

**การวิเคราะห์องค์ประกอบเชิงยืนยัน
ตอนที่ 4 (Confirmatory Factor
Analysis: Part 4)**



สันทัด พรประเสริฐมานิต



โครงร่างการนำเสนอ

- โมเดลองค์ประกอบลำดับที่สอง (Second-order Factor Model)
- โมเดลองค์ประกอบสองด้าน (Bifactor Model)
- ตัวบ่งชี้แบบจัดอันดับ (Ordered Categorical Indicators)




โมเดลองค์ประกอบอันดับที่สอง

- CFA ในบทที่ผ่านมาจะเป็นการอธิบายว่าตัวบ่งชี้แต่ละตัว มีองค์ประกอบแฝงอะไรบ้าง

$$\begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ x_5 \\ x_6 \\ x_7 \\ x_8 \\ x_9 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ \lambda_{21} & 0 & 0 \\ \lambda_{31} & 0 & 0 \\ 0 & 1 & 0 \\ 0 & \lambda_{52} & 0 \\ 0 & \lambda_{62} & 0 \\ 0 & 0 & 1 \\ 0 & 0 & \lambda_{83} \\ 0 & 0 & \lambda_{93} \end{bmatrix} \begin{bmatrix} S_1 \\ S_2 \\ S_3 \end{bmatrix} + \begin{bmatrix} e_1 \\ e_2 \\ e_3 \\ e_4 \\ e_5 \\ e_6 \\ e_7 \\ e_8 \\ e_9 \end{bmatrix}$$

$$\mathbf{x} = \mathbf{\Lambda s} + \mathbf{e}$$

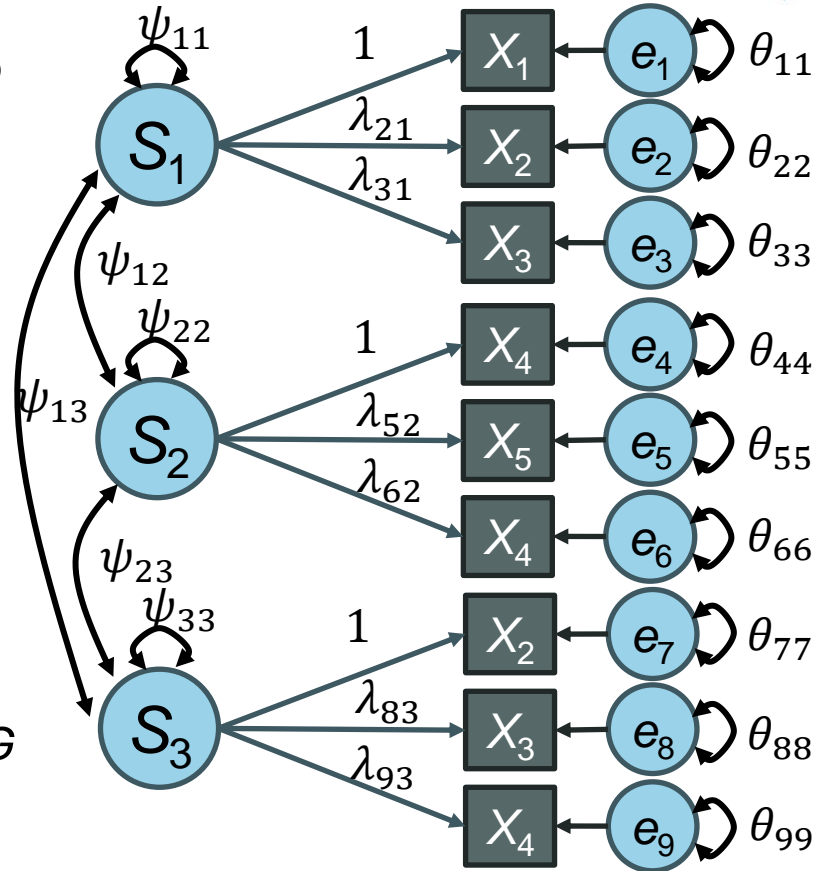


โมเดลองค์ประกอบอันดับที่สอง

- ในโมเดลนี้ \mathbf{s} จะมีเมทริกซ์ความแปรปรวนร่วม คือ

$$\begin{bmatrix} \psi_{11} & & & \\ \psi_{21} & \psi_{22} & & \\ \psi_{31} & \psi_{32} & \psi_{33} & \end{bmatrix}$$

- แนวคิดของโมเดลองค์ประกอบอันดับที่สอง (Second-order Factor) คือ องค์ประกอบ \mathbf{s} เหล่านี้ที่เป็นองค์ประกอบอันดับที่หนึ่ง (First-order Factor) อาจมีองค์ประกอบที่อยู่เหนือขึ้นไป อธิบายการเปลี่ยนแปลงของ \mathbf{s} ร่วมกัน เรียกว่า G



โมเดลองค์ประกอบอันดับที่สอง

- กล่าวคือ


$$S_1 = \beta_1 G + d_1$$

$$S_2 = \beta_2 G + d_2$$

$$S_3 = \beta_3 G + d_3$$

$$\begin{bmatrix} S_1 \\ S_2 \\ S_3 \end{bmatrix} = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \beta_3 \end{bmatrix} [G] + \begin{bmatrix} d_1 \\ d_2 \\ d_3 \end{bmatrix}$$

$$\mathbf{s} = \mathbf{B}\mathbf{g} + \mathbf{d}$$



โมเดลองค์ประกอบอันดับที่สอง

- โมเดลที่มีองค์ประกอบอธิบายเป็นอันดับขึ้น จะเรียกว่า โมเดลองค์ประกอบลำดับชั้น (Hierarchical Factor Model) และถ้ามีเพียงสองอันดับขึ้น เรียกว่า โมเดลองค์ประกอบอันดับที่สอง (Second-order Factor Model)
- ตัวอย่างของโมเดลองค์ประกอบอันดับที่สอง เช่น บุคลิกภาพ ที่มีองค์ประกอบย่อย 30 องค์ประกอบ (อาจเรียกว่า Facets) และมีองค์ประกอบอันดับที่สอง 5 องค์ประกอบ ที่เรียกว่า Big Five
- องค์ประกอบอันดับที่สอง มีการระบุสเกลได้ทั้งแบบ Fixed-Factor Approach หรือ Marker “variable” (ควรเป็น first-order factor) approach
- โมเดลที่ระบุได้ ถ้ามีองค์ประกอบอันดับที่สองแค่องค์ประกอบเดียว ควรมีย่อยประกอบย่อยอย่างน้อย 3 องค์ประกอบเพื่อให้ระบุโมเดลได้ แต่หากมีองค์ประกอบอันดับที่สองมากกว่า 1 องค์ประกอบ ควรมีย่อยประกอบย่อย 2 องค์ประกอบต่อแต่ละองค์ประกอบอันดับที่สอง

โมเดลองค์ประกอบอันดับที่สอง

- การประเมินความเหมาะสมของโมเดล ควรทำเป็นสองขั้นตอน คือ
 - ประเมินโมเดลที่มีเฉพาะองค์ประกอบอันดับที่หนึ่งก่อน ซึ่งเป็นโมเดล CFA ปกติ ใช้วิธีการประเมินความเหมาะสมของโมเดลแบบเต็ม
 - ประเมินโมเดลที่มีองค์ประกอบอันดับที่สอง เปรียบเทียบกับโมเดลที่แล้วด้วย Nested Model Comparison
- นักวิเคราะห์มุ่งที่จะหาทั้งคะแนนขององค์ประกอบทั้งอันดับแรกและอันดับที่สอง เช่น ต้องการรู้ทั้งคะแนนความรับผิดชอบ ที่เป็นองค์ประกอบอันดับที่สอง และการปฏิบัติตามหน้าที่ (Dutifulness) ที่เป็นองค์ประกอบอันดับที่หนึ่ง
 - ดังนั้น นักวิเคราะห์อาจต้องการสร้างคะแนนองค์ประกอบเพื่อประมาณค่าคะแนนองค์ประกอบเหล่านี้
 - วิธีการสร้างคะแนนองค์ประกอบที่ได้รับความนิยม คือ คะแนนรวมของข้อคำถาม ทำให้ต้องประเมินความเที่ยงของคะแนนรวมเหล่านั้น

คะแนนองค์ประกอบอันดับที่หนึ่ง

$$X_{ij} = \mu_j + \lambda_{jk} S_{ki} + e_{ij}$$


$$X_{ij} = \mu_j + \lambda_{jk} (\beta_k G + d_k) + e_{ij}$$

$$X_{ij} = \mu_j + \lambda_{jk} \beta_k G + \lambda_{jk} d_k + e_{ij}$$

คะแนนองค์ประกอบรวม

คะแนนองค์ประกอบย่อย

เมื่อควบคุมองค์ประกอบรวมให้คงที่



$$\hat{S}_{1i} = X_{i1} + X_{i2} + X_{i3} \quad X_{ij} = \mu_j + \lambda_{jk}\beta_k G_i + \lambda_{jk}d_{ki} + e_{ij}$$

$$\hat{S}_{1i} = \mu_1 + \lambda_{11}\beta_1 G_i + \lambda_{11}d_{1i} + e_{i1} + \mu_2 + \lambda_{21}\beta_1 G_i + \lambda_{21}d_{1i} + e_{i2} + \mu_3 + \lambda_{31}\beta_1 G_i + \lambda_{31}d_{1i} + e_{i3}$$

$$\hat{S}_{1i} = \sum_{j=1}^3 \mu_j + G_i \sum_{j=1}^3 \lambda_{j1} \beta_1 + d_{1i} \sum_{j=1}^3 \lambda_{j1} + \sum_{j=1}^3 e_{ij}$$

$$\text{Var}(\hat{S}_{1i}) = \text{Var}\left(\sum_{j=1}^3 \mu_j + G_i \sum_{j=1}^3 \lambda_{j1} \beta_1 + d_{1i} \sum_{j=1}^3 \lambda_{j1} + \sum_{j=1}^3 e_{ij}\right) = \text{Var}\left(G_i \sum_{j=1}^3 \lambda_{j1} \beta_1 + d_{1i} \sum_{j=1}^3 \lambda_{j1} + \sum_{j=1}^3 e_{ij}\right)$$

$$\text{Var}(\hat{S}_{1i}) = \left(\sum_{j=1}^3 \lambda_{j1} \beta_1\right)^2 \text{Var}(G_i) + \left(\sum_{j=1}^3 \lambda_{j1}\right)^2 \text{Var}(d_{1i}) + \sum_{j=1}^3 \text{Var}(e_{ij})$$

$$\text{Var}(\hat{S}_{1i}) = \phi_{11} \left(\sum_{j=1}^3 \lambda_{j1} \beta_1\right)^2 + \psi_{11} \left(\sum_{j=1}^3 \lambda_{j1}\right)^2 + \sum_{j=1}^3 \theta_{jj}$$

โมเดลองค์ประกอบอันดับที่สอง

- ค่าสัมประสิทธิ์โอเมก้า คือ สัดส่วนของความแปรปรวนองค์ประกอบทั้งหมดต่อความแปรปรวนของคะแนนรวม คือ

$$\omega_{S_1} = \frac{\phi_{11}(\sum_{j=1}^3 \lambda_{j1} \beta_1)^2 + \psi_{11}(\sum_{j=1}^3 \lambda_{j1})^2}{\text{Var}(X_1 + X_2 + X_3)}$$

- ถ้านักวิเคราะห์ต้องการเอาคะแนนองค์ประกอบย่อย ไปอ้างอิงถึงคะแนนองค์ประกอบรวม ให้ใช้ค่าสัมประสิทธิ์โอเมก้าแบบลำดับชั้น (Hierarchical Omega) ได้ผลดังนี้ (Zinbarg et al., 2005)

$$\omega_{H(S_1)} = \frac{\phi_{11}(\sum_{j=1}^3 \lambda_{j1} \beta_1)^2}{\text{Var}(X_1 + X_2 + X_3)}$$

$$\hat{H}_i = \sum_{j=1}^9 X_{ij} \quad X_{ij} = \mu_j + \lambda_{jk} \beta_k G_i + \lambda_{jk} d_{ki} + e_{ij}$$

$$\hat{H}_{1i} = \sum_{j=1}^9 \mu_j + G_i \sum_{j=1}^3 \lambda_{j1} \beta_1 + d_{1i} \sum_{j=1}^3 \lambda_{j1} + G_i \sum_{j=4}^6 \lambda_{j2} \beta_2 + d_{2i} \sum_{j=4}^6 \lambda_{j2} + G_i \sum_{j=7}^9 \lambda_{j3} \beta_3 + d_{3i} \sum_{j=7}^9 \lambda_{j3} + \sum_{j=1}^9 e_{ij}$$

$$\hat{H}_{1i} = \sum_{j=1}^9 \mu_j + G_i \left(\sum_{j=1}^3 \lambda_{j1} \beta_1 + \sum_{j=4}^6 \lambda_{j2} \beta_2 + \sum_{j=7}^9 \lambda_{j3} \beta_3 \right) + d_{1i} \sum_{j=1}^3 \lambda_{j1} + d_{2i} \sum_{j=4}^6 \lambda_{j2} + d_{3i} \sum_{j=7}^9 \lambda_{j3} + \sum_{j=1}^9 e_{ij}$$

$$\text{Var}(\hat{H}_{1i}) = \phi_{11} \left(\sum_{j=1}^3 \lambda_{j1} \beta_1 + \sum_{j=4}^6 \lambda_{j2} \beta_2 + \sum_{j=7}^9 \lambda_{j3} \beta_3 \right)^2 + \psi_{11} \left(\sum_{j=1}^3 \lambda_{j1} \right)^2 + \psi_{22} \left(\sum_{j=4}^6 \lambda_{j2} \right)^2 + \psi_{33} \left(\sum_{j=7}^9 \lambda_{j3} \right)^2 + \sum_{j=1}^9 \theta_{jj}$$

โมเดลองค์ประกอบอันดับที่สอง

- ค่าสัมประสิทธิ์โอเมก้าของคะแนนรวมทั้งมาตร คือ สัดส่วนของความแปรปรวนองค์ประกอบทั้งหมด (ทั้งอันดับที่หนึ่งและอันดับที่สอง) ต่อความแปรปรวนของคะแนนรวม คือ

$$\omega = \frac{\phi_{11}(\sum_{j=1}^3 \lambda_{j1} \beta_1 + \sum_{j=4}^6 \lambda_{j2} \beta_2 + \sum_{j=7}^9 \lambda_{j3} \beta_3)^2 + \psi_{11}(\sum_{j=1}^3 \lambda_{j1})^2 + \psi_{22}(\sum_{j=4}^6 \lambda_{j2})^2 + \psi_{33}(\sum_{j=7}^9 \lambda_{j3})^2}{\text{Var}(\sum X_j)}$$

- อย่างไรก็ตาม นักวิเคราะห์มักต้องการนำคะแนนรวมทั้งมาตรไปอ้างถึงองค์ประกอบอันดับที่สองอยู่แล้ว ในที่นี้ ค่าสัมประสิทธิ์โอเมก้าแบบลำดับชั้น (Hierarchical Omega) จะมีประโยชน์กว่า

$$\omega_H = \frac{\phi_{11}(\sum_{j=1}^3 \lambda_{j1} \beta_1 + \sum_{j=4}^6 \lambda_{j2} \beta_2 + \sum_{j=7}^9 \lambda_{j3} \beta_3)^2}{\text{Var}(\sum X_j)}$$

- รากที่ 2 ของค่าสัมประสิทธิ์โอเมก้าแบบลำดับชั้น จะเท่ากับค่าสหสัมพันธ์ระหว่างคะแนนรวมและองค์ประกอบอันดับที่สอง

โมเดลองค์ประกอบอันดับที่สอง

- วิเคราะห์องค์ประกอบย่อยของความรับผิดชอบ ก่อนวิเคราะห์โมเดลองค์ประกอบอันดับที่สอง

```
> library(lavaan)
> datcon <- read.table("lecture11consci.csv", sep=",", header=TRUE, na.strings="999")
> mcon <- '
+ achi =~ c1 + c7 + c13 + c19 + c25 + c31 + c37 + c43 + c49 + c55
+ caut =~ c2 + c8 + c14 + c20 + c26 + c32 + c38 + c44 + c50 + c56
+ duti =~ c3 + c9 + c15 + c21 + c27 + c33 + c39 + c45 + c51 + c57
+ orde =~ c4 + c10 + c16 + c22 + c28 + c34 + c40 + c46 + c52 + c58
+ disc =~ c5 + c11 + c17 + c23 + c29 + c35 + c41 + c47 + c53 + c59
+ effi =~ c6 + c12 + c18 + c24 + c30 + c36 + c42 + c48 + c54 + c60'
> outcon <- cfa(mcon, data=datcon)
> summary(outcon, fit=TRUE, std=TRUE)
lavaan 0.6-12 ended normally after 193 iterations
```

Estimator	ML
Optimization method	NLMINB
Number of model parameters	135
Number of observations	475

Model Test User Model:

Test statistic	5080.683
Degrees of freedom	1695
P-value (Chi-square)	0.000

User Model versus Baseline Model:

Comparative Fit Index (CFI)	0.633
Tucker-Lewis Index (TLI)	0.616

Loglikelihood and Information Criteria:

Loglikelihood user model (H0)	-32826.252
Loglikelihood unrestricted model (H1)	-30285.910

Akaike (AIC)	65922.504
Bayesian (BIC)	66484.551
Sample-size adjusted Bayesian (BIC)	66056.081

Root Mean Square Error of Approximation:

RMSEA	0.065
90 Percent confidence interval - lower	0.063
90 Percent confidence interval - upper	0.067
P-value RMSEA <= 0.05	0.000

Standardized Root Mean Square Residual:

SRMR	0.094
------	-------

$\chi^2(1695, N = 475) = 5080.68, p < .001, CFI = .633, TLI = .616, RMSEA = .065, SRMR = .094$

โมเดลไม่ได้เหมาะสมกับข้อมูลดี แต่ใช้โมเดลนี้ต่อเพื่อเป็นตัวอย่างในการสอน

```
> inspect(outcon, "cov.lv")
      achi  caut  duti  orde  disc  effi
achi 0.204
caut 0.009 0.004
duti 0.148 0.015 0.245
orde 0.174 0.018 0.144 0.356
disc 0.138 0.013 0.114 0.171 0.145
effi 0.181 0.009 0.128 0.161 0.146 0.184
> inspect(outcon, "cor.lv")
      achi  caut  duti  orde  disc  effi
achi 1.000
caut 0.289 1.000
duti 0.663 0.450 1.000
orde 0.645 0.470 0.489 1.000
disc 0.802 0.506 0.603 0.753 1.000
effi 0.935 0.318 0.605 0.630 0.890 1.000
```

คำนวณความแปรปรวนร่วมระหว่างองค์ประกอบ

คำนวณสหสัมพันธ์ระหว่างองค์ประกอบ

องค์ประกอบย่อยทั้งหมดมีความสัมพันธ์ไปด้วยกัน
เป็นไปได้ว่ามีองค์ประกอบชั้นที่สอง

วิเคราะห์โมเดลองค์ประกอบลำดับที่สอง

```
> mconh <- '
+ achi =~ c1 + c7 + c13 + c19 + c25 + c31 + c37 + c43 + c49 + c55
+ caut =~ c2 + c8 + c14 + c20 + c26 + c32 + c38 + c44 + c50 + c56
+ duti =~ c3 + c9 + c15 + c21 + c27 + c33 + c39 + c45 + c51 + c57
+ orde =~ c4 + c10 + c16 + c22 + c28 + c34 + c40 + c46 + c52 + c58
+ disc =~ c5 + c11 + c17 + c23 + c29 + c35 + c41 + c47 + c53 + c59
+ effi =~ c6 + c12 + c18 + c24 + c30 + c36 + c42 + c48 + c54 + c60
+ con =~ achi + caut + duti + orde + disc + effi'
> outconh <- cfa(mconh, data=datcon)
> summary(outconh, fit=TRUE, std=TRUE)
lavaan 0.6-12 ended normally after 139
```

Estimator
Optimization method
Number of model parameters

Number of observations

475

Model Test User Model:

Test statistic
Degrees of freedom
P-value (Chi-square)

5175.991
1704
0.000

นิยามองค์ประกอบลำดับที่สอง
โดยเสมือนองค์ประกอบลำดับ
ที่หนึ่งเป็นตัวบ่งชี้เลย

User Model versus Baseline Model:

Comparative Fit Index (CFI) 0.623
Tucker-Lewis Index (TLI) 0.609

Loglikelihood and Information Criteria:

Loglikelihood user model (H0) -32873.906
Loglikelihood unrestricted model (H1) -30285.910

Akaike (AIC) 65999.812
Bayesian (BIC) 66524.390
Sample-size adjusted Bayesian (BIC) 66124.484

Root Mean Square Error of Approximation:

RMSEA 0.065
90 Percent confidence interval - lower 0.063
90 Percent confidence interval - upper 0.068
P-value RMSEA <= 0.05 0.000

Standardized Root Mean Square Residual:

SRMR 0.096

$\chi^2(1704, N = 475) = 5175.99, p < .001, CFI = .623, TLI = .609, RMSEA = .065, SRMR = .096$

ค่าดัชนีความเหมาะสมตกลงเล็กน้อย เมื่อเทียบกับโมเดล CFA

Con =~	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
achi	1.000				0.935	0.935
caut	0.072	0.043	1.686	0.092	0.441	0.441
duti	0.811	0.088	9.217	0.000	0.670	0.670
orde	1.060	0.105	10.115	0.000	0.723	0.723
disc	0.846	0.110	7.687	0.000	0.935	0.935
effi	0.961	0.096	10.028	0.000	0.949	0.949

```
> library(nonnest2)
> vuongtest(outcon, outconh, nested=TRUE)
```

```
Model 1
Class: lavaan
Call: lavaan::lavaan(model = mcon, data = datcon, model.type = "cfa", ...)
```

```
Model 2
Class: lavaan
Call: lavaan::lavaan(model = mconh, data = datcon, model.type = "cfa", ...)
```

```
Variance test
H0: Model 1 and Model 2 are indistinguishable
H1: Model 1 and Model 2 are distinguishable
w2 = 0.354, p = <2e-16
```

```
Robust likelihood ratio test of distinguishable models
H0: Model 2 fits as well as Model 1
H1: Model 1 fits better than Model 2
LR = 95.308, p = 1.16e-08
```

ดูแล้วมี **Cautiousness** ตัวเดียวที่
Standardized Loadings
ต่ำที่สุด องค์กรประกอบย่อยอื่น มีขนาดดี

พบว่าโมเดล **CFA** ปกติดีกว่าโมเดล
องค์กรประกอบสองชั้นแตกต่างอย่างมีนัยสำคัญ
ตามนี้ ควรเลือกโมเดล **CFA** ปกติ หรือหา
โมเดลองค์กรประกอบอันดับที่สองอื่น

จากที่ผมลองตรวจสอบแล้ว พบว่าหากนำ
Cautiousness ออกจากโมเดลแล้ว
โมเดลองค์กรประกอบแบบสองชั้นจะเหมาะสมดี


```

> detailscon <- data.frame(detailscon[,c("VariableName", "Direction")])
> detailscon <- detailscon[detailscon$VariableName %in% paste0("c", 1:60),]
>
> for(i in 1:nrow(detailscon)) {
+   if(detailscon[i, "Direction"] == "-"){
+     temp <- datcon[,detailscon[i, "VariableName"]]
+     temp <- 6 - temp
+     datcon[,detailscon[i, "VariableName"]] <- temp
+   }
+ }
> outcon <- cfa(mcon, data=datcon)
> outconh <- cfa(mconh, data=datcon)
>
> library(semTools)
> compRelSEM(outconh, higher="con")
  achi  caut  duti  orde  disc  effi  con
0.636 0.697 0.768 0.816 0.720 0.797 0.777

```

ประมาณค่าโมเดลใหม่

หาความเที่ยงโดยกำหนดองค์ประกอบลำดับที่สองใน higher

สูตรโอเมก้าลำดับชั้นของผลรวมคะแนนทุกข้อ

สังเกตที่สีของตัวอักษร ว่าตรงกับสูตรไหนในสไลด์ที่ผ่านมา

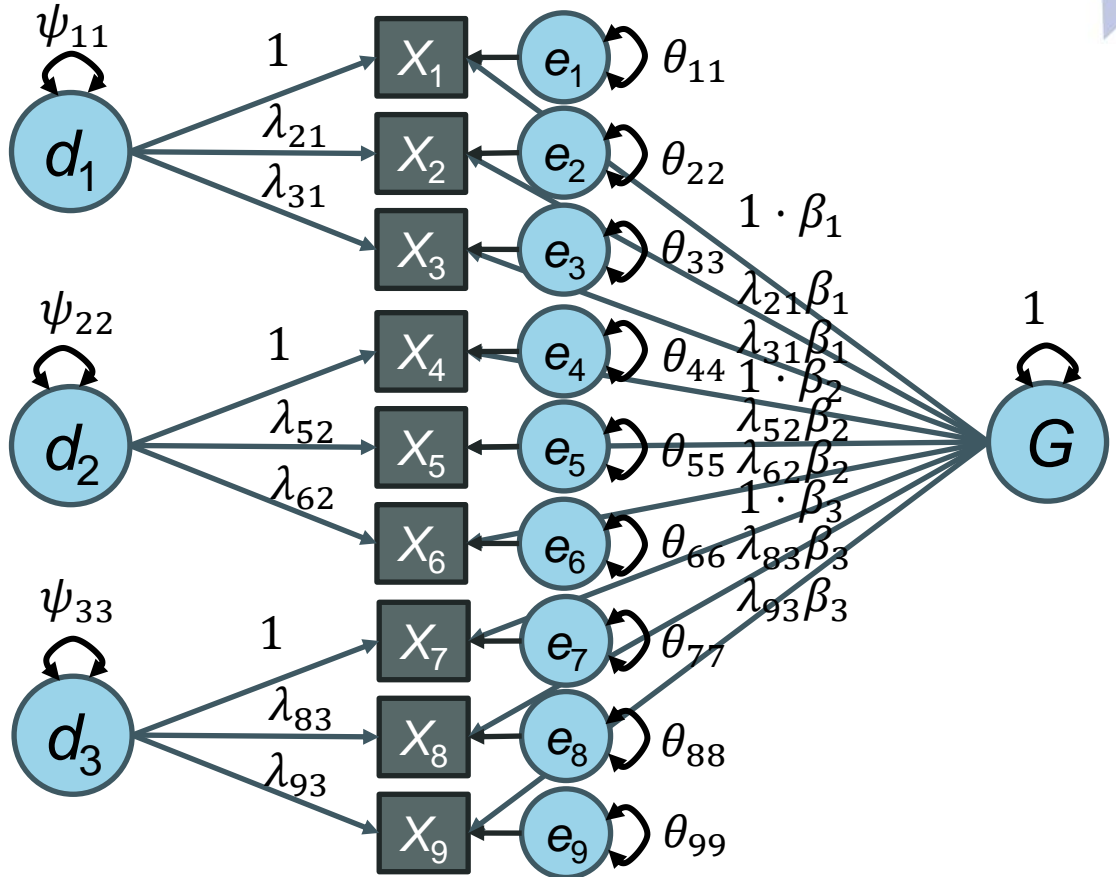
ก่อนหาความเที่ยง ต้องกลับคะแนน
ข้อคำถามทุกข้อให้เป็นทิศทางเดียวกันก่อน

ผมเขียน **for loop** เพื่อให้อ่านข้อมูล
แล้วกลับคะแนนแต่ละข้ออัตโนมัติ
ถ้าไม่ถนัด เขียนกลับคะแนน โดยนำ
คะแนนไปลบจาก **6** ทีละข้อได้เลย

สูตรโอเมก้าปกติกขององค์ประกอบย่อย
(ผลรวมจะเฉพาะข้อที่อยู่ในแต่ละ
องค์ประกอบย่อย)

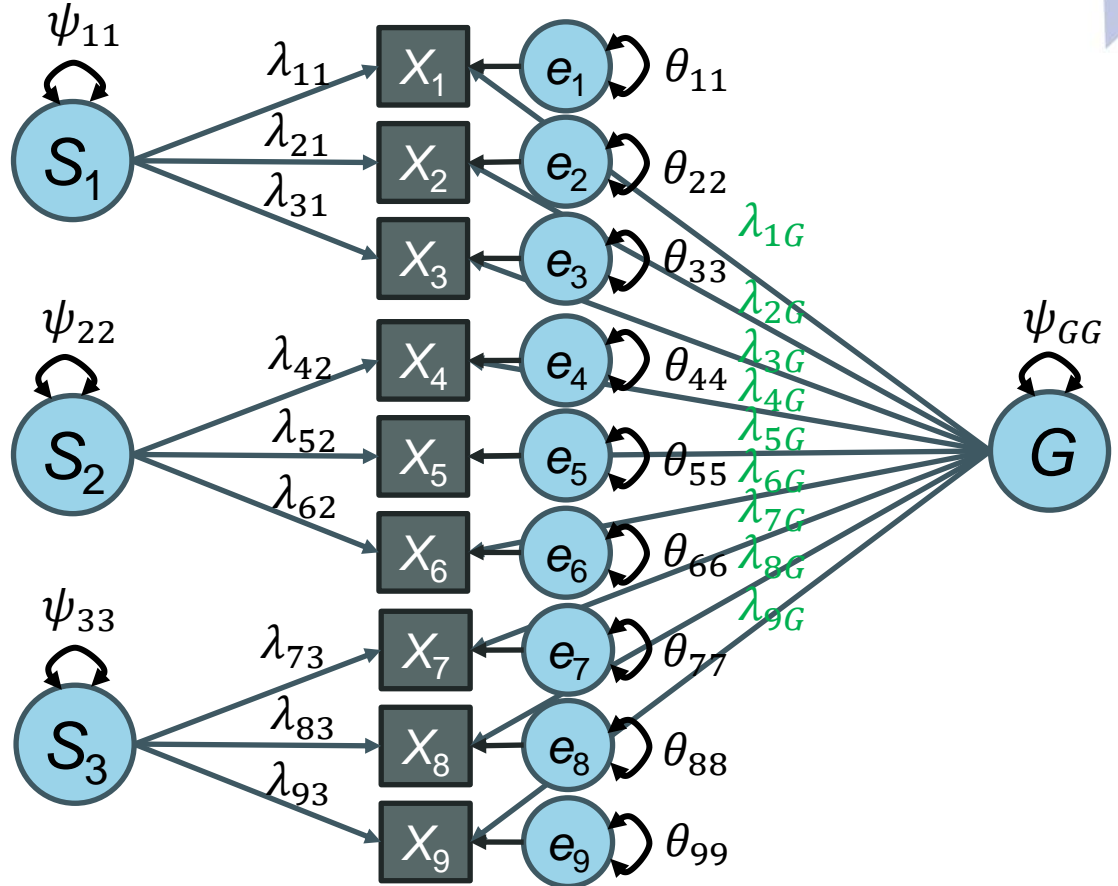
โมเดลองค์ประกอบสองด้าน

- โมเดลองค์ประกอบลำดับชั้นจะมองว่า องค์ประกอบอันดับที่หนึ่งถูกอธิบายด้วยองค์ประกอบอันดับที่สองซ้อนอีกทีหนึ่ง
- ถ้าเขียนโมเดลองค์ประกอบลำดับชั้นใหม่ จะสามารถเขียนได้ดังนี้
- เห็นว่า แต่ละข้อคำถามจะอธิบายด้วยองค์ประกอบรวม (G) และองค์ประกอบกลุ่มย่อย (d)



โมเดลองค์ประกอบสองด้าน

- อีกแนวคิดหนึ่ง มองว่าตัวบ่งชี้ทั้งหมด วัดเพียงองค์ประกอบองค์ประกอบเดียว แต่ตัวบ่งชี้บางข้อสามารถจับกลุ่มกัน ในสิ่งที่ไม่เกี่ยวข้องกับองค์ประกอบที่ต้องการวัด แนวคิดองค์ประกอบแบบนี้จะเรียกว่า โมเดลองค์ประกอบสองด้าน (Bifactor Model) เกิดจาก
 - องค์ประกอบรวม (General Factor)
 - องค์ประกอบย่อย (Specific Factor)

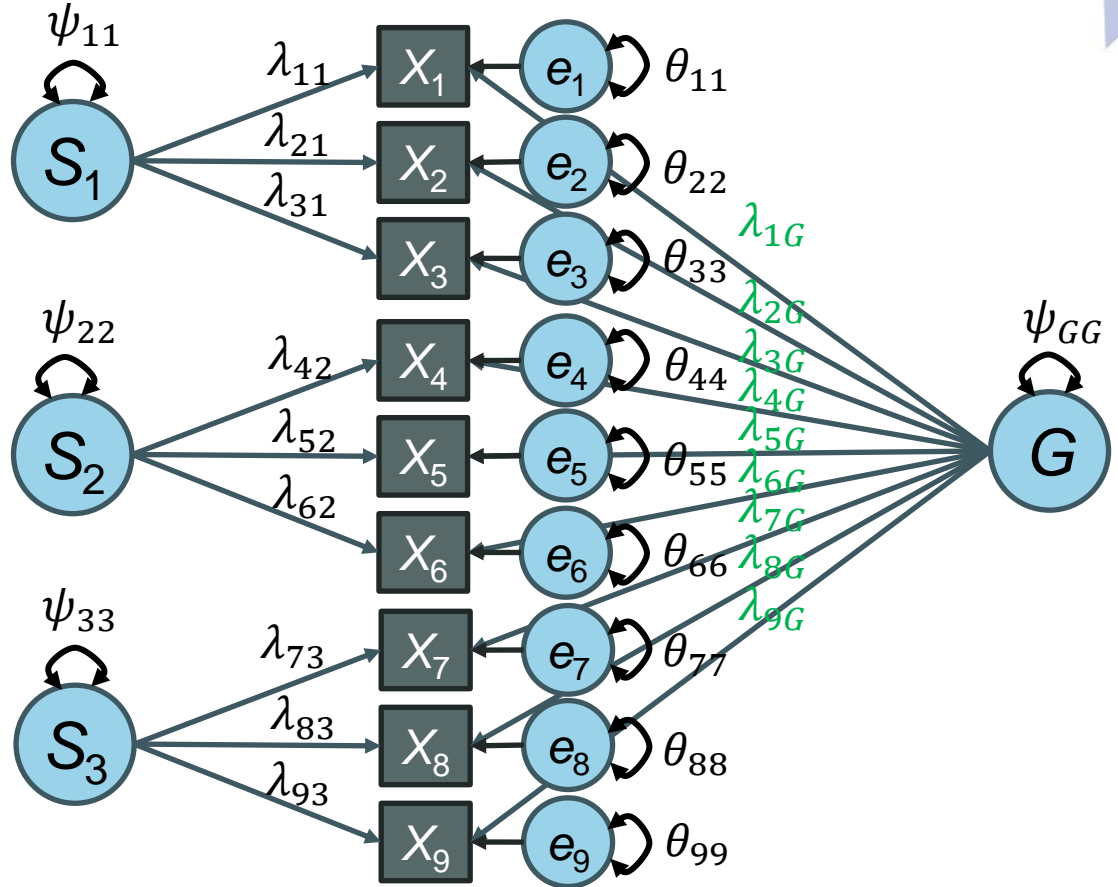




Bifactor model

$$\mathbf{x} = \Lambda \mathbf{f} + \mathbf{e}$$

$$\begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ x_5 \\ x_6 \\ x_7 \\ x_8 \\ x_9 \end{bmatrix} = \begin{bmatrix} \lambda_{1G} & \lambda_{11} & 0 & 0 \\ \lambda_{2G} & \lambda_{21} & 0 & 0 \\ \lambda_{3G} & \lambda_{31} & 0 & 0 \\ \lambda_{4G} & 0 & \lambda_{42} & 0 \\ \lambda_{5G} & 0 & \lambda_{52} & 0 \\ \lambda_{6G} & 0 & \lambda_{62} & 0 \\ \lambda_{7G} & 0 & 0 & \lambda_{73} \\ \lambda_{8G} & 0 & 0 & \lambda_{83} \\ \lambda_{9G} & 0 & 0 & \lambda_{93} \end{bmatrix} \begin{bmatrix} G \\ S_1 \\ S_2 \\ S_3 \end{bmatrix} + \begin{bmatrix} e_1 \\ e_2 \\ e_3 \\ e_4 \\ e_5 \\ e_6 \\ e_7 \\ e_8 \\ e_9 \end{bmatrix}$$



โมเดลองค์ประกอบสองด้าน

- การระบุโมเดลองค์ประกอบสองด้านและระบุสเกลองค์ประกอบใช้แนวทางเดียวกับ CFA เลย
- ส่วนการทดสอบความเหมาะสมของโมเดลองค์ประกอบสองด้าน ให้ใช้ดัชนีความเหมาะสมแบบปกติ แต่ DFI ยังไม่สนับสนุนการทดสอบโมเดลองค์ประกอบสองด้าน
- การเปรียบเทียบโมเดลองค์ประกอบสองด้านกับโมเดลอื่น
 - เปรียบเทียบกับกับ โมเดลองค์ประกอบแบบลำดับชั้น (Hierarchical Factor Model) ด้วย Nested Model Comparison ได้ เพราะ Bifactor Model เป็นโมเดลตั้งต้น
 - หากต้องการเปรียบเทียบระหว่าง CFA ปกติ (ที่มี S_1, S_2, \dots, S_k ที่สัมพันธ์กัน) และโมเดลองค์ประกอบสองด้าน จะไม่ใช่โมเดลที่ซ้อนกันกับ CFA ต้องใช้ Nonnested Model Comparison

โมเดลองค์ประกอบสองด้าน

- โมเดลองค์ประกอบแบบลำดับชั้นจะบอกว่า อิทธิพลของ General Factor ที่ส่งไปสู่ตัวบ่งชี้ต่างๆ ถูก Fully Mediated โดย Specific Factor แต่ละตัว
 - ถ้าเลือกโมเดลองค์ประกอบแบบลำดับชั้น แสดงว่าองค์ประกอบรวม ส่งผลต่อองค์ประกอบย่อย แล้วค่อยส่งผลต่อตัวบ่งชี้เท่านั้น
 - แต่ถ้าปฏิเสธโมเดลองค์ประกอบแบบลำดับชั้น แสดงว่าองค์ประกอบรวมมีผลต่อตัวบ่งชี้โดยตรง ไม่จำเป็นต้องผ่านองค์ประกอบย่อย
 - แสดงว่าโมเดลแบบสองด้าน องค์ประกอบย่อยจะเกี่ยวข้อง เป็นภาวะสันนิษฐานเนื้อเดียวกับองค์ประกอบรวม (เช่น ด้านต่างๆ ของความพึงพอใจในชีวิต) หรือไม่เกี่ยวข้องใดๆ เลย (เช่น วิธีการวัด เครื่องมือ ฯลฯ) ก็ได้
- โมเดลองค์ประกอบสองด้านสามารถหาความเที่ยงของคะแนนรวมตัวบ่งชี้ภายในองค์ประกอบย่อย และคะแนนรวมทั้งมาตรได้เหมือนกัน เพื่อแทนค่าองค์ประกอบย่อยและองค์ประกอบรวม

$$\hat{S}_{1i} = X_{i1} + X_{i2} + X_{i3} \quad X_{ij} = \mu_j + \lambda_{jG}G_i + \lambda_{jk}S_{ki} + e_{ij}$$

$$\hat{S}_{1i} = \mu_1 + \lambda_{1G}G_i + \lambda_{11}S_{1i} + e_{i1} + \mu_2 + \lambda_{2G}G_i + \lambda_{21}S_{1i} + e_{i2} + \mu_3 + \lambda_{3G}G_i + \lambda_{31}d_{1i} + e_{i3}$$

$$\hat{S}_{1i} = \sum_{j=1}^3 \mu_j + G_i \sum_{j=1}^3 \lambda_{jG} + S_{1i} \sum_{j=1}^3 \lambda_{j1} + \sum_{j=1}^3 e_{ij}$$

$$\text{Var}(\hat{S}_{1i}) = \text{Var}\left(\sum_{j=1}^3 \mu_j + G_i \sum_{j=1}^3 \lambda_{jG} + S_{1i} \sum_{j=1}^3 \lambda_{j1} + \sum_{j=1}^3 e_{ij}\right) = \text{Var}\left(G_i \sum_{j=1}^3 \lambda_{jG} + S_{1i} \sum_{j=1}^3 \lambda_{j1} + \sum_{j=1}^3 e_{ij}\right)$$

$$\text{Var}(\hat{S}_{1i}) = \left(\sum_{j=1}^3 \lambda_{jG}\right)^2 \text{Var}(G_i) + \left(\sum_{j=1}^3 \lambda_{j1}\right)^2 \text{Var}(S_{1i}) + \sum_{j=1}^3 \text{Var}(e_{ij})$$

$$\text{Var}(\hat{S}_{1i}) = \psi_{GG} \left(\sum_{j=1}^3 \lambda_{jG}\right)^2 + \psi_{11} \left(\sum_{j=1}^3 \lambda_{j1}\right)^2 + \sum_{j=1}^3 \theta_{jj}$$

โมเดลองค์ประกอบสองด้าน

- ค่าสัมประสิทธิ์โอเมก้า คือ สัดส่วนของความแปรปรวนองค์ประกอบทั้งหมดต่อความแปรปรวนของคะแนนรวม คือ

$$\omega_{S_1} = \frac{\psi_{GG}(\sum_{j=1}^3 \lambda_{jG})^2 + \psi_{11}(\sum_{j=1}^3 \lambda_{j1})^2}{\text{Var}(X_1 + X_2 + X_3)}$$

- ถ้านักวิเคราะห์ต้องการเอาคะแนนองค์ประกอบย่อย ไปอ้างอิงถึงคะแนนองค์ประกอบรวม ให้ใช้ค่าสัมประสิทธิ์โอเมก้าแบบลำดับชั้น (Hierarchical Omega) ได้ผลดังนี้ (Rodriguez et al., 2015)

$$\omega_{H(S_1)} = \frac{\psi_{GG}(\sum_{j=1}^3 \lambda_{jG})^2}{\text{Var}(X_1 + X_2 + X_3)}$$

โมเดลองค์ประกอบสองด้าน

- ถ้าเทียบระหว่างคนที่คะแนนองค์ประกอบรวมเท่ากัน (ควบคุมอิทธิพลของคะแนนรวม) ผลรวมคะแนนสามข้อนี้จะบ่งชี้ขนาดคะแนนองค์ประกอบย่อยได้มากน้อยเพียงใด ค่านี้เรียกว่าสัมประสิทธิ์โอเมก้าลำดับชั้นสำหรับองค์ประกอบย่อย (Omega Hierarchical Subscale) มีค่าดังนี้

$$\omega_{HS(S_1)} = \frac{\psi_{11}(\sum_{j=1}^3 \lambda_{j1})^2}{\text{Var}(X_1 + X_2 + X_3)}$$

$$\hat{H}_i = \sum_{j=1}^9 X_{ij} \quad X_{ij} = \mu_j + \lambda_{jG} G_i + \lambda_{jk} S_{ki} + e_{ij}$$

$$\hat{H}_{1i} = \sum_{j=1}^9 \mu_j + G_i \sum_{j=1}^3 \lambda_{jG} + S_{1i} \sum_{j=1}^3 \lambda_{j1} + G_i \sum_{j=4}^6 \lambda_{jG} + S_{2i} \sum_{j=4}^6 \lambda_{j2} + G_i \sum_{j=7}^9 \lambda_{jG} + S_{3i} \sum_{j=7}^9 \lambda_{j3} + \sum_{j=1}^9 e_{ij}$$

$$\hat{H}_{1i} = \sum_{j=1}^9 \mu_j + G_i \left(\sum_{j=1}^3 \lambda_{jG} + \sum_{j=4}^6 \lambda_{jG} + \sum_{j=7}^9 \lambda_{jG} \right) + S_{1i} \sum_{j=1}^3 \lambda_{j1} + S_{2i} \sum_{j=4}^6 \lambda_{j2} + S_{3i} \sum_{j=7}^9 \lambda_{j3} + \sum_{j=1}^9 e_{ij}$$

$$\text{Var}(\hat{H}_{1i}) = \psi_{GG} \left(\sum_{j=1}^9 \lambda_{jG} \right)^2 + \psi_{11} \left(\sum_{j=1}^3 \lambda_{j1} \right)^2 + \psi_{22} \left(\sum_{j=4}^6 \lambda_{j2} \right)^2 + \psi_{33} \left(\sum_{j=7}^9 \lambda_{j3} \right)^2 + \sum_{j=1}^9 \theta_{jj}$$

โมเดลองค์ประกอบสองด้าน

- ค่าสัมประสิทธิ์โอเมก้าของคะแนนรวมทั้งมาตร คือ สัดส่วนของความแปรปรวนขององค์ประกอบทั้งหมด (ทั้งอันดับที่หนึ่งและอันดับที่สอง) ต่อความแปรปรวนของคะแนนรวม คือ

$$\omega = \frac{\psi_{GG}(\sum_{j=1}^9 \lambda_{jG})^2 + \psi_{11}(\sum_{j=1}^3 \lambda_{j1})^2 + \psi_{22}(\sum_{j=4}^6 \lambda_{j2})^2 + \psi_{33}(\sum_{j=7}^9 \lambda_{j3})^2}{Var(\sum X_j)}$$

- อย่างไรก็ตาม นักวิเคราะห์มักต้องการนำคะแนนรวมทั้งมาตรไปอ้างอิงองค์ประกอบอันดับที่สองอยู่แล้ว ในที่นี้ ค่าสัมประสิทธิ์โอเมก้าแบบลำดับชั้น (Hierarchical Omega) จะมีประโยชน์กว่า

$$\omega_H = \frac{\psi_{GG}(\sum_{j=1}^9 \lambda_{jG})^2}{Var(\sum X_j)}$$

- รากที่ 2 ของค่าสัมประสิทธิ์โอเมก้าแบบลำดับชั้น จะเท่ากับค่าสหสัมพันธ์ระหว่างคะแนนรวมและองค์ประกอบอันดับที่สอง

```

> mconb <- '
+ achi =~ c1 + c7 + c13 + c19 + c25 + c31 + c37 + c43 + c49 + c55
+ caut =~ c2 + c8 + c14 + c20 + c26 + c32 + c38 + c44 + c50 + c56
+ duti =~ c3 + c9 + c15 + c21 + c27 + c33 + c39 + c45 + c51 + c57
+ orde =~ c4 + c10 + c16 + c22 + c28 + c34 + c40 + c46 + c52 + c58
+ disc =~ c5 + c11 + c17 + c23 + c29 + c35 + c41 + c47 + c53 + c59
+ effi =~ c6 + c12 + c18 + c24 + c30 + c36 + c42 + c48 + c54 + c60
+ con =~ c1 + c7 + c13 + c19 + c25 + c31 + c37 + c43 + c49 + c55
+ + c2 + c8 + c14 + c20 + c26 + c32 + c38 + c44 + c50 + c56
+ + c3 + c9 + c15 + c21 + c27 + c33 + c39 + c45 + c51 + c57
+ + c4 + c10 + c16 + c22 + c28 + c34 + c40 + c46 + c52 + c58
+ + c5 + c11 + c17 + c23 + c29 + c35 + c41 + c47 + c53 + c59
+ + c6 + c12 + c18 + c24 + c30 + c36 + c42 + c48 + c54 + c60
+ con ~~ 0*achi + 0*caut + 0*duti + 0*orde + 0*disc + 0*effi
+ achi ~~ 0*caut + 0*duti + 0*orde + 0*disc + 0*effi
+ caut ~~ 0*duti + 0*orde + 0*disc + 0*effi
+ duti ~~ 0*orde + 0*disc + 0*effi
+ orde ~~ 0*disc + 0*effi
+ disc ~~ 0*effi
+ '

```

บังคับให้องค์ประกอบทั้งหมดไม่สัมพันธ์กัน

```

> outconb <- cfa(mconb, data=datcon, std.lv=TRUE) ใช้ Fixed Factor

```

```

> summary(outconb, fit=TRUE, std=TRUE) เพราะ Marker ประมาณค่าไม่ได้
lavaan 0.6-12 ended normally after 34 iterations

```

Estimator	ML
Optimization method	NLMINB
Number of model parameters	180
Number of observations	475
Model Test User Model:	
Test statistic	4173.239
Degrees of freedom	1650
P-value (Chi-square)	0.000

User Model versus Baseline Model:

Comparative Fit Index (CFI)	0.726
Tucker-Lewis Index (TLI)	0.706

Loglikelihood and Information Criteria:

Loglikelihood user model (H0)	-32372.530
Loglikelihood unrestricted model (H1)	-30285.910

Akaike (AIC)	65105.060
Bayesian (BIC)	65854.456
Sample-size adjusted Bayesian (BIC)	65283.163

Root Mean Square Error of Approximation:

RMSEA	0.057
90 Percent confidence interval - lower	0.055
90 Percent confidence interval - upper	0.059
P-value RMSEA <= 0.05	0.000

Standardized Root Mean Square Residual:

SRMR	0.076
------	-------

ค่าดัชนีความเหมาะสมดีกว่าโมเดล CFA แบบปกติด้วยซ้ำ แต่ค่าดัชนีความเหมาะสมอาจยังไม่เพียงพอที่จะยอมรับโมเดล องค์ประกอบสองด้าน แต่ใช้ผลนี้เป็นตัวอย่างไปก่อน

$$\chi^2(1650, N = 475) = 4173.24, p < .001, CFI = .726, TLI = .706, RMSEA = .057, SRMR = .076$$

con	=~						
c1	0.432	0.031	13.916	0.000	0.432	0.599	
c7	0.401	0.029	13.794	0.000	0.401	0.594	
c13	0.342	0.028	12.048	0.000	0.342	0.531	
c19	0.270	0.047	5.740	0.000	0.270	0.271	
c25	-0.005	0.048	-0.114	0.910	-0.005	-0.005	
c31	0.456	0.033	13.881	0.000	0.456	0.597	
c37	0.248	0.036	6.867	0.000	0.248	0.319	
c43	0.233	0.041	5.724	0.000	0.233	0.268	
c49	0.454	0.042	10.838	0.000	0.454	0.485	
c55	0.462	0.048	9.698	0.000	0.462	0.439	
c2	0.332	0.035	9.536	0.000	0.332	0.432	
c8	0.174	0.037	4.716	0.000	0.174	0.222	
c14	0.253	0.037	6.762	0.000	0.253	0.314	
c20	0.111	0.046	2.402	0.016	0.111	0.114	
c26	0.393	0.043	9.208	0.000	0.393	0.419	
c32	0.065	0.041	1.582	0.114	0.065	0.076	
c38	0.163	0.042	3.855	0.000	0.163	0.183	
c44	-0.114	0.042	-2.719	0.007	-0.114	-0.129	
c50	0.446	0.046	9.764	0.000	0.446	0.442	
c56	0.253	0.050	5.106	0.000	0.253	0.240	
c3	0.298	0.035	8.584	0.000	0.298	0.393	
c9	0.333	0.036	9.357	0.000	0.333	0.425	
c15	0.244	0.038	6.359	0.000	0.244	0.297	
c21	0.288	0.034	8.538	0.000	0.288	0.391	
c27	0.269	0.034	8.029	0.000	0.269	0.370	
c33	0.266	0.044	6.025	0.000	0.266	0.282	
c39	0.354	0.041	8.614	0.000	0.354	0.394	
c45	0.315	0.035	8.953	0.000	0.315	0.409	

ข้อเหล่านี้ควรนำไปพิจารณาว่าเกิดอะไรขึ้น
 ทำไป Standardized Loadings
 ต่ำใกล้ 0 หรือติดลบ

ส่วน Standardized Loadings
 ขององค์ประกอบจำเพาะ นักวิเคราะห์อาจจะ
 ไม่สนใจ หรือสนใจก็ได้ ขึ้นอยู่ว่าจะแปล
 ความหมายขององค์ประกอบจำเพาะหรือไม่

```
> vuongtest(outcon, outconb)
```

```
Model 1  
Class: lavaan  
Call: lavaan::lavaan(model = mcon, data = datcon, mod
```

```
Model 2  
Class: lavaan  
Call: lavaan::lavaan(model = mconb, data = datcon, st
```

```
Variance test  
H0: Model 1 and Model 2 are indistinguishable  
H1: Model 1 and Model 2 are distinguishable  
w2 = 4.921, p = <2e-16
```

```
Non-nested likelihood ratio test  
H0: Model fits are equal for the focal population  
H1A: Model 1 fits better than Model 2  
z = -9.384, p = 1  
H1B: Model 2 fits better than Model 1  
z = -9.384, p = < 2.2e-16
```

```
> vuongtest(outconb, outconh, nested=TRUE)
```

```
Model 1  
Class: lavaan  
Call: lavaan::lavaan(model = mconb, data = datcon, std.1
```

```
Model 2  
Class: lavaan  
Call: lavaan::lavaan(model = mconh, data = datcon, model
```

```
Variance test  
H0: Model 1 and Model 2 are indistinguishable  
H1: Model 1 and Model 2 are distinguishable  
w2 = 4.773, p = 2.78e-08
```

```
Robust likelihood ratio test of distinguishable models  
H0: Model 2 fits as well as Model 1  
H1: Model 1 fits better than Model 2  
LR = 1002.752, p = <2e-16
```

โมเดลองค์ประกอบสองด้านดีกว่าโมเดล **CFA** ปกติ
อย่างมีนัยสำคัญ

โมเดลองค์ประกอบสองด้านแตกต่างจากโมเดล
องค์ประกอบสองชั้นอย่างมีนัยสำคัญ จึงเลือกโมเดล
องค์ประกอบสองด้าน

```
> compReISEM(outcomb)
```

```
  achi  caut  duti  orde  disc  effi   con  
0.183 0.491 0.314 0.385 0.200 0.073 0.816
```

สูตรโอเมก้าลำดับชั้นสำหรับองค์ประกอบย่อย
(ผลรวมจะเฉพาะข้อที่อยู่ในแต่ละองค์ประกอบย่อย)

สังเกตที่สีของตัวอักษร ว่าตรงกับสูตรไหนในสไลด์ที่ผ่านมา

สูตรโอเมก้าลำดับชั้นของผลรวมคะแนนทุกข้อ

ตัวบ่งชี้แบบจัดอันดับ

- ใน CFA หรือ SEM ที่ผ่านมาทั้งหมด จะกำหนดให้ตัวบ่งชี้เป็นตัวแปรต่อเนื่อง แต่มาตรวัดทางจิตวิทยาส่วนใหญ่ จะเป็นมาตรที่แบ่งเป็นกลุ่มๆ เช่น มาตรวัดแบบลิเคิร์ต (Likert) หรือมาตรวัดแบบใช่/ไม่ใช่ (Binary variables)
- แม้จะสามารถเอา CFA สำหรับตัวแปรต่อเนื่องมาวิเคราะห์ตัวบ่งชี้แบบจัดอันดับได้ แต่ค่าพารามิเตอร์จะมีค่าน้อยกว่าความเป็นจริง ส่งผลให้ค่าน้ำหนักองค์ประกอบมาตรฐานต่ำ ทำให้ดูเหมือนมาตรไม่มีคุณภาพ
- โมเดลที่เหมาะสมกับตัวบ่งชี้แบบจัดกลุ่มแบบเรียงลำดับ (Ordered Categorical Variables) นั้น จะต้องสร้างสมการที่เหมาะสมสำหรับความสัมพันธ์ระหว่างองค์ประกอบที่เป็นตัวแปรต่อเนื่อง และตัวบ่งชี้ที่เป็นตัวแปรแบบจัดกลุ่มเรียงลำดับ

ตัวบ่งชี้แบบจัดอันดับ

- ให้ x_j เป็นตัวแปรแบบจัดอันดับ ซึ่งมีค่าได้ตั้งแต่ $c = 0, 1, \dots, C - 1$ โดย C คือจำนวนกลุ่ม
 - หากเป็นมาตรแบบทวินาม (Binary Variables) $C = 2$ และ $c = 0, 1$
 - หากเป็นมาตรแบบลิเคิร์ต 5 ระดับ $C = 5$ และ $c = 0, 1, 2, 3, 4$
- มาตรจัดอันดับเหล่านี้ จะมีความสัมพันธ์กับองค์ประกอบผ่านจุดเปลี่ยน (Thresholds) เช่น ถ้าองค์ประกอบความรับผิดชอบ (F) อยู่ในระดับต่ำมากๆ จะตอบข้อคำถามทวินามที่ว่า “ฉันเป็นคนรับผิดชอบ” ว่า “ไม่ใช่” หากองค์ประกอบความรับผิดชอบ (F) มีค่ามากขึ้นเรื่อยๆ จนเกินระดับจุดเปลี่ยน จะตอบคำถามทวินามดังกล่าวว่า “ใช่”
 - เช่น ให้ตัวบ่งชี้มีน้ำหนักองค์ประกอบมาตรฐานเท่ากับ 0.8, $F \sim N(0, 1)$, $e \sim N(0, 0.6)$ ถ้าตัวบ่งชี้เป็นตัวแปรต่อเนื่อง (ให้สัญลักษณ์แทนเป็น y^*) สมการที่อธิบายอิทธิพลขององค์ประกอบไปหา y^* เป็นดังนี้

$$y^* = 0.8F + e$$

$$y^* = 0.8F + e$$

คุณมีความรับผิดชอบ
(ไม่ใช้ / ใช้)

จุดเปลี่ยน = 0.25

```
> set.seed(123321)
> f <- rnorm(10, 0, 1)
> e <- rnorm(10, 0, 0.6)
> ystar <- 0.8*f + e
> ycut <- cut(ystar, c(-Inf, 0.25, Inf))
> y <- as.numeric(ycut) - 1
> data.frame(f, e, ystar, ycut, y)
```

	f	e	ystar	ycut	y
1	0.7964754	1.24489371	1.882074039	(0.25, Inf]	1
2	0.9673793	-0.96534738	-0.191443928	(-Inf, 0.25]	0
3	0.5404655	-0.42555126	0.006821144	(-Inf, 0.25]	0
4	1.2876865	-0.76640969	0.263739523	(0.25, Inf]	1
5	-1.2772009	-0.04408187	-1.065842624	(-Inf, 0.25]	0
6	0.3688038	0.62856449	0.923607537	(0.25, Inf]	1
7	0.1279525	0.15187945	0.254241457	(0.25, Inf]	1
8	0.3892638	0.90361548	1.215026503	(0.25, Inf]	1
9	-0.5727820	0.24722949	-0.210996113	(-Inf, 0.25]	0
10	-0.4322062	-0.12711528	-0.472880265	(-Inf, 0.25]	0

คุณมีความรับผิดชอบ

(ไม่เห็นด้วยอย่างยิ่ง / ไม่เห็นด้วย / เห็นด้วย / เห็นด้วยอย่างยิ่ง)

จุดเปลี่ยน = -1.25, -0.15, 0.90


```
> set.seed(113113)
> f <- rnorm(10, 0, 1)
> e <- rnorm(10, 0, 0.6)
> ystar <- 0.8*f + e
> ycut <- cut(ystar, c(-Inf, -1.25, -0.15, 0.90, Inf))
> y <- as.numeric(ycut) - 1
> data.frame(f, e, ystar, ycut, y)
```

	f	e	ystar	ycut	y
1	0.6971884	-0.24077974	0.31697100	(-0.15, 0.9]	2
2	-0.2086236	1.04486490	0.87796602	(-0.15, 0.9]	2
3	0.7894843	0.40425715	1.03584460	(0.9, Inf]	3
4	-0.9645252	-1.50746738	-2.27908750	(-Inf, -1.25]	0
5	-1.7787699	-0.76340560	-2.18642148	(-Inf, -1.25]	0
6	-0.1376532	-0.33488174	-0.44500431	(-1.25, -0.15]	1
7	1.2409768	-0.45733803	0.53544342	(-0.15, 0.9]	2
8	-0.3898191	0.31775020	0.00589495	(-0.15, 0.9]	2
9	0.9007824	-0.07124724	0.64937870	(-0.15, 0.9]	2
10	0.1700058	0.64739970	0.78340437	(-0.15, 0.9]	2

$$y^* = 0.8F + e$$


คุณมีความรับผิดชอบ
(ไม่ใช้ / ใช้)

จุดเปลี่ยน = 0.25



คุณมีความรับผิดชอบ
(ไม่เห็นด้วยอย่างยิ่ง / ไม่เห็นด้วย / เห็นด้วย / เห็นด้วยอย่างยิ่ง)

จุดเปลี่ยน = -1.25, -0.15, 0.90




$$y^* = 0.8F + e$$

e จะเป็นส่วนค่าคงเหลือที่ทำให้ค่า F หนึ่งบางครั้งอาจเกินจุดเปลี่ยนหรือบางครั้งอาจต่ำกว่าจุดเปลี่ยน
หาโอกาสที่จะออกค่า c แต่ละค่า ในแต่ละระดับของ F

คุณมีความรับผิดชอบ
(ไม่ใช่/ใช่)


จุดเปลี่ยน = 0.25



คุณมีความรับผิดชอบ

(ไม่เห็นด้วยอย่างยิ่ง/ ไม่เห็นด้วย/ เห็นด้วย/ เห็นด้วยอย่างยิ่ง)

จุดเปลี่ยน = -1.25, -0.15, 0.90



ตัวบ่งชี้แบบจัดอันดับ

- ให้ y^* เป็นตัวแปรแฝงที่อยู่ใต้ตัวบ่งชี้แบบจัดกลุ่ม y ที่มีจำนวนกลุ่ม C กลุ่ม มีค่า $c = 0, 1, \dots, C - 1$ แล้ว โมเดล CFA สำหรับตัวบ่งชี้แบบจัดกลุ่มแบบจัดอันดับจะเป็นดังนี้

$$y^* = \Lambda f + e$$

$$f \sim \text{MVN}(0, \Psi)$$

$$e \sim \text{MVN}(0, \Theta)$$

$$y_j = c \quad \text{if} \quad \tau_{j,c-1} < y_j^* < \tau_{j,c}$$

$$\text{Var}(y_j^*) = 1$$

$$\tau_0 = -\infty$$

$$\tau_C = \infty$$

- สเกลขององค์ประกอบ สามารถกำหนดได้ทั้ง Fixed Factor Approach หรือ Marker Variable Approach
- สเกลของ y^* กำหนดโดยให้ $\text{Var}(y_j^*) = 1$ ทำให้ไม่ได้ประมาณค่า $\text{Var}(e_j)$ หรือ θ_{jj}
- ค่าเฉลี่ยขององค์ประกอบ กำหนดให้เป็น 0 และจุดตัด (Intercept; ν_j) ของ y_j^* กำหนดให้เป็น 0

ตัวบ่งชี้แบบจัดอันดับ

- ให้ y^* เป็นตัวแปรแฝงที่อยู่ใต้ตัวบ่งชี้แบบจัดกลุ่ม y ที่มีจำนวนกลุ่ม C กลุ่ม มีค่า $c = 0, 1, \dots, C - 1$ แล้ว โมเดล CFA สำหรับตัวบ่งชี้แบบจัดกลุ่มแบบจัดอันดับจะเป็นดังนี้

$$y^* = \Lambda f + e$$

$$f \sim \text{MVN}(0, \Psi)$$

$$e \sim \text{MVN}(0, \Theta)$$

$$y_j = c \quad \text{if} \quad \tau_{j,c-1} < y_j^* < \tau_{j,c}$$

$$\text{Var}(y_j^*) = 1$$

$$\tau_0 = -\infty$$

$$\tau_C = \infty$$

- ส่วนโมเดลค่าเฉลี่ยจะถูกผลักดันให้ไปอยู่ในจุดเปลี่ยนทั้งหมด เนื่องจากค่าเฉลี่ยขององค์ประกอบกำหนดให้เป็น 0 และจุดตัด (Intercept; ν_j) ของ y_j^* กำหนดให้เป็น 0 เช่นกัน
- การกำหนดค่าคงที่ในโมเดลแบบนี้ เรียกว่า การกำหนดพารามิเตอร์แบบเดลต้า (Delta Parameterization)

ตัวบ่งชี้แบบจัดอันดับ

- กำหนดพารามิเตอร์อีกแบบหนึ่ง จะให้ $Var(e_j) = \theta_{jj} = 1$ โดยไม่กำหนด $Var(y_j^*)$ การกำหนดพารามิเตอร์แบบนี้เรียกว่า การกำหนดพารามิเตอร์แบบเทต้า (Theta Parameterization)

$$\mathbf{y}^* = \mathbf{\Lambda} \mathbf{f} + \mathbf{e}$$

$$\mathbf{f} \sim \text{MVN}(0, \mathbf{\Psi})$$

$$\mathbf{e} \sim \text{MVN}(0, \mathbf{\Theta})$$

$$y_j = c \quad \text{if} \quad \tau_{j,c-1} < y_j^* < \tau_{j,c}$$

$$\theta_{jj} = 1$$

$$\tau_0 = -\infty$$

$$\tau_C = \infty$$

- Theta Parameterization จะใช้ในตอนเปรียบเทียบความคงทนของคุณสมบัติการวัด (Measurement Invariance) ระหว่างกลุ่ม เวลา ฯลฯ เนื่องจากใน Metric Invariance ต้องกำหนดให้น้ำหนักองค์ประกอบเท่ากัน แต่ต้องยอมรับว่าขนาดความแปรปรวนของค่าคงเหลือของทั้งสองกลุ่มแตกต่างกัน จึงต้องกำหนดให้ $\theta_{jj} = 1$ ในกลุ่มหนึ่ง และประมาณค่าอย่างอิสระในอีกกลุ่มหนึ่ง
- ค่าปกติจะเป็น delta parameterization เพราะเข้าใจง่ายกว่าเยอะ

ตัวบ่งชี้แบบจัดอันดับ

- สมมติว่าโครงสร้างองค์ประกอบเป็นแบบง่ายมาก (Very Simple Structure) ใช้ Fixed Factor Approach และ Delta Parameterization จำนวนพารามิเตอร์จะเป็นดังนี้
 - ความสัมพันธ์ระหว่างองค์ประกอบ (กรณีมากกว่า 1 องค์ประกอบ) : $k(k - 1)/2$
 - น้ำหนักองค์ประกอบ เท่ากับจำนวนตัวบ่งชี้ : J
 - จำนวนจุดเปลี่ยน : $\sum_{j=1}^J C_j - 1$
- จำนวนข้อมูลเท่ากับจำนวนสหสัมพันธ์ที่เป็นไปได้ระหว่างตัวบ่งชี้ : $J(J - 1)/2$ รวมกับจำนวนจุดเปลี่ยนรวมจากแต่ละข้อ $\sum_{j=1}^J C_j - 1$
- $df =$ จำนวนข้อมูล - จำนวนพารามิเตอร์

ตัวบ่งชี้แบบจัดอันดับ

- การประมาณค่าจะไม่สามารถประมาณค่าผ่าน Maximum Likelihood ได้แล้ว เนื่องจากการกระจายของตัวบ่งชี้ไม่ได้เป็นตัวแปรต่อเนื่องที่มีการกระจายเป็น Multivariate Normal Distribution
- วิธีการประมาณค่าพารามิเตอร์ที่ไม่สนใจการกระจายของตัวบ่งชี้ที่เหมาะสมในกรณีนี้ คือ การทำให้ผลต่างกำลังสองต่ำสุดแบบถ่วงน้ำหนัก (Weighted Least Square; WLS)
- ให้ \mathbf{v} และ \mathbf{w} เป็นเวกเตอร์ที่มีสมาชิกเป็นจุดเปลี่ยนและสหสัมพันธ์ระหว่าง \mathbf{y}^* ของกลุ่มตัวอย่าง (Saturated Model) และสร้างจากโมเดล (Model-implied) แล้ว ค่า Discrepancy Function สามารถนิยามได้ดังนี้

$$F_{WLS}(\boldsymbol{\theta}) = (\mathbf{v} - \mathbf{w})' \mathbf{W}^{-1} (\mathbf{v} - \mathbf{w})$$

- โดย \mathbf{W} เป็นเมทริกซ์ความแปรปรวนร่วมของ Sampling Distribution ของ \mathbf{v} โดยรากที่สองของสมาชิกแนวทแยงมุมของ \mathbf{W} คือ ค่าความผิดพลาดมาตรฐาน (Standard Errors) ของจุดเปลี่ยนและสหสัมพันธ์ระหว่างตัวบ่งชี้

ตัวบ่งชี้แบบจัดอันดับ

- หากมีกลุ่มตัวอย่างเยอะมากๆ WLS จะสามารถประมาณค่าพารามิเตอร์ได้ถูกต้อง
- อย่างไรก็ตาม WLS ในกลุ่มตัวอย่างขนาดเล็กจะไม่เหมาะสม สมมติว่ามีตัวบ่งชี้ทั้งหมด 10 ตัว จะมีจุดเปลี่ยน 10 ตัว ความแปรปรวนร่วม 45 ตัว \mathbf{W} จะมีขนาด 55×55 ซึ่งการหา Inverse ของเมทริกซ์ขนาด 55×55 เป็นเรื่องที่เปลืองทรัพยากรในการคำนวณมาก ค่าที่ได้มีโอกาสที่ไม่เสถียรถ้ากลุ่มตัวอย่างน้อย
- Muthén (1984) จึงเสนอให้ใช้เฉพาะสมาชิกแนวทแยงมุมของ \mathbf{W} มาใช้ในการประมาณค่าพารามิเตอร์ เรียกว่า Diagonally Weighted Least Square (DWLS) ซึ่งจะลดจำนวนสมาชิกให้น้อยลงมาก การหา Matrix Inverse ก็ง่ายมากโดยการกลับเศษเป็นส่วนเท่านั้น
- ค่า Chi-square จะสามารถคำนวณได้ดังนี้

$$\chi^2 = N \cdot F_{WLS}(\boldsymbol{\theta})$$

ตัวบ่งชี้แบบจัดอันดับ

- เมื่อการกระจายของตัวบ่งชี้ไม่ได้เป็น MVN และกลุ่มตัวอย่างขนาดเล็ก ค่า Chi-square เมื่อ Null Hypothesis เป็นจริงจะไม่ได้มีการกระจายเป็น Chi-square นักวิจัยจึงเสนอค่า Scaled Chi-square เพื่อปรับค่าของ Chi-square ให้มีการกระจายเป็น Chi-square Distribution มากขึ้น เมื่อตัวบ่งชี้ไม่ได้เป็น MVN (Savalei & Rosseel, 2022)
 - Satorra & Bentler (1995) เสนอสูตร Scaled Chi-square ปรับให้ค่าเฉลี่ยเท่ากับ df
 - Asparouhov & Muthén (2010) เสนอสูตร Scaled Chi-square ปรับให้ค่าเฉลี่ยเท่ากับ df และความแปรปรวนเท่ากับ $2df$ ตาม Chi-square distribution ด้วย
- ค่าปกติของ lavaan จะใช้ DWLS และ Scaled Chi-square ตามสูตรของ Asparouhov & Muthén (2010) ซึ่งตรงกับการกำหนด ESTIMATOR = WLSMV ใน Mplus ซึ่งเป็นวิธีที่ได้รับความนิยมในปัจจุบัน

ตัวบ่งชี้แบบจัดอันดับ

- อย่างไรก็ตาม DWLS จะไม่สามารถจัดการค่าสูญหายได้ ไม่เหมือนกับ ML ที่สามารถปรับสูตรให้สนใจเฉพาะค่าที่ไม่สูญหายในแต่ละ Case ได้ ดังนั้นการแทนค่าสูญหายสำหรับ Categorical CFA จึงควรใช้แบบ Listwise หรือ Multiple Imputation (ซึ่งดีกว่า) เท่านั้น
- บางครั้ง WLS จะเรียกว่า Asymptotic Distribution Free (ADF) เพราะไม่สนใจการกระจายของตัวบ่งชี้เลย แต่ต้องใช้กลุ่มตัวอย่างจำนวนมาก ($N > 5000$) ถึงจะได้การประมาณค่าพารามิเตอร์ที่ถูกต้อง และ SE ที่ถูกต้อง (จึงเป็นสาเหตุที่ Muthén เสนอ DWLS)
- ULS เป็นอีกหนึ่งทางเลือกในการประมาณค่าพารามิเตอร์ ที่ $\mathbf{W} = \mathbf{I}$ แต่ไม่ค่อยได้รับความนิยม
- ดูรายละเอียดเพิ่มเติมได้ที่ [rosseel_sem_cat.pdf](https://personality-project.org/rosseel_sem_cat.pdf) (personality-project.org)

```
> head(datdicho)
  y1 y2 y3 y4 y5 y6 y7 y8
1  1  2  2  2  2  1  1  1
2  2  1  2  2  2  1  1  1
3  2  1  1  2  2  1  1  2
4  2  2  2  2  2  1  1  1
5  1  1  2  2  2  2  2  2
6  1  2  2  1  1  1  1  1
```

ตัวแปรเป็นแบบทวินาม มี 2 ค่า
(1 = ไม่ใช่, 2 = ใช่)

```
> mdicho <- '
+ f1 =~ y1 + y2 + y3 + y4
+ f2 =~ y5 + y6 + y7 + y8
+'
> outdicho <- cfa(mdicho, data=datdicho, ordered=TRUE)
> summary(outdicho, std=TRUE, fit=TRUE)
lavaan 0.6-12 ended normally after 29 iterations
```


กำหนดว่าเป็นตัวบ่งชี้แบบจัดอันดับ

พารามิเตอร์:

ความแปรปรวนร่วม 1 ตัว,
น้ำหนักองค์ประกอบ 8 ตัว,
จุดเปลี่ยน 8 ตัว
รวม 17 ตัว

	DWLS	
Estimator		
Optimization method	NLMINB	
Number of model parameters	17	
Number of observations	200	
Model Test User Model:		
Test Statistic	Standard	Robust
Degrees of freedom	24.102	27.909
P-value (Chi-square)	19	19
Scaling correction factor	0.192	0.085
Shift parameter		0.961
simple second-order correction		2.835

$$\chi^2(19, N = 200) = 27.91, p = .085$$



ดู Scaled
Chi-square

ข้อมูล: สหสัมพันธ์ $(8)(7)/2 = 28$, จุดเปลี่ยน 8 ตัว รวม 36 ตัว

$$df = 36 - 17 = 19$$

User Model versus Baseline Model:

Comparative Fit Index (CFI)	0.985	0.967
Tucker-Lewis Index (TLI)	0.977	0.951

Robust Comparative Fit Index (CFI)		NA
Robust Tucker-Lewis Index (TLI)		NA

Root Mean Square Error of Approximation:

RMSEA	0.037	0.049
90 Percent confidence interval - lower	0.000	0.000
90 Percent confidence interval - upper	0.076	0.085
P-value RMSEA \leq 0.05	0.665	0.487

Robust RMSEA		NA
90 Percent confidence interval - lower		0.000
90 Percent confidence interval - upper		NA

Standardized Root Mean Square Residual:

SRMR	0.109	0.109
------	-------	-------

แม้ว่าดัชนีความเหมาะสมจะเหมือนกับกรณีตัวแปรต่อเนื่อง แต่จุดตัดที่หามาจากตัวแปรต่อเนื่องไม่เหมาะสมกับตัวแปรจัดกลุ่มแบบจัดอันดับ (Nye & Drasgow, 2010)

อย่างไรก็ตาม คนก็ใช้จุดตัดจากตัวแปรต่อเนื่องอยู่ดี

ดังนั้น **DFI** น่าจะเหมาะสมในกรณีนี้มากที่สุด แต่ฟังก์ชัน **cfaHB** ในปัจจุบัน (ต.ค. 2566) ยังทำได้เฉพาะการประมาณค่าแบบ **ML**

RMSEA = .049, SRMR = .109, CFA = .967, TLI = .951

Latent Variables:

	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
f1 =~						
y1	1.000				0.672	0.672
y2	0.890	0.192	4.639	0.000	0.598	0.598
y3	0.809	0.193	4.198	0.000	0.544	0.544
y4	1.416	0.287	4.937	0.000	0.951	0.951
f2 =~						
y5	1.000				0.549	0.549
y6	1.297	0.319	4.069	0.000	0.713	0.713
y7	1.603	0.375	4.280	0.000	0.881	0.881
y8	1.542	0.387	3.985	0.000	0.847	0.847

Standardized Loadings

แปลความหมายเหมือนปกติ ทุกตัวบ่งชี้
มีค่าสูง

Covariances:

	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
f1 ~~						
f2	0.135	0.052	2.614	0.009	0.365	0.365

ค่าสหสัมพันธ์ระหว่างองค์ประกอบ
ทางบวกอย่างมีนัยสำคัญ

Intercepts:

	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
.y1	0.000				0.000	0.000
.y2	0.000				0.000	0.000
.y3	0.000				0.000	0.000
.y4	0.000				0.000	0.000
.y5	0.000				0.000	0.000
.y6	0.000				0.000	0.000
.y7	0.000				0.000	0.000
.y8	0.000				0.000	0.000
f1	0.000				0.000	0.000
f2	0.000				0.000	0.000

ค่าเฉลี่ยขององค์ประกอบ, จุดตัดตัวบ่งชี้
มีค่าคงที่เท่ากับ 0

Thresholds:

	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
y1 t1	0.100	0.089	1.128	0.259	0.100	0.100
y2 t1	-0.385	0.091	-4.221	0.000	-0.385	-0.385
y3 t1	-0.628	0.096	-6.575	0.000	-0.628	-0.628
y4 t1	-0.739	0.098	-7.520	0.000	-0.739	-0.739
y5 t1	-0.994	0.107	-9.311	0.000	-0.994	-0.994
y6 t1	0.842	0.101	8.310	0.000	0.842	0.842
y7 t1	1.282	0.121	10.576	0.000	1.282	1.282
y8 t1	0.332	0.091	3.661	0.000	0.332	0.332

Variances:

	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
.y1	0.549				0.549	0.549
.y2	0.643				0.643	0.643
.y3	0.705				0.705	0.705
.y4	0.096				0.096	0.096
.y5	0.698				0.698	0.698
.y6	0.492				0.492	0.492
.y7	0.224				0.224	0.224
.y8	0.283				0.283	0.283
f1	0.451	0.128	3.520	0.000	1.000	1.000
f2	0.302	0.126	2.394	0.017	1.000	1.000

จุดเปลี่ยนมีเพียงค่าเดียวในแต่ละตัวบ่งชี้
(เพราะเป็นตัวแปรทวินาม)

ค่าความแปรปรวนของค่าคงเหลือ
แม้จะมีค่ามาให้ ได้จะถูกจำกัด เพราะ
กำหนด $\text{Var}(y^*) = 1$

ความแปรปรวนขององค์ประกอบ
มีการประมาณค่า เพราะใช้ **Marker
Variable Approach** ในการ
กำหนดสเกลองค์ประกอบ

Scales y*:

	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
y1	1.000				1.000	1.000
y2	1.000				1.000	1.000
y3	1.000				1.000	1.000
y4	1.000				1.000	1.000
y5	1.000				1.000	1.000
y6	1.000				1.000	1.000
y7	1.000				1.000	1.000
y8	1.000				1.000	1.000

กำหนดสเกลของตัวแปรต่อเนื่อง
ที่อยู่ภายใต้ของตัวบ่งชี้เท่ากับ 1
 $\text{Var}(y^*) = 1$

```

> outdicho <- cfa(mdicho, data=datdicho, ordered=TRUE)
> outdicho2 <- cfa(mdicho, data=datdicho, ordered=TRUE, estimator="WLSMV")
> outdicho3 <- cfa(mdicho, data=datdicho, ordered=TRUE, estimator="DWLS",
+               se="standard", test="scaled.shifted")
> outdicho3
lavaan 0.6-12 ended normally after 29 iterations

```

```

Estimator                DWLS
Optimization method      NLMINB
Number of model parameters 17

Number of observations    200

```

Model Test User Model:

	Standard	Robust
Test Statistic	24.102	27.909
Degrees of freedom	19	19
P-value (Chi-square)	0.192	0.085
Scaling correction factor		0.961
Shift parameter		2.835
simple second-order correction		

การกำหนด **arguments** ที่สามรูปแบบได้
ผลลัพธ์แบบเดียวกัน

สังเกตว่าค่าปกติของ **Categorical CFA**
คือ การกำหนด **estimator="WLSMV"**

หรือการกำหนดตัวเลือกอย่างละเอียด คือ

- estimator = "DWLS"

- se = "standard"

- test = "scaled.shifted" คือ ปรับ

แบบ Asparouhov & Muthen (2010)

```
> outdichotheta <- cfa(mdicho, data=datdicho, ordered=TRUE,  
+                       parameterization="theta")  
> summary(outdichotheta, fit=TRUE, std=TRUE)  
lavaan 0.6-12 ended normally after 75 iterations
```

กำหนดให้ใช้ theta parameterization

Estimator	DWLS
Optimization method	NLMINB
Number of model parameters	17
Number of observations	200

ค่าดัชนีความเหมาะสมเหมือนเดิมท

Model Test User Model:

	Standard	Robust
Test Statistic	24.102	27.909
Degrees of freedom	19	19
P-value (Chi-square)	0.192	0.085
Scaling correction factor		0.961
Shift parameter		2.835
simple second-order correction		

Latent Variables:

	Estimate	Std.Err	z-value	P(> z)	std.lv	std.all
f1 =~						
y1	1.000				0.907	0.672
y2	0.822	0.297	2.766	0.006	0.746	0.598
y3	0.714	0.268	2.661	0.008	0.648	0.544
y4	3.390	3.972	0.854	0.393	3.074	0.951
f2 =~						
y5	1.000				0.657	0.549
y6	1.545	0.620	2.492	0.013	1.016	0.713
y7	2.828	1.605	1.762	0.078	1.859	0.881
y8	2.423	1.293	1.874	0.061	1.593	0.847

Variances:

	Estimate	Std.Err	z-value	P(> z)	Std.lv	std.all
.y1	1.000				1.000	0.549
.y2	1.000				1.000	0.643
.y3	1.000				1.000	0.705
.y4	1.000				1.000	0.096
.y5	1.000				1.000	0.698
.y6	1.000				1.000	0.492
.y7	1.000				1.000	0.224
.y8	1.000				1.000	0.283
f1	0.822	0.426	1.932	0.053	1.000	1.000
f2	0.432	0.258	1.672	0.095	1.000	1.000

$$\theta_{jj} = 1$$

Covariances:

	Estimate	Std.Err	z-value	P(> z)	Std.lv	std.all
f1 ~~						
f2	0.218	0.109	1.995	0.046	0.365	0.365

Scales y*:

	Estimate	Std.Err	z-value	P(> z)	Std.lv	std.all
y1	0.741				0.741	1.000
y2	0.802				0.802	1.000
y3	0.839				0.839	1.000
y4	0.309				0.309	1.000
y5	0.836				0.836	1.000
y6	0.702				0.702	1.000
y7	0.474				0.474	1.000
y8	0.532				0.532	1.000

$$Var(y^*) \neq 1$$

Intercepts:

	Estimate	Std.Err	z-value	P(> z)	Std.lv	std.all
.y1	0.000				0.000	0.000
.y2	0.000				0.000	0.000
.y3	0.000				0.000	0.000
.y4	0.000				0.000	0.000
.y5	0.000				0.000	0.000
.y6	0.000				0.000	0.000
.y7	0.000				0.000	0.000
.y8	0.000				0.000	0.000
f1	0.000				0.000	0.000
f2	0.000				0.000	0.000

Thresholds:

	Estimate	Std.Err	z-value	P(> z)	Std.lv	std.all
y1 t1	0.136	0.121	1.120	0.263	0.136	0.100
y2 t1	-0.481	0.119	-4.053	0.000	-0.481	-0.385
y3 t1	-0.748	0.123	-6.065	0.000	-0.748	-0.628
y4 t1	-2.388	2.259	-1.057	0.290	-2.388	-0.739
y5 t1	-1.190	0.156	-7.620	0.000	-1.190	-0.994
y6 t1	1.200	0.217	5.522	0.000	1.200	0.842
y7 t1	2.705	1.029	2.629	0.009	2.705	1.282
y8 t1	0.624	0.248	2.514	0.012	0.624	0.332

ค่าพารามิเตอร์แตกต่างจากเดิมนิดหน่อย เพราะ y^* มีความแปรปรวนไม่เท่ากับ 1 แต่ standardized estimates เหมือนเดิม

วัดองค์ประกอบเดียวกัน ใน 4 ช่วงเวลาในระยะห่างของเวลาใกล้เคียงกัน
 โมเดลที่ตัวแปรในแต่ละเวลามีอิทธิพลต่อตัวแปรในเวลาถัดไป เรียกว่า
 โมเดลวิเคราะห์ถดถอยต่อตนเอง (Autoregressive Models)


กรณีที่โมเดลมีอิทธิพลต่อกันเพียงแค่ 1 ช่วงเวลา จะเรียกว่า **First-order autoregressive models** หรือบางทีจะเรียกว่า **simplex model** แต่ในที่นี้จะเป็นในระดับองค์ประกอบ

เขียนสมการได้คือ $F_t = \beta F_{t-1} + \zeta_t$ โดย $Var(\zeta_t) = \psi$
 (โมเดลเต็มจะมีจุดตัด เพื่อจัดการการเปลี่ยนแปลงของค่าเฉลี่ย)

```
> library(lavaan)
> datlikert <- read.table("lecture12ex2.csv", sep="," , header=TRUE)
> head(datlikert)
```

	y1	y2	y3	y4	y5	y6	y7	y8	y9	y10	y11	y12
1	1	3	2	3	4	3	4	3	4	3	3	3
2	3	4	3	2	2	3	2	2	3	4	4	2
3	2	2	2	1	3	1	3	3	3	3	2	3
4	3	3	2	2	1	2	2	2	3	3	2	2
5	4	4	3	4	4	2	3	3	4	3	4	2
6	2	2	2	3	4	3	2	2	3	1	1	1

ตัวแปรแต่ละตัวมีค่า 1,2,3,4



สร้างโมเดล CFA

```
> mlikert <- '  
+ f1 =~ y1 + y2 + y3  
+ f2 =~ y4 + y5 + y6  
+ f3 =~ y7 + y8 + y9  
+ f4 =~ y10 + y11 + y12  
'  
> outlikert <- cfa(mlikert, data=datlikert, ordered=TRUE)  
> summary(outlikert, fit=TRUE, std=TRUE)  
lavaan 0.6-12 ended normally after 32 iterations
```

ใส่ `ordered=TRUE` เพื่อระบุว่าตัวบ่งชี้
เป็นแบบจัดอันดับ

```
Estimator DWLS  
Optimization method NLMINB  
Number of model parameters 54  
  
Number of observations 700
```

Model Test User Model:

	Standard	Robust
Test Statistic	27.668	46.653
Degrees of freedom	48	48
P-value (Chi-square)	0.992	0.528
Scaling correction factor		0.716
Shift parameter		8.033
simple second-order correction		

$$\chi^2(48, N = 700) = 46.65, p = .53$$

โมเดลเหมาะสมกับข้อมูลดี

User Model versus Baseline Model:

Comparative Fit Index (CFI)	1.000	1.000
Tucker-Lewis Index (TLI)	1.005	1.001
Robust Comparative Fit Index (CFI)		NA
Robust Tucker-Lewis Index (TLI)		NA

Root Mean Square Error of Approximation:

RMSEA	0.000	0.000
90 Percent confidence interval - lower	0.000	0.000
90 Percent confidence interval - upper	0.000	0.024
P-value RMSEA <= 0.05	1.000	1.000
Robust RMSEA		NA
90 Percent confidence interval - lower		0.000
90 Percent confidence interval - upper		NA

$$RMSEA = 0, SRMR = .025, CFI = 1.00, TLI = 1.00$$

Standardized Root Mean Square Residual:

SRMR	0.025	0.025
------	-------	-------

Latent Variables:

	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
f1 =~						
y1	1.000				0.715	0.715
y2	1.117	0.054	20.649	0.000	0.799	0.799
y3	1.237	0.066	18.826	0.000	0.885	0.885
f2 =~						
y4	1.000				0.920	0.920
y5	0.609	0.051	11.885	0.000	0.560	0.560
y6	0.640	0.053	11.970	0.000	0.589	0.589
f3 =~						
y7	1.000				0.812	0.812
y8	0.760	0.054	14.164	0.000	0.617	0.617
y9	0.890	0.056	16.017	0.000	0.722	0.722
f4 =~						
y10	1.000				0.855	0.855
y11	0.829	0.050	16.578	0.000	0.709	0.709
y12	0.791	0.049	16.145	0.000	0.677	0.677

Covariances:

	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
f1 =~						
f2	0.294	0.031	9.477	0.000	0.448	0.448
f3	0.151	0.029	5.218	0.000	0.261	0.261
f4	0.115	0.030	3.890	0.000	0.189	0.189
f2 =~						
f3	0.403	0.034	11.737	0.000	0.541	0.541
f4	0.259	0.037	7.069	0.000	0.330	0.330
f3 =~						
f4	0.394	0.033	11.911	0.000	0.567	0.567

Intercepts:

	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
.y1	0.000				0.000	0.000
.y2	0.000				0.000	0.000
.y3	0.000				0.000	0.000
.y4	0.000				0.000	0.000
.y5	0.000				0.000	0.000
.y6	0.000				0.000	0.000
.y7	0.000				0.000	0.000
.y8	0.000				0.000	0.000
.y9	0.000				0.000	0.000
.y10	0.000				0.000	0.000
.y11	0.000				0.000	0.000
.y12	0.000				0.000	0.000
f1	0.000				0.000	0.000
f2	0.000				0.000	0.000
f3	0.000				0.000	0.000
f4	0.000				0.000	0.000

จุดตัดเป็น 0

ค่าเฉลี่ยของค่าประกอบ

เป็น 0

Thresholds:

	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
y1 t1	-0.937	0.056	-16.796	0.000	-0.937	-0.937
y1 t2	0.000	0.047	0.000	1.000	0.000	0.000
y1 t3	1.043	0.058	17.955	0.000	1.043	1.043
y2 t1	-1.211	0.062	-19.387	0.000	-1.211	-1.211
y2 t2	-0.298	0.048	-6.185	0.000	-0.298	-0.298
y2 t3	0.674	0.052	13.087	0.000	0.674	0.674
y3 t1	-1.425	0.070	-20.415	0.000	-1.425	-1.425
y3 t2	0.021	0.047	0.453	0.650	0.021	0.021
y3 t3	1.405	0.069	20.357	0.000	1.405	1.405
y4 t1	-0.706	0.052	-13.593	0.000	-0.706	-0.706
y4 t2	0.239	0.048	4.981	0.000	0.239	0.239
y4 t3	1.250	0.064	19.635	0.000	1.250	1.250
y5 t1	-1.250	0.064	-19.635	0.000	-1.250	-1.250
y5 t2	-0.309	0.048	-6.411	0.000	-0.309	-0.309
y5 t3	0.693	0.052	13.376	0.000	0.693	0.693
y6 t1	-1.087	0.059	-18.381	0.000	-1.087	-1.087
y6 t2	0.180	0.048	3.775	0.000	0.180	0.180
y6 t3	1.197	0.062	19.283	0.000	1.197	1.197
y7 t1	-1.368	0.068	-20.225	0.000	-1.368	-1.368
y7 t2	0.061	0.047	1.284	0.199	0.061	0.061
y7 t3	0.821	0.054	15.296	0.000	0.821	0.821
y8 t1	-0.412	0.049	-8.435	0.000	-0.412	-0.412
y8 t2	0.496	0.050	10.000	0.000	0.496	0.496
y8 t3	1.405	0.069	20.357	0.000	1.405	1.405
y9 t1	-0.943	0.056	-16.863	0.000	-0.943	-0.943
y9 t2	0.250	0.048	5.207	0.000	0.250	0.250
y9 t3	1.227	0.063	19.488	0.000	1.227	1.227
y10 t1	-1.386	0.068	-20.294	0.000	-1.386	-1.386
y10 t2	-0.476	0.049	-9.628	0.000	-0.476	-0.476
y10 t3	0.496	0.050	10.000	0.000	0.496	0.496
y11 t1	-1.377	0.068	-20.260	0.000	-1.377	-1.377
y11 t2	-0.202	0.048	-4.227	0.000	-0.202	-0.202
y11 t3	0.837	0.054	15.504	0.000	0.837	0.837
y12 t1	-0.883	0.055	-16.123	0.000	-0.883	-0.883
y12 t2	0.294	0.048	6.110	0.000	0.294	0.294
y12 t3	1.161	0.061	19.014	0.000	1.161	1.161

ตัวบ่งชี้แต่ละตัว
มี 3 จุดเปลี่ยน

Variances:						
	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
.y1	0.489				0.489	0.489
.y2	0.362				0.362	0.362
.y3	0.217				0.217	0.217
.y4	0.154				0.154	0.154
.y5	0.686				0.686	0.686
.y6	0.654				0.654	0.654
.y7	0.341				0.341	0.341
.y8	0.620				0.620	0.620
.y9	0.478				0.478	0.478
.y10	0.269				0.269	0.269
.y11	0.497				0.497	0.497
.y12	0.542				0.542	0.542
f1	0.511	0.041	12.477	0.000	1.000	1.000
f2	0.846	0.063	13.405	0.000	1.000	1.000
f3	0.659	0.049	13.468	0.000	1.000	1.000
f4	0.731	0.047	15.499	0.000	1.000	1.000

ค่าคงเหลือ ถูกจำกัดเพื่อให้ $Var(y^*) = 1$

ความแปรปรวนองค์ประกอบได้ประมาณค่า เพราะใช้ Marker Variable Approach

Scales y*:						
	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
y1	1.000				1.000	1.000
y2	1.000				1.000	1.000
y3	1.000				1.000	1.000
y4	1.000				1.000	1.000
y5	1.000				1.000	1.000
y6	1.000				1.000	1.000
y7	1.000				1.000	1.000
y8	1.000				1.000	1.000
y9	1.000				1.000	1.000
y10	1.000				1.000	1.000
y11	1.000				1.000	1.000
y12	1.000				1.000	1.000

$$Var(y^*) = 1$$

ทำโมเดลที่นำหน้าองค์ประกอบเท่ากันทั้ง 4 ช่วงเวลา (Metric Invariance)

```
> mlikert2 <- '
+ f1 =~ y1 + lambda2*y2 + lambda3*y3
+ f2 =~ y4 + lambda2*y5 + lambda3*y6
+ f3 =~ y7 + lambda2*y8 + lambda3*y9
+ f4 =~ y10 + lambda2*y11 + lambda3*y12
+ '
> outlikert2 <- cfa(mlikert2, data=datlikert, ordered=TRUE)
> summary(outlikert2, fit=TRUE, std=TRUE)
lavaan 0.6-12 ended normally after 28 iterations
```

$$\chi^2(54, N = 700) = 58.47, p = .32$$

โมเดลเหมาะสมกับข้อมูลดี

Estimator	DWLS
Optimization method	NLMINB
Number of model parameters	54
Number of equality constraints	6
Number of observations	700

Model Test User Model:	Standard	Robust
Test Statistic	40.939	58.469
Degrees of freedom	54	54
P-value (Chi-square)	0.905	0.315
Scaling correction factor		0.852
Shift parameter		10.431
simple second-order correction		

Latent Variables:

	Estimate	Std.Err	z-value	P(> z)	std.lv	std.a11
f1 =~						
y1	1.000				0.713	0.713
y2	(1mb2) 1.157	0.040	28.780	0.000	0.825	0.825
y3	(1mb3) 0.855	0.033	26.223	0.000	0.609	0.609
f2 =~						
y4	1.000				0.709	0.709
y5	(1mb2) 1.157	0.040	28.780	0.000	0.820	0.820
y6	(1mb3) 0.855	0.033	26.223	0.000	0.606	0.606
f3 =~						
y7	1.000				0.729	0.729
y8	(1mb2) 1.157	0.040	28.780	0.000	0.843	0.843
y9	(1mb3) 0.855	0.033	26.223	0.000	0.623	0.623
f4 =~						
y10	1.000				0.688	0.688
y11	(1mb2) 1.157	0.040	28.780	0.000	0.796	0.796
y12	(1mb3) 0.855	0.033	26.223	0.000	0.588	0.588

```
> anova(outlikert, outlikert2)
```

Scaled Chi-Squared Difference Test (method = "satorra.2000")

lavaan NOTE:

The "chisq" column contains standard test statistics, not the robust test that should be reported per model. A robust difference test is a function of two standard (not robust) statistics.

	Df	AIC	BIC	Chisq	Chisq diff	Df diff	Pr(>Chisq)
outlikert	48			33.425			
outlikert2	54			40.939	5.4759	6	0.4844

ทำ **Nested Model Comparison** พบผลไม่แตกต่างกัน
อย่างมีนัยสำคัญ เลือกโมเดล **Metric Invariance**

Unstandardized Loadings เท่ากันทุกช่วงเวลา

```

> mlikert3 <- '
+ f1 =~ y1 + lambda2*y2 + lambda3*y3
+ f2 =~ y4 + lambda2*y5 + lambda3*y6
+ f3 =~ y7 + lambda2*y8 + lambda3*y9
+ f4 =~ y10 + lambda2*y11 + lambda3*y12
+ f2 ~ f1
+ f3 ~ f2
+ f4 ~ f3
+ '

```

ปรับให้เป็น Autoregressive Model

```

> outlikert3 <- cfa(mlikert3, data=datlikert, ordered=TRUE)
> summary(outlikert3, fit=TRUE, std=TRUE)
lavaan 0.6-12 ended normally after 20 iterations

```

Estimator	DWLS
Optimization method	NLMINB
Number of model parameters	51
Number of equality constraints	6
Number of observations	700

Model Test User Model:

	Standard	Robust
Test Statistic	55.516	70.414
Degrees of freedom	57	57
P-value (Chi-square)	0.531	0.109
Scaling correction factor		0.951
Shift parameter		12.034
simple second-order correction		

Regressions:

	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
f2 ~ f1	0.593	0.044	13.513	0.000	0.608	0.608
f3 ~ f2	0.586	0.046	12.779	0.000	0.564	0.564
f4 ~ f3	0.453	0.047	9.561	0.000	0.475	0.475

ผลการวิเคราะห์ถดถอยในแต่ละช่วงเวลา
ที่ติดกัน

$$\chi^2(57, N = 700) = 70.41, p = .11$$

โมเดลเหมาะสมกับข้อมูลดี

```

> anova(outlikert2, outlikert3)
Scaled Chi-Squared Difference Test (method = "satorra.2000")

```

Lavaan NOTE:

The "Chisq" column contains standard test statistics, not the robust test that should be reported per model. A robust difference test is a function of two standard (not robust) statistics.

	Df	AIC	BIC	Chisq	Chisq diff	Df diff	Pr(>Chisq)				
outlikert2	54			40.939							
outlikert3	57			55.516	7.6174	3	0.05462 .				

Signif. codes:	0	'****'	0.001	'***'	0.01	'**'	0.05	'.'	0.1	' '	1

ผลการทำ Nested Model Comparison
ไม่แตกต่างกันอย่างมีนัยสำคัญ เลือก โมเดล AR(1)

```

> mlikert4 <- '
+ f1 ~ y1 + lambda2*y2 + lambda3*y3
+ f2 ~ y4 + lambda2*y5 + lambda3*y6
+ f3 ~ y7 + lambda2*y8 + lambda3*y9
+ f4 ~ y10 + lambda2*y11 + lambda3*y12
+ f2 ~ beta*f1
+ f3 ~ beta*f2
+ f4 ~ beta*f3
+ f2 ~ psi*f2
+ f3 ~ psi*f3
+ f4 ~ psi*f4
+ '
> outlikert4 <- cfa(mlikert4, data=datlikert, ordered=TRUE)
> summary(outlikert4, fit=TRUE, std=TRUE)
lavaan 0.6-12 ended normally after 16 iterations

```

ตรวจสอบ Stationary Assumption

$$\chi^2(61, N = 700) = 79.21, p = .059$$

โมเดลเหมาะสมกับข้อมูลดี

Estimator	DWLS
Optimization method	NLMINB
Number of model parameters	51
Number of equality constraints	10
Number of observations	700

Model Test User Model:

Test Statistic	Standard	Robust
Degrees of freedom	72.202	79.205
P-value (Chi-square)	61	61
Scaling correction factor	0.154	0.059
Shift parameter		1.134
simple second-order correction		15.520

```
> anova(outlikert3, outlikert4)
```

Scaled Chi-Squared Difference Test (method = "satorra.2000")

lavaan NOTE:

The "chisq" column contains standard test statistics, not the robust test that should be reported per model. A robust difference test is a function of two standard (not robust) statistics.

	Df	AIC	BIC	Chisq	Chisq diff	Df diff	Pr(>Chisq)
outlikert3	57			55.516			
outlikert4	61			72.202	7.3776	4	0.1172

Nested Model Comparison ไม่แตกต่างกัน

อย่างมีนัยสำคัญ ยอมรับ Stationary Assumption

ขนาดอิทธิพล = .545, ความแปรปรวน = .338


Regressions:

	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
f2 ~						
f1	(beta)	0.545	0.026	20.725	0.000	0.565
f3 ~						
f2	(beta)	0.545	0.026	20.725	0.000	0.551
f4 ~						
f3	(beta)	0.545	0.026	20.725	0.000	0.547

Variiances:

	Estimate	Std.Err	z-value	P(> z)	Std.lv	Std.all
.f2	(psi)	0.338	0.021	15.840	0.000	0.681
.f3	(psi)	0.338	0.021	15.840	0.000	0.696
.f4	(psi)	0.338	0.021	15.840	0.000	0.701

$$f_t = 0.545f_{t-1} + e_t; e_t \sim N(0, 0.581)$$



ตัวอย่างของข้อมูล 10 ชุด ที่มีการเปลี่ยนแปลง
จากเวลาที่ 1 ไปยังเวลาที่ 4

ตัวบ่งชี้แบบจัดอันดับ

- การทำให้ตัวบ่งชี้เป็นแบบจัดอันดับจะทำให้
 - การวิเคราะห์ผลซับซ้อนมากขึ้น (เช่น การทดสอบความคงทนของการวัด [Measurement Invariance])
 - ไม่สามารถใช้ FIML ได้
 - ไม่สามารถใช้สถิติที่ออกแบบสำหรับตัวแปรต่อเนื่องบางอย่างได้ เช่น Vuong Test สำหรับการเปรียบเทียบโมเดล
- หากมีกลุ่มแบบจัดอันดับจำนวนมาก อาจเหมารวมให้ตัวบ่งชี้เป็นตัวแปรต่อเนื่องได้ โดย Rhemtulla และคณะ (2012) ได้ทำ Simulation Study พบว่าถ้ามีกลุ่ม 5 กลุ่มขึ้นไป (ที่มีข้อมูลคนตอบ) การใช้ ML สำหรับตัวแปรต่อเนื่อง จะประมาณค่าพารามิเตอร์ได้ถูกต้องเทียบเท่ากับใช้ CFA สำหรับตัวบ่งชี้แบบจัดอันดับ