i=1}^k l_i)^2}{(\sum_{i=1}^k l_i)^2 + \sum_{i=1}^k \varepsilon_i} \quad (2.20)$$

dimana l_i mewakili muatan faktor untuk item faktor umum ke i dan ε_i merupakan kekeliruan untuk masing-masing variabel ke i dimana $\varepsilon_i = 1 - l_i$ (1 dikurangi dengan masing-masing muatan faktor untuk item faktor umum ke i).

Pembilang di reliabilitas komposit (ω) identik dengan $\mathbf{1}'\Lambda\mathbf{1}$ (yaitu matriks persegi), dalam jumlah penuh yang berisikan model matriks kovarians item skor benar, sedangkan penyebut merupakan varians skor benar ditambah dengan semua varians galatnya. Di bawah kesetaraan yang sama, seperti pada persamaan yang sebelumnya menjadi matematis identik ketika model faktor digunakan untuk memperkirakan reliabilitas komposit (ω) cocok dengan data yang sebenarnya. Pada Cronbach's α mungkin dianggap sebagai kasus khusus dari reliabilitas komposit (ω) di bawah kesetaraan yang sama. Kebenaran skor matriks kovarians yang menyebutkan bahwa semua sama dengan rata-rata antar item kovarians, dan penyebut dari kedua persamaan hanya mewakili jumlah dari semua sumber skor skala varians. Menurut Hair, dkk (1998) nilai reliabilitas komposit dikatakan bisa diterima apabila nilai dari perhitungannya lebih besar dari 0,7.

2.5.2 Reliabilitas Maksimal

Reliabilitas komposit merupakan hubungan antara skala yang mendasari faktor laten dan satuan unit komposit terboboti, tetapi unit skala komposit terboboti mungkin tidak optimal mencerminkan konstruk laten yang mendasarinya. Varians skor benar diperkirakan pada analisis faktor memungkinkan untuk indikator heterogen terboboti, dan itu adalah wajar untuk memungkinkan adanya korelasi heterogen terboboti sama demikian pula saat membuat skor skala komposit. Salah satu alternatif untuk membandingkan skor varians benar dengan skala varians dari unit terboboti yang disebut sebagai reliabilitas maksimal (H, misalnya, Bentler, 2007; Conger, 1980; Hancock & Mueller, 2001; Li, 1997; Raykov, 2004), yang mewakili skala reliabilitas komposit secara optimal terboboti:

$$H = \frac{\sum_{i=1}^k \frac{\ell_i^2}{1 - \ell_i^2}}{1 + \sum_{i=1}^k \frac{\ell_i^2}{1 - \ell_i^2}} \quad (2.21)$$

dimana ℓ_j^2 merupakan kuadrat dari muatan faktor yang dibakukan dari indikator faktor umum ke i , yang identik dengan reliabilitas indikator ke i (dengan asumsi model faktor umum ditentukan dengan benar). Rumus yang lain dari Hancock dan Mueller (2001) menunjukkan bahwa :

$$H = \left(1 + \frac{1}{\sum_{i=1}^k \frac{\ell_i^2}{1 - \ell_i^2}} \right)^{-1} \quad (2.22)$$

Karena reliabilitas maksimal (H) indikator optimal terboboti dan kuadrat muatan faktor, Hancock dan Mueller (2001) menyatakan bahwa reliabilitas maksimal (H) memiliki beberapa sifat yang tidak dimiliki oleh reliabilitas komposit. Pertama,

reliabilitas komposit negatif dipengaruhi oleh muatan faktor negatif (yaitu, jumlah pembilang semua muatan faktor sebelum dikuadratkan), muatan faktor kuadrat digunakan di reliabilitas maksimal (H) memungkinkan indikator berkontribusi negatif berarti bagi nilai taksiran varians yang benar. Kedua, karena reliabilitas maksimal (H) indikator optimal terboboti ketika menghitung skor komposit, reliabilitas maksimal (H) tidak akan kurang dari reliabilitasnya (yaitu, kuadrat dari muatan faktor yang dibakukan) dari indikator. Demikian pula, penambahan indikator dapat mengurangi nilai taksiran reliabilitas komposit tetapi tidak akan mengurangi nilai reliabilitas maksimal (H). karena indikator yang lemah akan menerima beban yang sangat kecil ketika menghitung nilai komposit optimal terboboti. Oleh karena itu reliabilitas maksimal (H) menganggap indikator yang lemah setidaknya cukup memberikan informasi, dan masuknya indikator yang lemah kedalam skala tidak harus mengurangi keandalan komposit secara optimal terboboti. Pembobotan ini juga berarti, bahwa H bukan taksiran parameter populasi yang sama dengan reliabilitas komposit (ω) atau cronbach's α . Seperti halnya reliabilitas komposit nilai reliabilitas maksimal dikatakan bisa diterima apabila nilai dari perhitungannya lebih besar dari 0,7.