

ตัวแบบเส้นทางกำลังสองน้อยที่สุดบางส่วน

Partial Least Square Path Modeling (PLS Path Modeling)

มนตรี พิริยะกุล

Montree Piriyakul

ภาควิชาสถิติ คณะวิทยาศาสตร์ มหาวิทยาลัยรามคำแหง

PLS เป็น variance based model พัฒนาตามวิธี OLS ที่ใช้ principal component regression (PCR) เป็นเครื่องมือตามวิธี Least Square ซอฟต์แวร์ที่ใช้คือ PLS เช่น PLS-Graph, Visual PLS, Smart PLS ซึ่งใช้ง่ายและ convergence เสมอเมื่อเทียบกับ LISREL หรือ AMOS

ตัวแบบสมการโครงสร้าง (structural equation modeling, SEM) เป็น Second Generation Model คือเป็นตัวแบบที่สามารถวิเคราะห์ความสัมพันธ์ระหว่างตัวแปรได้หลายระดับของ SEM ทั้งวิเคราะห์ความสัมพันธ์ใน inner model (structure model) และวิเคราะห์ความสัมพันธ์ใน outer model (measurement model) ไปในคราวเดียวกันคือเป็นการวิเคราะห์ที่เบ็ดเสร็จครั้งเดียว ต่างกันกับ first generation modeling เช่น regression analysis, probit analysis, ANOVA, MANOVA ที่วิเคราะห์ได้ครั้งละ 1 ตัวแบบ ซึ่งทำให้ต้องใช้เวลามากกว่าที่จะวิเคราะห์ path model เดียวกันได้เสร็จ แม้ว่าจะได้ผลลัพธ์ตรงกัน คำว่าผลลัพธ์ตรงกันหมายถึงผลการศึกษตรงกัน มิใช่ค่าที่เป็นตัวเลขสัมประสิทธิ์การถดถอย ค่าสถิติ t และตัวชี้วัดอื่น ๆ เพราะค่าต่าง ๆ เหล่านี้ย่อมแตกต่างกันเป็นธรรมดาเพราะใช้ขั้นตอนวิธีในการวิเคราะห์ไม่เหมือนกัน แต่ถึงกระนั้นก็มีค่าใกล้เคียงกัน

SEM มีวิธี 2 แบบคือ

1. Covariance-Based SEM (CBSEM) เช่น LISREL, AMOS, EQS ซึ่งวิเคราะห์ข้อมูลโดยใช้วิธี maximize similarity ระหว่าง covariance structure ตามทฤษฎีกับ covariance structure ตามข้อมูลเชิงประจักษ์ การวิเคราะห์ตามแนวทางนี้มักจำเป็นต้องปรับตัวแบบกันอยู่นานกว่าโครงสร้างทั้ง 2 จะทาบกันสนิทโดยตรวจสอบได้จากเกณฑ์ (threshold) ที่กำหนด เช่น ค่า RMSE chi-square และ fit index ต่าง ๆ การปรับตัวแบบมักจะเป็นการโยงให้เกิดความสัมพันธ์ระหว่าง error term ของ manifest variable

2 Variance-based SEM (VBSEM หรือ อาจเรียกว่า Component-Based SEM เพราะใช้ principal component regression (PCR) ในอัลกอริทึมสำหรับประมาณค่า) VBSEM จะใช้วิธี OLS ในการวิเคราะห์ คือจะใช้วิธี minimize $\sum e_i^2$ ตามที่ใช้กันในการวิเคราะห์การถดถอยโดยทำการวิเคราะห์ทีละ block (1 block คือ โครงสร้างที่ประกอบด้วย construct 1 ตัว พร้อม indicator ของ construct นั้น)

คำสำคัญ PLS, SEM, CR, AVE, Average Communalities, Average Redundancy

จากการติดตามการใช้ Second generation modeling ในวารสารด้าน IS พบว่ามีการนำซอฟต์แวร์ PLS และ LISREL ไปใช้ในงานวิจัย 39 % เท่ากัน ที่เหลืออีก 23% เป็นซอฟต์แวร์ SEM อื่น เช่น AMOS EQS และอื่น ๆ (Gefen, Straub and Boudreau, 2000)

ข้อแตกต่างระหว่าง PLS LISREL และ multiple regression analysis (MRA) ที่ใช้ในการวิเคราะห์ path model ปรากฏดังนี้

ตาราง 1 เปรียบเทียบระหว่าง LISREL, PLS และ MRA

ประเด็นพิจารณา	LISREL	PLS	MRA
1. วัตถุประสงค์โดยรวม	ตรวจสอบในภาพรวมว่าทั้งโครงสร้างมีความเป็นไปได้ (เช่น ดูที่ chi-square test และ RMSE) ทั้งตรวจสอบนัยสำคัญรายเส้นทาง	ตรวจสอบนัยสำคัญรายเส้นทาง	ตรวจสอบนัยสำคัญรายเส้นทาง
2. เป้าหมายของ ANOVA	เพื่อวัด overall fit เช่น χ^2 หรือ GFI	เพื่อหาค่า R^2	เพื่อหาค่า R^2
3.ความต้องการด้านทฤษฎี/วรรณกรรม	เน้นทฤษฎี/วรรณกรรมที่สนับสนุนอย่างแข็งแกร่ง เน้น CFA	ไม่จำเป็นต้องเน้นทฤษฎี/วรรณกรรมที่แข็งแกร่ง ใช้ได้ทั้ง CFA และ EFA	ไม่จำเป็นต้องเน้นทฤษฎี/วรรณกรรมที่แข็งแกร่ง
4. การแจกแจง	ต้องเป็นการแจกแจงปกติ เพราะวิเคราะห์ด้วยวิธี ML ถ้าไม่เป็นแบบปกติต้องเปลี่ยนไปใช้เทคนิคอื่นหรือปรับข้อมูล	ไม่จำเป็นต้องแจกแจงปกติ มีความแกร่งต่อการเบนไปจากการแจกแจงปกติ	ไม่จำเป็นต้องแจกแจงปกติ มีความแกร่งต่อการเบนไปจากการแจกแจงปกติ และยังมีสูตรประมาณค่าตามการแจกแจงอื่นที่ไม่ใช่การแจกแจงปกติ
5. ขนาดตัวอย่าง	อย่างน้อย 100 -150 หน่วย หรือ 15-20 เท่าของจำนวน MV ที่มีอยู่ทั้งหมด หรือดูที่ $\frac{\# MV}{\# LV}$ ถ้าไม่เกิน 2 ต้องใช้ n มากกว่า 200 ถ้าเกิน 3 ก็ใช้ n ไม่เกิน 100	อย่างน้อย 30-100 หน่วย หรืออย่างน้อย 10 เท่าของจำนวน MV ใน LV ที่มี MV มากที่สุด	ไม่ควรต่ำกว่า 30 แต่น้อยกว่านี้ก็ได้อีก
6. ความกลมกลืน	ต้องการ MV 4 ตัวเป็นอย่างน้อย ต่อ LV เพื่อให้ over-identify	กลมกลืนเสมอ	-
7. การประมาณค่า LV	ใช้ MV จากทั้งหมด	วิเคราะห์เฉพาะ ใน block ของตัวเองตน	-
8. โยงเส้นทางไปยังตัวแปรแฝงและตัวแปรมาตรวัดและวิเคราะห์ทั้งหมดพร้อมกัน	ทำได้	ทำได้	ทำไม่ได้

9. สร้างเส้นโยงระหว่างความคลาดเคลื่อน เช่น ระหว่าง δ ระหว่าง ϵ ระหว่าง δ กับ ϵ	ทำได้	ไม่อนุญาตให้ทำ	ไม่อนุญาตให้ทำ
10. โยงตัวแปรมาตรวัดโดยวิธี reflective	ทำได้	ทำได้	ทำไม่ได้
11. โยงตัวแปรมาตรวัดโดยวิธี formative	ทำไม่ได้ (ที่จริงอาจทำได้)	ทำได้	ทำไม่ได้
12. ยอมให้ error variance เป็นส่วนหนึ่งของตัวแปร	ทำได้	ทำไม่ได้	-
13. วิเคราะห์ทุกเส้นโยงในคราวเดียว	ทำได้	ทำได้	ต้องวิเคราะห์ทีละ 1 สมการ
14. ทำ CFA	ทำได้	ทำได้	ทำไม่ได้
15. การแสดงค่าสถิติที่ใช้เปรียบเทียบ CFA	ทำได้	ทำไม่ได้	ทำไม่ได้
16. มีตัวแปรตามมากกว่า 1 ตัว	ทำไม่ได้	ทำได้	ทำได้
17. convergence	ไม่ค่อย convergence	convergence เสมอ	-

PLS Path Modeling

ให้ $X = \{X_1, X_2, \dots, X_H\}$ แทนค่าสังเกตของ exogenous latent variable

ให้ $\xi = \{\xi_1, \xi_2, \dots, \xi_H\}$ คือ exogenous latent variable (เราอาจเรียก latent variable ว่า score หรือ component)

ให้ $Y = \{Y_1, Y_2, \dots, Y_K\}$ เป็นค่าสังเกตของ endogenous latent variable

ให้ $\eta = \{\eta_1, \eta_2, \dots, \eta_K\}$ คือ endogenous latent variable

ซึ่งความสัมพันธ์ระหว่างตัวแปรแฝง (Latent variable-LV) กับตัวแปรมาตรวัด (manifest variable- MV หรือ indicator หรือ proxy) อาจเป็นแบบ reflective หรือ formative ก็ได้ขึ้นอยู่กับบริบท ดังนี้


1. Reflective indicator เป็นความสัมพันธ์ตามแบบ factor analysis โดยที่ใน block หนึ่ง ๆ ตัวแปร LV จะส่งอิทธิพลต่อ MV's ซึ่ง MV's เหล่านี้จะผันแปรร่วมกัน เรียกความสัมพันธ์นี้ว่า ตัวแบบมาตรวัดชี้ออกนอก (outer-directed measurement model) ซึ่งการศึกษาลักษณะนี้เราจะศึกษา Covariance ของตัวแปร MV สมการความสัมพันธ์ระหว่าง LV กับ MV's ใน block ใดๆ จะเป็นดังนี้

$$X_{jh} = \lambda_{xj} \xi_j + \epsilon_{xj}; j = 1, 2, \dots, H; h = 1, 2, \dots, m_j \text{ หรือ } \mathbf{X} = \mathbf{\Lambda}_x \boldsymbol{\xi} + \boldsymbol{\epsilon}_x$$


โดยที่ H คือจำนวน exogenous latent variable ทั้งหมด และ m_j คือจำนวน MV ใน block ที่ j

$$\text{และ } Y_{jh} = \lambda_{yj} \eta_j + \epsilon_{yj}; j = 1, 2, \dots, K; h = 1, 2, \dots, n_j \text{ หรือ } \mathbf{Y} = \mathbf{\Lambda}_y \boldsymbol{\eta} + \boldsymbol{\epsilon}_y$$

โดยที่ K คือจำนวน endogenous latent variable ทั้งหมดและ n_j คือจำนวน MV ใน block ที่ j ดังภาพต่อไปนี ทั้งนี้ $E(\xi_j) = a_j$, $V(\xi_j) = 1$, $E(\eta_j) = b_j$, $V(\eta_j) = 1$, $E(\epsilon_j) = 0$, $V(\epsilon_j) = 1$ สัมประสิทธิ์ λ_j คือ factor loading



2. Formative indicator คือกรณีที่มี MV ร่วมกันสร้างตัวแปร LV ขึ้นมา เรียกว่าตัวแบบมาตรวัดชี้เข้าไป (inner-directed measurement model) เป้าหมายของ SEM ในกรณีนี้คือการลด residual ของความสัมพันธ์เชิงโครงสร้างให้น้อยที่สุด



ความสัมพันธ์ระหว่าง LV กับแต่ละ MV ใน block ใดๆ จะเป็นดังนี้

$$\xi_j = \pi_{xj} X_{jh} + \delta_{\xi_j}; j = 1, 2, \dots, H; h = 1, 2, \dots, m_j \text{ หรือ } \xi = \Pi_x X + \delta_{\xi}$$

$$\eta_j = \pi_{yj} Y_{jh} + \delta_{\eta_j}; j = 1, 2, \dots, K; h = 1, 2, \dots, n_j \text{ หรือ } \eta = \Pi_y Y + \delta_{\eta}$$

การวิเคราะห์ความสัมพันธ์ ใน block ที่ j อาจใช้การวิเคราะห์สมการถดถอยพหุก็ได้คือ

$$\xi_j = \pi_{j0} + \pi_{j1}x_{j1} + \pi_{j2}x_{j2} + \dots + \pi_{jm}x_{jm} + \delta_j \text{ หรือ}$$

$$\eta_j = \pi_{j0} + \pi_{j1}y_{j1} + \pi_{j2}y_{j2} + \dots + \pi_{jn}y_{jn} + \delta_j$$

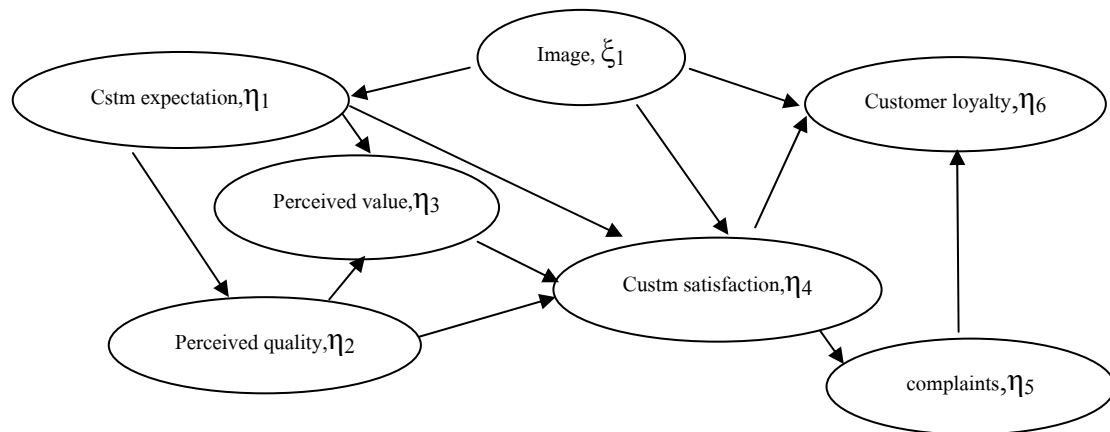
ค่าสัมประสิทธิ์ π_j คือสัมประสิทธิ์สมการถดถอยพหุ

ความสัมพันธ์แบบ reflective ถูกพัฒนาขึ้นมาเพื่อให้ MV และ LV สัมพันธ์กันในทางบวกคือ loading และ/หรือสัมประสิทธิ์การถดถอยต้องมีค่าเป็นบวก แต่ก็ไม่ได้เคร่งครัดนัก คือยอมให้มีเครื่องหมายเป็นลบได้บ้าง แต่การที่สัมประสิทธิ์มีเครื่องหมายลบสื่อว่ามีปัญหาในข้อมูล เช่น ข้อมูลต่างมาตรการวัด (scale of measurement) กันเปรียบเทียบกันไม่ได้ หรือค่าเฉลี่ยไม่สื่อความหมายหรือค่าความผันแปรไม่สื่อความหมาย (Martin, 2008; Chatelin, Vinzi and Tenenhaus, 2002) วิธีแก้ไขป้องกันปัญหาคือแปลงข้อมูลเป็นคะแนนมาตรฐานคือแปลงจาก X, Y, ξ , η เป็นคะแนนมาตรฐานโดยลบด้วยค่าเฉลี่ยแล้วหารด้วยส่วนเบี่ยงเบนมาตรฐาน (กรณี LISREL จะไม่มีการประมาณค่าของ ξ และ η) หรือ

เปลี่ยนเป็น formative ถ้าสื่อความหมายไม่ผิดจากเดิม หรือตัด MV ที่มีปัญหาทิ้งไป การตัดทิ้งอาจพิจารณาจาก loading < 0.707 หรือ Communality ต่ำ หรือ p-value สูงเกิน α ที่กำหนด

สมการโครงสร้าง (Structural model หรือ inner model) PLS เรียกว่า inner model ขณะที่ LISERLL เรียกว่า structural model คือสมการความสัมพันธ์ระหว่างตัวแปรแฝงตามภาพกรอบแนวคิด โดยถือว่าตัวแปรตามคือตัวแปรที่ถูกลูกศรชี้เข้าใส่ ตัวแปรอิสระคือตัวแปรที่อยู่ต้นลูกศร ซึ่งเราอาจมีตัวแปรตามได้หลายตัว

การกำหนดสมการโครงสร้างเรานิยมกำหนดตามตัวแปรตาม โดยสร้างสมการขึ้นมาคราวละ 1 สมการเริ่มจากตัวแปรตามแล้วสืบหาตัวแปรอิสระจากลูกศรที่ยิงเข้ามา ทั้งนี้เราจะเริ่มจากตัวแปรตามที่อยู่ด้านขวามือสุดเข้ามา ถ้ามีตัวแปรตามอยู่ด้านซ้ายมือก็ให้เริ่มจากซ้ายมือสุดเข้ามา ก่อนนั้นจะเป็นตัวแปรแทรกกลาง (Intervening variable) ที่ทำหน้าที่เป็นตัวแปรตามในโครงสร้าง ให้ทำแบบเดียวกันจนครบทุกตัวแปรตาม หรือเราอาจเตรียมความสัมพันธ์ไว้ในรูปตารางที่แต่ละ Cell มีค่า 0 หรือ 1 ขึ้นอยู่กับว่าตัวแปรด้าน Column (ใช้เป็นต้นทาง) มีอิทธิพลต่อตัวแปรด้าน row (ใช้เป็นปลายทาง) หรือไม่ ถ้าเป็นก็ให้รหัส 1 มิเช่นนั้นให้รหัส 0 เช่น จากภาพกรอบแนวคิดต่อไปนี้ (ดัดแปลงจาก Lauro & Vinzi, 2002) 1 แถวคือสมการ โครงสร้าง 1 สมการ



เราสามารถเสนอเป็นตารางเพื่อกำหนด Inner model ได้ดังนี้

ตัวแปรตาม	ตัวแปรอิสระ (antecedent)					
	Complaints	Image	CstmStfctn	PercValue	CstmExpct	PercQuality
Customer loyalty	1	1	1	0	0	0
Complaints	0	0	1	0	0	0
Image	0	0	0	0	0	0
Customer Satisfaction	0	1	0	1	1	1
Perceived value	0	0	0	0	1	1
Customer expectation	0	1	0	0	0	0
Perceived quality	0	0	0	0	1	0

ซึ่งหากเราอ่านทีละ 1 แถวจะได้สมการโครงสร้างดังนี้ (ความจริงดูที่ภาพกรอบแนวความคิดก็ได้ ตารางข้างบนนี้มีไว้เพื่อให้เห็นวิธีคิดที่หลากหลายเท่านั้น) จะพบว่า

$$\text{Customer Loyalty} = \beta_0 + \beta_1 \text{Complaints} + \beta_2 \text{image} + \beta_3 \text{customer satisfaction} + \zeta$$

จากแถวที่ 2

$$\text{Complaints} = \beta_0 + \beta_1 \text{Customer Satisfaction} + \zeta$$

จากแถวที่ 3 ไม่มีสมการเพราะ Image เป็นตัวแปรอิสระ

จากแถวที่ 4f

$$\text{Customer Satisfaction} = \beta_0 + \beta_1 \text{Image} + \beta_2 \text{Perceived Value} + \beta_3 \text{Customer Expectation} + \beta_4 \text{Perceived Quality} + \zeta$$

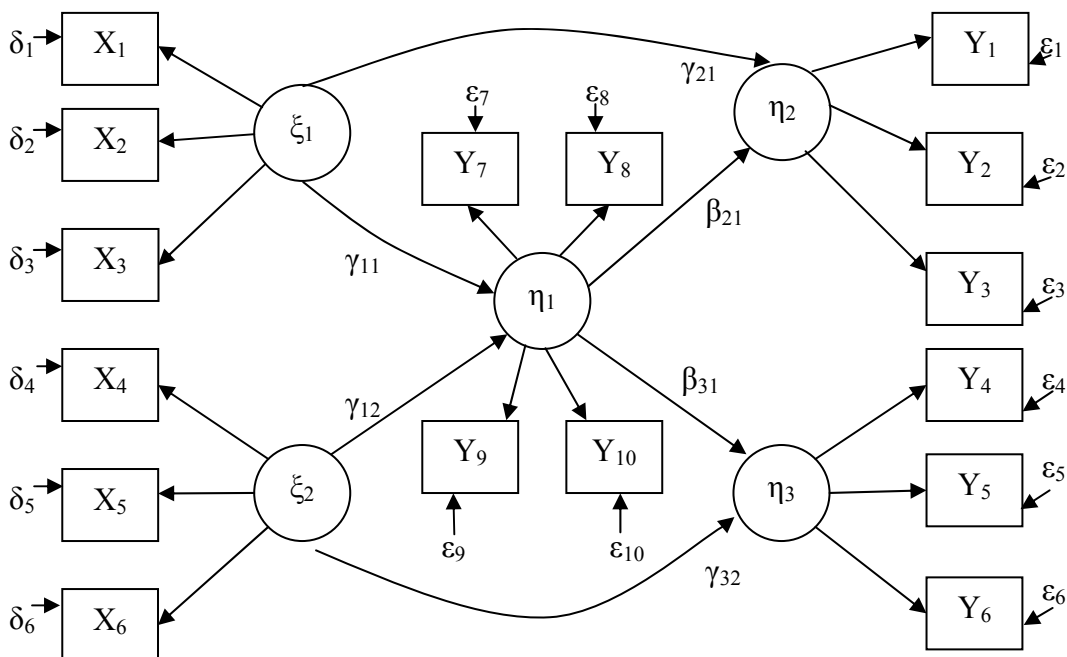
จากแถวที่ 5

$$\text{Customer Expectation} = \beta_0 + \beta_1 \text{Image} + \zeta$$

จากแถวที่ 6

$$\text{Perceived Quality} = \beta_0 + \beta_1 \text{Customer Expectation} + \zeta$$

ภาพทั่วไปของตัวแบบ PLS ปรากฏดังนี้ และเพื่อให้เข้าใจง่ายขอย่อให้มีตัวแปรอิสระ (exogenous variable) 2 ตัว ตัวแปรแทรกกลาง (intervening variable) 1 ตัว ตัวแปรตาม (endogenous variable) 2 ตัว ดังภาพ และเพื่อป้องกันความสับสนจะขอใช้ชื่อ MV และ LV ตาม LISREL และ/หรือ AMOS การขยายเป็นกรณีทั่วไปให้ใช้วิธีการเดิม



ให้ $X = \{X_1, X_2, \dots, X_H\}$ เป็นเซตของตัวชี้วัดของตัวแปร exogenous H ตัวคือ

$\xi = \{\xi_1, \xi_2, \dots, \xi_H\}$ ในที่นี้ $H = 2$

ให้ $Y = \{Y_1, Y_2, \dots, Y_K\}$ เป็นเซตของตัวชี้วัดของตัวแปร exogenous K ตัวคือ $\eta = \{\eta_1, \eta_2, \dots, \eta_K\}$ ในที่นี้ $K = 3$

สมการโครงสร้างคือ

$$\eta_1 = \gamma_{11}\xi_1 + \gamma_{12}\xi_2 + \zeta_1$$

$$\eta_2 = \beta_{21}\eta_1 + \gamma_{21}\xi_1 + \zeta_2$$

$$\eta_3 = \beta_{31}\eta_1 + \gamma_{32}\xi_2 + \zeta_3$$

หรือเสนอในรูปเมทริกซ์ได้ดังนี้

$$\begin{bmatrix} \eta_1 \\ \eta_2 \\ \eta_3 \end{bmatrix} = \begin{bmatrix} 0 & 0 & 0 \\ \beta_{21} & 0 & 0 \\ \beta_{31} & 0 & 0 \end{bmatrix} \begin{bmatrix} \eta_1 \\ \eta_2 \\ \eta_3 \end{bmatrix} + \begin{bmatrix} \gamma_{11} & \gamma_{12} \\ \gamma_{21} & 0 \\ 0 & \gamma_{32} \end{bmatrix} \begin{bmatrix} \xi_1 \\ \xi_2 \end{bmatrix} + \begin{bmatrix} \zeta_1 \\ \zeta_2 \\ \zeta_3 \end{bmatrix}$$

$$\text{นั่นคือ } \eta = \beta\eta + \Gamma\xi + \zeta$$

และสมการมาตรวัดคือ

$$\begin{bmatrix} x_{i1} \\ x_{i2} \\ x_{i3} \end{bmatrix} = \begin{bmatrix} \lambda_{x_{i1}} \\ \lambda_{x_{i2}} \\ \lambda_{x_{i3}} \end{bmatrix} \begin{bmatrix} \xi_i \end{bmatrix} + \begin{bmatrix} \delta_{i1} \\ \delta_{i2} \\ \delta_{i3} \end{bmatrix}; i = 1, 2$$

และ

$$\begin{bmatrix} y_{i1} \\ y_{i2} \\ y_{i3} \end{bmatrix} = \begin{bmatrix} \lambda_{y_{i1}} \\ \lambda_{y_{i2}} \\ \lambda_{y_{i3}} \end{bmatrix} \begin{bmatrix} \eta_i \end{bmatrix} + \begin{bmatrix} \varepsilon_{i1} \\ \varepsilon_{i2} \\ \varepsilon_{i3} \end{bmatrix}; i = 1, 2, 3$$

จากสมการโครงสร้าง $\eta = \beta\eta + \Gamma\xi + \zeta$ จะพบว่ามีสมการ reduced form เป็น

$$\eta - \beta\eta = \Gamma\xi + \zeta$$

$$(I - \beta)\eta = \Gamma\xi + \zeta$$

$$\eta = (I - \beta)^{-1}\Gamma\xi + (I - \beta)^{-1}\zeta$$

$$= \beta^*\xi + \zeta^*$$

และโดยเหตุที่ $E(\zeta^*\xi) = 0$ ดังนั้น $E(\eta\xi) = \beta^*\xi$ คือสมการพยากรณ์ η จาก ξ และสมการมาตรวัด (measurement model หรือ outer model) ในรูปเมทริกซ์ปรากฏดังนี้

1.กรณี reflective (เรียกว่าแบบมาตรวัดมุ่งออกนอก) คือ

$$X = \Lambda_x\xi + \delta_x \text{ และ } E(X|\xi) = \Lambda_x\xi$$

$$\text{หรือ } Y = \Lambda_y\eta + \varepsilon_y \text{ และ } E(Y|\eta) = \Lambda_y\eta$$

กรณีนี้ Λ_x และ Λ_y คือ loading matrix (หรือ component matrix)

แนวความคิดเรื่อง reflective measurement model เป็นสิ่งที่มีรากฐานมาจาก psychometric test ซึ่งเป็นวิธีวัดความอ่อนไหว ความคิด ความเฉลียวฉลาด ความถนัด บุคลิกภาพ ความรัก และอื่นๆ ที่เป็นสิ่งที่มีอยู่เป็นอยู่ตามธรรมชาติโดยที่ตัว indicator เป็นสิ่งที่สะท้อนการเปลี่ยนแปลงของ construct (คือ latent variable) ซึ่งถึงอย่างไรก็ต้องมี error อยู่ในตัว (เรียกว่า error-afflicted measurement) ซึ่งหาก LV เปลี่ยนแปลงไป MV เหล่านี้ก็จะถูกกระทบ เช่น สถิติปัญหาหรือความเฉลียวฉลาดมีตัวชี้วัดหลายตัวคือ ความสามารถทางภาษา ความสามารถทางการคำนวณ ความสามารถเชิงตรรกะ ความสามารถเกี่ยวกับมิติสัมพันธ์ ถ้านักเรียนมี IQ สูง คะแนนสอบของตัวชี้วัดเหล่านี้จะมีค่าสูง ถ้านักเรียนมี IQ ต่ำลงคะแนนของตัวชี้วัดเหล่านี้ก็จะน้อยลง แสดงให้เห็นว่าความสามารถทั้ง 4 ด้านเป็นผลสะท้อนของ IQ แต่ต้องทราบไว้ด้วยว่าไม่ว่าจะวัดอย่างไรก็ต้องมี error ตัวแบบของเราจึงมี error ด้วย

2. formative measurement model เป็นความสัมพันธ์แบบชี้เข้า (inner-directed measurement model) เป็นสถานการณ์ที่ LV เกิดขึ้นจากการรวม (combine) ของตัวแทนตัวชี้วัดตามแนวความคิดแบบสมการถดถอยพหุ แนวความคิดแบบสมการถดถอยพหุถือว่าตัวแปรอิสระที่ใช้อธิบายตัวแปรตามมิได้มากแต่เราอาจกำหนดเอาไว้ให้เป็นตัวแปรอิสระไม่มากนัก อาจมีเฉพาะตัวแปรสำคัญเพียง 4-5 ตัว ทั้งนี้ที่โดยความเป็นจริงมีมากกว่านั้น เราจึงถือว่าตัวชี้วัดกรณี formative model เป็นตัวแทนของตัวชี้วัด เช่น กลยุทธ์ทางการตลาดที่ LV ที่ประกอบด้วยกลยุทธ์ 4 ด้าน คือ price place promotion และ production/service ความจริงส่วนประกอบทางการตลาดมีได้ถึง 8 ด้าน คือ price place promotion production/service process people physical evidence และ partnership คือ construct ชื่อ กลยุทธ์ทางการตลาด เป็น formative model เพราะเกิดจากกลยุทธ์ 8P แต่ถ้าเราจะตัดให้เหลือน้อยลงเพียง 4P ก็ถือว่านั่นเป็นตัวแทนของบรรดากลยุทธ์ทางการตลาด และไม่ใช่ว่าจะมีเพียง 8P อาจเป็นอย่างอื่นได้อีก เช่น responsiveness, reverse order, CSR (corporate social responsibility, corporate citizenship) สิ่งที่เราควรทราบคือ formative มักจะเป็นเรื่องของสิ่งที่สร้างขึ้นมิใช่เกิดขึ้นแล้วตามธรรมชาติ เช่น ความผูกพันองค์กร เป็น construct ตัวชี้วัดคือ ความผูกพันเพราะความรักองค์กร ความผูกพันเพราะเป็นหน้าที่ของคนดีที่ต้องรักองค์กรของตน ความผูกพันเพราะเป็นสถานที่ทำงานที่ดี ตัวชี้วัดเหล่านี้เมื่อรวมกันเข้าแล้วก็จะชี้ว่าพนักงานผูกพันองค์กรมากหรือน้อย ถ้าพนักงานรักองค์กรน้อยลง ไม่เห็นค่าของอาชีพของตนในทีนั้น นิสัยไม่ดีไม่รู้คุณค่า ไม่เห็นที่นั่นมีสวัสดิการ/รายได้/ความก้าวหน้าดีกว่าที่อื่น ก็จะผูกพันองค์กรน้อยลง

ตัวแบบความสัมพันธ์ในรูปเมทริกซ์ คือ

$$\xi = \Pi_x X_x + \delta_x \text{ และ } E(\xi|X_x) = \Pi_x X_x$$

$$\text{หรือ } \eta = \Pi_y Y_y + \varepsilon_y \text{ และ } E(\eta|Y_y) = \Pi_y Y_y$$

Π_x และ Π_y คือเมทริกซ์ของสัมประสิทธิ์การถดถอย

PLS เป็น soft modeling คือพัฒนาความสัมพันธ์โดยไม่ยึดว่า ζ จะต้อง IID $N(0, \sigma^2)$ คือไม่มีข้อตกลงเรื่องการแจกแจงของ residual แต่สนใจว่าจะต้องคาดคะเน (predict) ค่าตัวแปรตามให้แม่นยำ

ที่สุด คือหาค่าประมาณของสัมประสิทธิ์ต่าง ๆ ที่มีผลให้ $\sum \text{residual}^2$ มีค่าต่ำสุด คือ minimize $\sum e_i^2$, minimize $\sum \delta_i^2$ และ minimize $\sum \zeta_i^2$

ความข้างต้นนี้มีนัยเป็น 2 ประการคือ 1. Soft modeling และ 2. prediction objective นัยทั้ง 2 นี้ พัวพันกัน เรื่องนี้ก็คือแนวความคิดของ least square ใน MRA นั่นเอง คือใน OLS เรามุ่ง minimize $\sum e_i^2$ เทียบต่อ $\hat{\beta}$ ผลที่ได้คือ $\hat{\beta}$ ที่ทำให้ $\sum e_i^2$ มีค่าต่ำที่สุด แต่ $e_i = Y_i - \hat{Y}_i$ นั่นหมายความว่า การใช้ OLS ประมาณค่า β จะทำให้ \hat{Y}_i คาดคะเน (predict) ค่าของ Y_i ได้แม่นยำ ด้วยเหตุนี้คำว่า soft modeling และ prediction objective ก็คือการพัฒนา path model โดยยึดหลัก OLS ซึ่งเป็นวิธีวิทยาที่ใช้ใน MRA ตามปกติทั่วไป ด้วยความรู้ข้อนี้เมื่อย้อนไปมอง LISREL จะเห็นว่า LISREL ต่างจาก PLS ตรงนัยทั้ง 2 นี้คือ LISREL ต้องกำหนดให้ ζ เป็น IID $N(0, \sigma_\zeta^2)$ เพราะต้องใช้วิธี maximum likelihood method และ มุ่ง maximize ความคล้ายคลึง/สอดคล้อง/กลมกลืนระหว่าง covariance matrix ของข้อมูลเชิงประจักษ์ กับ covariance matrix ตามทฤษฎี

อัลกอริทึมของ PLS

อัลกอริทึมของ PLS ทำเป็น 2 ชั้นคือ (Tenenhaus, 2008)

1. External estimation ของ LV (ในที่นี้จะใช้สัญลักษณ์เป็นคือ V_h) โดยที่ V_h คือ weighted aggregation จาก MV's ของตนเอง (คือเฉพาะใน block ของตนเอง)

$$V_h \propto \sum_j w_{jh} O_{jh} ; h = 1, 2, \dots, (H + K)$$

H คือจำนวน LV ที่เป็น exogenous variable K คือจำนวน LV ที่เป็น endogenous variable สัญลักษณ์ \propto หมายความว่าพจน์ทางซ้ายเป็น standardized value ของพจน์ทางขวาในที่นี้ V_h คือ standardized value ของ $\sum_j w_{jh} O_{jh}$

หมายเหตุ ในที่นี้ใช้อักษร O ในความหมายของ X หรือ Y และใช้ V และ Z ในความหมายของ ζ หรือ η)

2. Internal estimation ของ LV (คือ Z_h) โดยที่ Z_h คือ weighted aggregation ของ LV คือ

$$Z_h \propto \sum_{h'} e_{hh'} V_{h'}$$

การประมาณค่าจะเริ่มจากขั้นที่ 1 โดยการกำหนดค่าเริ่มต้นให้ w_{jh} ด้วยวิธีที่เหมาะสมได้ V_h จากนั้นส่งค่า V_h ไปใช้ในขั้นที่ 2 เพื่อหาค่า Z_h โดยกำหนดค่าเริ่มต้นของน้ำหนัก $e_{hh'}$ ด้วยค่าที่เหมาะสม จากนั้นย้อนกลับไปคำนวณ V_h และ Z_h สลับไปมาจนกระทั่ง Convergent

อัลกอริทึม โดยละเอียดปรากฏดังนี้

ขั้นที่ 1 ประมาณค่า LV ใน block ที่ h ; h = 1, 2, ..., H + K (H + K คือจำนวน LV ทั้งที่เป็น exogenous variable และ endogenous variable รวมกัน) คือ

$$V_h = w_{h1} O_{h1} + w_{h2} O_{h2} + \dots + w_{hp} O_{hp} ; h = 1, 2, \dots, (H + K)$$

แล้วแปลงค่าของ V_h เป็นคะแนนมาตรฐาน เมื่อ p คือจำนวน MV (เรียกว่า indicator หรือ proxy)

การกำหนดค่าเริ่มต้นของ w_{hi} ; $i = 1, 2, \dots, p$ ทำได้หลายวิธี เช่น

$$1) w_{hi} = \frac{1}{p}$$

2) ใช้ค่าสมาชิกของ eigen vector ที่สอดคล้องกับ eigen value ค่าที่ใหญ่ที่สุดของอะเรย์ $(x_{hij})_{p \times p}$ เป็นค่าของ w_{hi} วิธีนี้คือ principal component regression (PCR)

3) กำหนด w_{hi} ตามสบายด้วยค่าใด ๆ

ขั้นที่ 2 ประมาณค่าสัมประสิทธิ์เส้นทางระหว่าง LV ซึ่งอาจทำได้โดยการวิเคราะห์สมการถดถอยของสมการโครงสร้างตามเส้นทาง หรือวิเคราะห์สมการถดถอยของสมการโครงสร้างแต่ใช้ตัวแปรที่เชื่อมโยงถึงกัน (adjacent variable) จะเป็นโยงออกไปหรือโยงเข้ามาก็ได้เป็นตัวแปรอิสระ หรือใช้ Correlation ระหว่าง adjacent LV

ขั้นที่ 3 ประมาณค่า LV ใหม่โดยใช้น้ำหนักที่ได้ในขั้นที่ 2 แล้วแปลงค่าของ LV เป็นคะแนนมาตรฐาน

ขั้นที่ 4 ประมาณค่า w_{hi} ; $i = 1, 2, \dots, p$; $h = 1, 2, \dots, (H + K)$ คราวนี้ให้แยกเป็นกรณี formative measurement model กับ reflective measurement model ดังนี้

1. กรณี Formative measurement model ให้ใช้สัมประสิทธิ์การถดถอยจากสมการ

$$\hat{V}_h = w_{h1}O_{h1} + w_{h2}O_{h2} + \dots + w_{hp}O_{hp}; h = 1, 2, \dots, (H + K)$$

$$\text{คือ } \hat{W} = (O_h' O_h)^{-1} O_h' \hat{V}_h \text{ โดยที่ } \hat{W} = \begin{bmatrix} \hat{w}_{h1} \\ \hat{w}_{h2} \\ \vdots \\ \hat{w}_{hp} \end{bmatrix}, \hat{V}_h = \begin{bmatrix} \hat{v}_{h1} \\ \hat{v}_{h2} \\ \vdots \\ \hat{v}_{hn_h} \end{bmatrix},$$

$$O_h = \begin{bmatrix} O_{h11} & O_{h21} & \dots & O_{hp1} \\ O_{h12} & O_{h22} & \dots & O_{hp2} \\ O_{h13} & O_{h23} & \dots & O_{hp3} \\ \vdots & \vdots & & \vdots \\ O_{h1n_h} & O_{h2n_h} & \dots & O_{hpn_h} \end{bmatrix}; h = 1, 2, \dots, (H + K)$$

2. กรณี Reflective measurement model ให้ใช้สหสัมพันธ์ระหว่าง \hat{V}_h กับ O_{hi} คือ

$$\hat{w}_{hi} = \text{corr}(\hat{V}_h, O_{hi}); i = 1, 2, \dots, p; h = 1, 2, \dots, (H + K)$$

ขั้นที่ 5 ส่งค่า \hat{W} ไปยังขั้นที่ 1 แล้วดำเนินตามขั้นที่ 2 ขั้นที่ 3 และขั้นที่ 4 โดยทำซ้ำๆ (iterate) เรื่อย ๆ ไปจนกว่าจะลู่เข้า (convergence) เงื่อนไขการลู่เข้าคือค่าประมาณของน้ำหนัก w_{hi} และสัมประสิทธิ์เส้นทางมีค่าใกล้เคียงกับค่าที่ได้ก่อนหน้านั้นคือ $|\hat{w}_{hi,t} - \hat{w}_{hi,t-1}| < q$ และ $|\hat{e}_{hi,t} - \hat{e}_{hi,t-1}| < q$ โดยที่ q คือระดับความคลาดเคลื่อนที่ยอมรับ

Factorial validity

Factorial validity หมายถึงการตรวจสอบความเชื่อถือได้และความเที่ยงตรงของมาตรวัดโดยปกติซอฟต์แวร์ตัวแบบสมการโครงสร้างทั่วไปจะต้องนำเสนอความเที่ยงตรงเชิงโครงสร้างไว้ด้วยเสมอ โดยจะนำเสนอแตกต่างกันไปตามแต่ละซอฟต์แวร์ โดยทั่วไปจะเสนอความเที่ยงตรงเชิงเหมือน (convergent validity) และความเที่ยงตรงเชิงจำแนก (discriminant validity) ของมาตรวัดเพื่อสะท้อนให้เห็นว่า construct ซึ่งเป็นนามธรรมและไม่มีค่าข้อมูลของตนเองแต่ต้องอาศัยข้อมูลจากตัวชี้วัด (manifest variable หรือ indicator หรือ proxy) ซึ่งอาจวัดได้ดีหรือไม่ดีก็ได้ หากวัดได้ไม่ดีความสัมพันธ์เชิงโครงสร้างของ construct ก็อาจผิดไปจากทฤษฎีหรือวรรณกรรมหรือนำสู่ข้อสรุปที่น่าเคลือบแคลง

1. ความเที่ยงตรงเชิงเหมือน (Convergent validity) คือค่าความเที่ยงตรงของข้อสอบตั้งแต่ 2 ฉบับขึ้นไปที่วัดผลสัมฤทธิ์ทางการเรียนของผู้เรียนได้เหมือนกัน ในความหมายของมาตรวัด (measure) จะหมายความว่าข้อถาม (item) หรือ MV's ต่าง ๆ สามารถใช้เป็นตัวชี้วัด construct เดียวกันนั้นได้เหมือนกัน สถิติที่ใช้วัดความเที่ยงตรงเชิงเหมือนคือ

1) Loading ของตัวชี้วัดใน block จะต้องมามีค่าสูงกว่า 0.707 แต่ก็มีบ้างที่ต่ำกว่านี้แต่ก็ต้องไม่ต่ำกว่า 0.50 โดยเหตุที่การพัฒนาอัลกอริทึมกำหนดค่าน้ำหนักเริ่มต้นของ loading เป็นปริมาณบวก ดังนั้นเราจึงคาดหวังว่าค่า loading ต้องเป็นปริมาณบวก หากเป็นปริมาณลบจะสื่อว่ามีความผิดปกติในข้อมูลทางออกโดยทั่วไปคือ

(1) การแปลงข้อมูลเป็นคะแนนมาตรฐานคือ $N(0,1)$ หรือ (2) เปลี่ยนสมการมาตรวัดเป็น formative หรือ (3) ตัด MV นั้นทิ้งไป

Loading คือค่าสัมประสิทธิ์ของปัจจัย (factor) ที่มีความสัมพันธ์กับตัวแปรที่ศึกษา เช่น ในสมการปัจจัย $X_j = a_{j1}F_1 + a_{j2}F_2 + a_{j3}F_3 + a_{j4}F_4 + a_{j5}F_5 + v_j$ เราเรียก a_{ji} ว่า loading คือน้ำหนัก (สหสัมพันธ์) ที่ F_i มีต่อ X_j ถ้า a_{jk} มีค่ามากที่สุดก็แสดงว่า X_j ต้องจัดเข้าเป็นสมาชิกกลุ่ม F_k

ในกรณีนี้ $X_j ; j = 1, 2, \dots, m_j$ คือ MV's และ F คือ LV_i ดังนั้น loading จึงหมายถึงน้ำหนักของความสัมพันธ์ที่ถ้าหากมีค่าสูงก็แสดงว่า MV นั้นควรจัดเข้ากลุ่มของ LV_i

2) ค่า t-test ของ loading ต้องมีนัยสำคัญคือ $|t| \geq 1.96$ (โดยปกติเราจะกำหนดเป็น $|t| \geq 2$) คำว่า มีนัยสำคัญก็คือเชื่อว่ามีความสัมพันธ์ระหว่างตัวชี้วัด O_{ei} กับ V_{ei} หรือสหสัมพันธ์มีค่าไม่ใช่ 0

3) $AVE_h \geq 0.50$ AVE ย่อมาจากคำว่า Average Variance Extracted คือ

$$AVE_h = \frac{1}{p} \sum_i^p (loading_{hi})^2 \quad \text{หรือ} \quad AVE_h = \frac{\sum_i^p \lambda_{hi}^2}{\sum_i^p \lambda_{hi}^2 + \sum_i^p (1 - \lambda_{hi}^2)} ; h = 1, 2, \dots, (H+K)$$

และเนื่องจาก $(Loading)^2$ คือ λ_{hi}^2 ก็คือ communality ซึ่งใช้เป็นดัชนีที่ชี้ว่า LV อธิบาย MV ในบล็อกรองตนได้ดีเพียงใดโดยที่ $0 \leq loading^2 \leq 1$ (กรณี reflective) ดังนั้น $(loading)^2$ จึงมีความหมาย

เดียวกับ r^2 คือเป็นความผันแปรทั้งหมดของ MV ที่ LV สามารถควบคุมได้ หรือก็คือ reliability ของ LV นั้นเอง ค่าเฉลี่ย communality ประจำ block คือ

$$AvCommun = \frac{1}{p} \sum_i (loading_{hi})^2 = \frac{\sum \lambda_{hi}^2}{\sum \lambda_{hi}^2 + p - \sum \lambda_{hi}^2} = \frac{\sum \lambda_{hi}^2}{p} = AVE_h \text{ นั้นเอง}$$

สูตร AVE_h พัฒนามาดังนี้

$$\text{จาก } X_{hi} = \lambda_{hi} \xi_i + \varepsilon_{hi}$$

$$\text{ดังนั้น } V(X_{hi}) = \lambda_{hi}^2 V(\xi_i) + V(\varepsilon_{hi})$$

$$\text{และ } \sum_i V(X_{hi}) = \sum_i \lambda_{hi}^2 V(\xi_i) + \sum_i V(\varepsilon_{hi})$$

และเมื่อนำ $\sum_i V(X_{hi})$ หารตลอดทั้ง 2 ด้านจะได้

$$1 = \frac{\sum \lambda_{hi}^2 V(\xi_i)}{\sum V(X_{hi})} + \frac{\sum V(\varepsilon_{hi})}{\sum V(X_{hi})}$$

$$\% \text{ explained} = \frac{\sum \lambda_{hi}^2 V(\xi_i)}{\sum V(X_{hi})}$$

$$\text{แต่ } V(\xi_i) = 1, V(\varepsilon_{hi}) = 1 - \lambda_{hi}^2$$

$$\begin{aligned} \text{ดังนั้น } \sum V(X_{hi}) &= \sum \lambda_{hi}^2 V(\xi_i) + \sum V(\varepsilon_{hi}) \\ &= \sum \lambda_{hi}^2 + \sum (1 - \lambda_{hi}^2) \end{aligned}$$

$$\therefore \% \text{ explained หรือ } AVE_h = \frac{\sum \lambda_{hi}^2}{\sum \lambda_{hi}^2 + \sum (1 - \lambda_{hi}^2)} = \frac{\sum \lambda_{hi}^2}{p} = AvCommun$$


โดยที่ λ_{hi}^2 คือ $loading_{hi}^2 = [corr(X_{hi})(\xi_h)]^2 = \% \text{ explained}$ เฉพาะของตัวชี้วัดที่ i

AVE_h จึงเป็นดัชนีที่แสดงให้เห็นว่า construct ที่ h สามารถควบคุมความผันแปรของตัวชี้วัดได้มากน้อยเพียงใด

สำหรับกรณี Formative measurement model เป็นกรณีที่เรารู้ไม่ได้ดูทั้ง validity และ reliability ซึ่งจำเป็นต้องกล่าวถึงในที่นี้ มิเช่นนั้นอาจเข้าใจได้ว่าเป็นเกณฑ์เดียวกัน แต่เราจะดูว่า

1) R^2 ซึ่งก็คือ $\frac{\text{SumSquare Regression}}{\text{SumSquare Total}}$ ของแต่ละ block โดยที่ R^2 ควรมีค่าสูง แต่ถ้าไม่สูง

มากก็ขออย่าต่ำกว่า 0.20 เกณฑ์ สำหรับพิจารณา R^2 คือ



2) ให้พิจารณาตามบริบทและการประกอบกันเข้าของตัวชี้วัดว่าเป็นตัวชี้วัดของ Construct นั้น ๆ หรือไม่ สามารถอธิบายได้หรือไม่ว่า construct นั้นเกิดจากการรวมกันเข้ามาของตัวชี้วัดเหล่านี้ ทั้งนี้ต้องเข้าใจไว้ด้วยว่าตัวชี้วัดใน formative measurement model นั้นถือว่าเป็นเพียงบางส่วนของตัวชี้วัดที่มีอยู่ มิใช่ทั้งหมด เช่น

Human development เกิดจากการรวมตัวกันของการศึกษา ความรู้ ความสามารถ การมีรายได้ และการมีวิถีชีวิตที่สมเหตุสมผล

Social status เกิดจากการศึกษา อาชีพ รายได้ ถิ่นที่อยู่ ความเป็นอยู่

Performance เกิดจาก marketing performance, financial performance, operation performance

3) ค่าที่ค่า Redundancy ค่านี้คือความสามารถที่ตัวแปรในโครงสร้างที่มีอิทธิพลตรงต่อ LV_h สามารถอธิบาย MV_{hj} ได้โดยอธิบายผ่าน LV_h ของบล็อก หมายความว่า LV 's อื่น ๆ ในโครงสร้างที่เกี่ยวข้องทางตรงกับ LV_h มีอิทธิพลต่อ MV ต่าง ๆ ของบล็อกที่ h เพียงใด ขั้นตอนคือ

(1) ในบล็อกที่ h วิเคราะห์สมการถดถอย $X_{hj} = aY_h + b$ เมื่อ Y_h คือ LV ที่ h จะได้ mean square total คือ MST_{hj}

(2) วิเคราะห์สมการถดถอย $Y_h = f(Y\text{'s ที่อธิบาย } Y_h)$ ได้ MST_{y_h}

(3) $Redundancy_j = \frac{MST_{y_h}}{MST_{hj}}$ หรือ $Redundancy_j = Commuality_j * R_{y_h}^2$

(4) $AvRedundancy = \frac{1}{p} \sum_i Redundancy_j$

2. ความเที่ยงตรงเชิงจำแนก (Discriminant validity) คือดัชนีที่ชี้ว่ามาตรวัดของ construct หนึ่ง ต้องแยกขาดจากกันกับมาตรวัดของ construct อื่น ถ้าเทียบกับการสอบ ข้อสอบวิชาคณิตศาสตร์ต้องไม่ปนเปื้อนกับวิชาภาษาอังกฤษแต่ต้องแยกวัดความรู้กัน จากแนวคิดนี้จึงเห็นได้ว่าเราอาจมองเกณฑ์พิจารณาได้เป็นระดับ item กับระดับ LV ในระดับ item คือข้อถามจากต่าง construct กันต้องถามคนละเรื่อง และในระดับ LV คือคะแนนของ LV ต้องไม่สัมพันธ์กันมาก

เกณฑ์ตัดสินใจ (Threshold) เรื่องความเที่ยงตรงเชิงจำแนกมีดังนี้คือ


1) indicator ใน block เดียวกันมีสหสัมพันธ์ต่อกันสูง แต่ในต่าง block จะมีสหสัมพันธ์ต่อกันต่ำ หรือถ้าจะทำ exploratory factor analysis (EFA) จะพบว่า loading ของ indicator ใน block เดียวกัน จะมีค่าสูง แต่ loading ของ indicator นี้ใน block อื่น (factor อื่น) จะมีค่าต่ำกว่า เรียกการวิเคราะห์ตรงนี้ว่า cross loading analysis หรือ monofactorial manifest variable analysis

ปัญหาของ EFA ก็คือ indicator ของกลุ่มหนึ่งกลับไปปนอยู่ในกลุ่มอื่น กรณีนี้ถ้าเราแปลงข้อมูลของทุก indicator เป็นคะแนนมาตรฐานคือ $N(0,1)$ ก็อาจไม่พบปัญหา แต่ถ้ายังพบอยู่ก็อาจต้องทิ้ง Indicator ที่เข้ากลุ่มผิดนั้นไป

2) สหสัมพันธ์ระหว่าง LV มีค่าต่ำกว่า \sqrt{AVE} เราเรียกสหสัมพันธ์ระหว่าง LV ว่า cross construct correlation ตารางนี้จะเป็นตารางจัตุรัสขนาด $(H+K) \times (H+K)$ โดยทั่วไปเราจะเสนอในรูปแบบ lower diagonal เพราะเป็นตารางที่สมมาตร แล้วนำ $\sqrt{AVE_h}$; $h = 1, 2, \dots, (H+K)$ ไปวางในตำแหน่งที่ (h, h) แล้วตรวจสอบว่าค่า 1 สดมภ์และ 1 แถว ถ้า $\sqrt{AVE_h}$ มีค่าสูงกว่าค่าสหสัมพันธ์ของ LV ในแถวที่ h และสดมภ์ที่ h ทุกตัวแสดงว่ามาตรวัดของ LV ที่ h มีความเที่ยงตรงเชิงจำแนก ทั้งนี้เรากำหนดไว้ว่า $\sqrt{AVE_h}$ ต้องมีค่าไม่ต่ำกว่า 0.50 คือ $\sqrt{AVE_h} > 0.5$ (ที่จริงเราจะดูที่ AVE หรือที่ \sqrt{AVE} ก็ได้เพราะถ้า AVE สูงกว่า cross construct correlation ค่า \sqrt{AVE} ก็ต้องสูงกว่าเช่นกัน)

3) ความเชื่อถือได้ (Reliability) เราวัดด้วยดัชนี 2 ตัว คือ Cronbach's α และ Composite reliability (CR) ค่าทั้งสองนี้ใช้วัดว่า indicator เมื่อรวมกันแล้วสามารถวัดค่าของ LV ได้คงเส้นคงวา (consistence) เพียงใด คำว่าคงเส้นคงวาหมายความว่าวัดกี่ครั้งผู้ตอบก็จะได้คะแนนรวมเท่ากับ p % เช่น $\alpha = 0.8$ แสดงว่าถ้าให้ผู้ตอบตอบคำถามชุดนี้ 100 ครั้ง จะได้คะแนนรวมเท่าเดิม 80 ครั้ง เรากำหนดเกณฑ์ (threshold) ไว้ดังนี้

(1) Cronbach's $\alpha \geq 0.70$ โดยที่ $\alpha = 1 - \frac{\sum s_i^2}{s^2}$ เมื่อ s_i^2 คือความผันแปรของคะแนนข้อถามที่ i และ s^2 คือความผันแปรของคะแนนรวมทั้งหมด (block) α จะมี bias ถ้ามี item น้อย



(2) Composite reliability ≥ 0.60 บางครั้งกำหนดสูงถึง 0.70 หรือ 0.80 โดยที่

$$CR \text{ (หรือ } \rho_c) = \frac{\left(\sum_i \lambda_{hi}\right)^2}{\left(\sum_i \lambda_{hi}\right)^2 + \sum (1 - \lambda_{hi}^2)}$$

ทั้ง α และ CR ใช้วัดความเชื่อถือได้ของมาตรวัดได้เหมือนกัน แต่ CR ดีกว่าตรงที่ไม่มีปัญหา over-estimate หรือ under-estimate ในกรณี EFA ค่าของ CR ควรสูงกว่า 0.60 และใน CFA ค่าของ CR ควรสูงกว่า 0.70 หรือ 0.80

ถึงตรงนี้อาจกล่าวโดยรวม ๆ ได้ว่า Model fit ให้ดูที่ loading โดย loading ต้องมีค่าสูง ค่า loading หรือ weight ต้องมีนัยสำคัญ R^2 ต้องมีค่าสูง

loading อาจเป็นค่าลบได้แม้จะพัฒนามาจากแนวคิดที่ต้องเป็นปริมาณบวกแต่ก็เป็นไปได้ที่อาจเป็นลบ ในเบื้องต้นถ้าพบว่า loading มีค่าเป็นปริมาณติดลบให้แปลงข้อมูลตัวแปรมาตรวัดและตัวแปรแฝงให้เป็น $N(0,1)$ ถ้ายังมีผลให้ loading ติดลบอยู่อีกก็ให้ทดลองตัด item นั้นทิ้ง ถ้ายังเป็นลบอยู่อีกก็ปล่อยไปตามนั้น ควรคำนึงถึงไว้ด้วยว่าจำนวนตัวชี้วัดต่อ MV ควรมากกว่า 2 ตัว

ใน Reflective measurement model เราจะถือว่า MV ใน block เดียวกันจะต้องวัดสิ่งเดียวกัน (คือ LV_h เดียวกัน) และสัมพันธ์กับเฉพาะ LV_h นั้นเท่านั้น (เรียกว่า uni-dimension) ดังนั้น composite reliability (คือ internal consistency หรือ homogeneity) ของบล็อกจึงวัดได้จากทั้ง α_h และ ρ_h โดยที่

$$\alpha_h = \frac{\frac{1}{p_h(p_h - 1)} \sum \text{corr}(X_{hi}, X_{hj})}{\frac{1}{p_h - 1} + \frac{1}{p_h(p_h - 1)} \sum \text{corr}(X_{hi}, X_{hj})} * \frac{p_h}{p_h - 1}$$

โดยที่ p_h = จำนวน MV ในบล็อกที่ h และ X_{hj} คือ MV ตัวที่ j ในบล็อกที่ h

$$\begin{aligned} \rho_h &= \frac{(\sum \lambda_{hj})^2 v(\xi_j)}{(\sum \lambda_{hj})^2 v(\xi_j) + \sum (1 - \lambda_{hj}^2)} \\ &= \frac{(\sum \lambda_{hj})^2}{(\sum \lambda_{hj})^2 + \sum (1 - \lambda_{hj}^2)} \end{aligned}$$

โดยที่ λ_{hj} คือ Loading ของ LV_h ที่มีต่อ X_{hj} ค่าทั้ง 2 ควรมากกว่า 0.7 แต่อาจเป็น 0.6 ได้ถ้าเป็น EFA และมากกว่า 0.8 ถ้าเป็น CFA

Model Validation หรือ PLS fit index

ความเที่ยงตรงของตัวแบบสามารถวัดได้ 3 วิธี (Tennenhaus, Vinzi, Chatelin and Lauro, 2004) ดังนี้

1. $\text{AvCommun}_h = \frac{1}{p_h} \sum_j \lambda_{hj}^2$; $h = 1, 2, \dots, (H+K)$ และ $\overline{\text{commun}} = \frac{1}{k} \sum_h p_h * \text{AvCommun}_h$ เมื่อ

k คือจำนวน LV ทั้งหมด ค่า communality จะใช้วัดว่า LV สามารถอธิบาย MV ในบล็อกของตัวได้ดีเพียงใด และ $\overline{\text{commun}}$ ใช้แสดงรวม ๆ ว่า LV's ใช้อธิบาย MV's ได้ดีเพียงใด

2. Redundancy ใช้อธิบายว่าตัวแปรแฝงทุกตัวในสมการโครงสร้างที่สัมพันธ์ทางตรงกับ LV ในบล็อกที่ h สามารถอธิบาย MV ในบล็อก h ได้ดีเพียงใด

$$\text{AvRedund}_h = \text{AvCommun}_j * R^2(\hat{\xi}_j, \hat{\xi}_q(\xi_q \rightarrow \xi_h)); h = 1, 2, \dots, m_j \text{ และ}$$

$$\overline{\text{Redund}} = \frac{1}{H + K} \sum_j \text{AvRedund}_j$$

โดยปกติเราจะนำเสนอค่า Communality และ redundancy เฉพาะค่าประจำบล็อกซึ่งเป็นค่าเฉลี่ยจาก MV ในบล็อก ค่าเหล่านี้อยู่ระหว่าง 0 ถึง 1 ยิ่งใกล้ 1 ยิ่งดี ส่วน $\overline{\text{Redund}}$ จะเป็นดัชนีที่ใช้วัดคุณภาพโดยรวมคือ prediction performance ของตัวแบบ

3. Goodness of Fit (GoF) ค่านี้คือดัชนีชี้ความเที่ยงตรงของตัวแบบในภาพรวม เป็นการวัดในภาพรวมทั้งหมดคือทั้งสมการโครงสร้างและสมการมาตรวัดว่ามี overall fit เพียงใด

$$\text{GoF} = \sqrt{\text{commun} * R^2} \quad \text{โดยที่} \quad R^2 = \frac{1}{J} \sum_j R^2(\xi_j; \xi_q(\xi_q \rightarrow \xi_j))$$

เมื่อ J คือจำนวน endogenous variable

เนื่องจาก GoF อาศัย $\overline{\text{Commun}}$ ดังนั้น GoF จึงใช้ได้กับกรณี reflective แต่ก็สามารถใช้ในกรณี formative โดยต้องยอมรับว่าในกรณีนี้ค่า Commun ต้องต่ำและค่า R^2 ต้องสูงเมื่อเทียบกับกรณี reflective เหตุนี้ GoF จึงใช้ได้ทั้ง 2 กรณี

การทดสอบสมมุติฐาน

การทดสอบสมมุติฐานจะทำเพื่อตรวจสอบว่าสัมประสิทธิ์เส้นทางของ Inner model ไม่เป็น 0 (คือตัวแปรที่อยู่ต้นสรมีอิทธิพลต่อตัวแปรที่อยู่ปลายสร) และสัมประสิทธิ์เส้นทางของ outer model ไม่เป็น 0 (กรณี formative model) หรือ loading ไม่เป็น 0 (กรณี reflective model) และเนื่องจาก t-test ต้องพัฒนาภายใต้ข้อตกลงเรื่อง normality แต่ PLS เป็น distribution-free คือไม่ได้ตกลงเรื่องนี้เพราะจะใช้ OLS เป็นเครื่องมือ การจะพัฒนา t-test ขึ้นมาจึงต้องอาศัยวิธีสุ่มซ้ำ (resampling)

คำว่า resampling ก็คือการสุ่มซ้ำจากกลุ่มตัวอย่างที่เลือกมาแล้วโดยถือว่าตัวอย่างเดิมนั้นเป็นเสมือนกลุ่มประชากรที่มีขนาด n การสุ่มซ้ำทำได้ 2 วิธีดังนี้

วิธีที่ 1 Bootstrap resampling วิธีนี้เราจะเลือกตัวอย่างมา n หน่วยโดยวิธีสุ่มแล้วใส่คืน (sampling with replacement) คือเลือกตัวอย่างมา 1 หน่วยจากประชากรขนาด n (ก็คือตัวอย่างที่เลือกไว้เดิม) บันทึกข้อมูลแล้วใส่คืนที่เก่าแล้วสุ่มใหม่บันทึกข้อมูลแล้วใส่คืนวนทำเช่นนี้จนครบ n ครั้ง จะได้ตัวอย่างขนาด n ซึ่งค่าอาจซ้ำกันเพราะมีโอกาสเลือกซ้ำได้ก็ไม่มีเป็นไร (ให้นึกถึงการเขียนฉลาก n ใบ ใส่กล่อง เขย่าแล้วหยิบมาดูผล แล้วใส่ฉลากนั้นคืนลงกล่องเขย่าแล้วหยิบมาใหม่อีก) โดยทั่วไป PLS จะทำ bootstrap เพื่อให้ได้ตัวอย่าง 100 กลุ่ม แต่ละกลุ่มจะหาค่าเฉลี่ยและ SD

คำว่า Bootstrap แปลว่าช่วยตนเอง สำเร็จได้ด้วยตนเอง เสมือนเชือกทรงเท้าที่ลากที่ปลายก็จะดึงห่วงต่าง ๆ ของตัวเชือกเองให้รั้งเข้ามา ในทางคอมพิวเตอร์ก็คือการช่วยตัวเองโดยในโปรแกรม bootstrap ซึ่งเป็นโปรแกรมเล็ก ๆ ที่รั้งเอาโปรแกรมต่าง ๆ เข้ามาเป็นโปรแกรมควบคุมระบบ ในทางสถิติคือการดึงเอาข้อมูลจากตัวอย่างของตนเองมาหาค่าสถิติเพื่อพัฒนาตัวทดสอบ

หลักการของ Bootstrap resampling มีดังนี้ (Benner, 2009)

1. เลือกตัวอย่างมา n หน่วยจากกลุ่มประชากรที่มีการแจกแจง $F(\cdot)$ ได้ตัวอย่าง X_1, X_2, \dots, X_n
2. เลือกตัวอย่างซ้ำจากกลุ่มตัวอย่างในข้อ 1 ด้วยวิธีใดวิธีหนึ่งต่อไปนี้คือ

(1) เลือกตัวอย่างแบบใส่คืนจากกลุ่มตัวอย่างในข้อ 1 มา n หน่วย รวม B ชุด หรือ

(2) นำข้อมูลในข้อ 1 มาหาตารางแจกแจงความถี่ (คือ $F(\cdot)$ จากข้อมูลเชิงประจักษ์) แล้วสร้าง

ข้อมูลเลียนแบบด้วยเลขสุ่มมา n หน่วยรวม B ชุด (เรียกว่าวิธีจำลองแบบ)

3. กำหนดหาค่าสถิติ $\hat{\theta}_b = s_b(y)$ และ $SE_b = \sqrt{\frac{1}{B-1} \sum_b (\hat{\theta}_b - \bar{\theta}_b)^2}$, $t = \frac{\bar{\theta}_b}{SE_b} \sim t_{B-1}$

b หมายถึงถึงคำว่า bootstrap s หมายถึง statistics ซึ่งเป็นฟังก์ชัน

ในกรณีที่จะวิเคราะห์สมการถดถอย ซึ่งทำกับทั้งใน Inner model และ outer model จะพบว่าเราจะสุ่มค่าสังเกต $W_i^{(b)} = (Y_i^{(b)}, X_{1i}^{(b)}, X_{2i}^{(b)}, \dots, X_k)$ มา n หน่วย ดังนี้ (Sahinler and Topuz, 2007)

(1) สุ่มตัวอย่างค่าสังเกต W มา n ชุดได้ W_1, W_2, \dots, W_n

(2) สุ่มตัวอย่าง W มาจากข้อ (1) แบบใส่คืนมา n หน่วยรวม B ชุดแต่ละชุดหาค่า $\hat{\beta}$ ได้ $\hat{\beta}^{(bi)} = (X^{(bi)} X^{(bi)})^{-1} X^{(bi)} Y^{(bi)}$; $i = 1, 2, \dots, B$

(3) หาค่าสถิติ $\hat{\beta}^b = \frac{1}{B} \sum_i \hat{\beta}^{(bi)}$,

$$V(\hat{\beta}^{(b)}) = \frac{1}{B-1} \sum_i \left\{ (\hat{\beta}^{(bi)} - \hat{\beta}^{(b)}) (\hat{\beta}^{(bi)} - \hat{\beta}^{(b)})' \right\},$$

$$t = \frac{\hat{\beta}_j}{Se(\hat{\beta}_j)}; j = 1, 2, \dots, k$$

วิธีที่ 2 Jackknife resampling คำว่า Jackknife แปลว่ามีดของแจ๊ค เป็นมีดฟันเล็กสามารถตัดได้ทุกสิ่ง เราใช้ในความหมายของการตัดค่าสังเกตออก d หน่วยจากกลุ่มตัวอย่างขนาด n เป็นการตัดชั่วคราว d อาจเท่ากับ 1 หรือเป็นค่าอื่น PLS จะให้ $d = 1$ ถ้า $d = 1$ เราจะตัดค่าสังเกตทิ้ง 1 ค่า เช่นตัดค่าที่ 1 ได้ตัวอย่างชุดที่ 1 ขนาด $n - 1$ หน่วย ต่อมาเอาหน่วยที่ 1 คืนที่เก่าแล้วตัดหน่วยที่ 2 ได้ตัวอย่างชุดที่ 2 ขนาด $n - 1$ หน่วย เอาหน่วยที่ 2 คืนที่เก่าแล้วตัดหน่วยที่ 3 เอาหน่วยที่ 3 คืนที่เก่าแล้วตัดหน่วยที่ 4 ทำเช่นนี้ไปจนถึงตัดหน่วยที่ n ถ้า $n = 100$ เราจะได้ตัวอย่างขนาด 99 รวม 100 ตัวอย่าง ถ้า $d = 2$ ก็ทำแบบเดียวกันแต่ตัดคราวละ 2 หน่วย กรณีนี้จะมีตัวอย่างย่อย $\binom{n}{2}$ ชุด

ขั้นตอนของ Jackknife resampling ปรากฏดังนี้

1. จากตัวอย่างเดิมคือ (X_1, X_2, \dots, X_n) ตัดค่าสังเกตทิ้งครั้งละ d หน่วย (ใน PLS กำหนดให้ $d = 1$) จะได้ตัวอย่างขนาด $(n - d)$ ทั้งสิ้น $\binom{n}{d}$ ชุด

2. คำนวณหาค่าสถิติ $\hat{\theta}_j = s_j(y)$ และ $SE_j = \sqrt{\frac{n-1}{n} \sum (\hat{\theta}_j - \bar{\theta}_j)^2}$; $j = 1, 2, \dots, m$ โดยที่ $m =$

$$\binom{n}{d}, t = \frac{\hat{\theta}_j}{SE_j}$$

ในกรณีวิเคราะห์การถดถอยจะพบว่ามีการเหมือนกรณี Bootstrap โดยมีตัวสถิติดังนี้

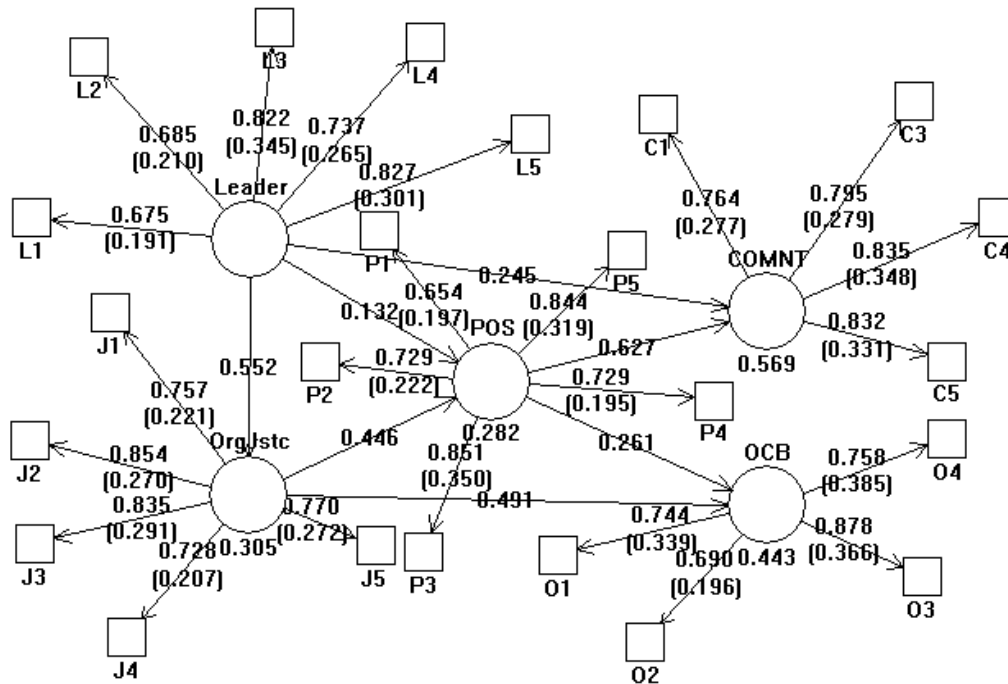
$$\hat{\beta}^{(j)} = \frac{1}{s} \sum_i \hat{\beta}^{(ji)} \text{ และ}$$

$$V(\hat{\beta}^{(j)}) = \frac{n-1}{n} \sum \left\{ (\hat{\beta}^{(ji)} - \hat{\beta}^j) (\hat{\beta}^{(ji)} - \hat{\beta}^j)' \right\}$$

$$t = \frac{\hat{\beta}_j}{Se(\hat{\beta}_j)} \sim t_{n-p} \text{ เมื่อ } p = \text{จำนวนตัวแปรอิสระ}$$

งานวิจัยที่ใช้ PLS

งานวิจัยต่อไปนี้เป็นการศึกษาวิเคราะห์ตัวแบบสมการ โครงสร้างเพื่อศึกษาความสัมพันธ์เชิงสาเหตุและเพื่อศึกษาบทบาทในฐานะสื่อกลางของ POS ในการเชื่อมโยงภาวะผู้นำและความยุติธรรมในองค์กรต่อความเป็นพนักงานที่ดีและความผูกพันองค์กร (บุญจาวรณ วิงวอน และ มนตรี พิริยะกุล, 2010) การวิจัยใช้วิธีสำรวจกับพนักงานภาคเอกชน 195 ราย โดยให้ตอบคำถามในด้านการรับรู้และเชื่อว่าองค์กรของตนจะเป็นเช่นนั้น การวิเคราะห์ SEM ใช้โปรแกรม PLS-Graph 3.0 (Chin, 2001) ในที่นี้ใช้ข้อมูลเป็นตัวอย่าง ผลการวิเคราะห์ตัวแบบสมการ โครงสร้างปรากฏดังนี้



หมายเหตุ ตัวเลขเหนือวงเล็บหมายถึงน้ำหนักของตัวชี้วัด (indicator loading) ตัวเลขในวงเล็บคือน้ำหนักการถดถอย ใช้สำหรับพิจารณาเมื่อตัวแบบภายนอกเป็น formative model ในที่นี้ไม่ได้ใช้เพราะตัวแบบภายนอกเป็น reflective model ภาพวงกลมหมายถึง construct ซึ่งมีธรรมชาติเป็นนามธรรม ต้องอาศัยตัวชี้วัด ตัวเลขบนเส้นโยงระหว่าง construct หมายถึงสัมประสิทธิ์เส้นทาง ตัวเลขใต้ endogenous construct หมายถึงค่า R² ภาพนี้ผ่านการปรับปรุงโดยการตัด indicator ที่มีค่า loading ไม่ถึง 0.707 ที่ไปแล้วคือ C2 และ O5

TL = transformational leadership, OJ = organizational justice, POS = perceived organization support, OCB = organization citizenship behavior, COMNT = organization commitment

จากภาพพบว่า POS มีบทบาทเป็นสื่อกลางที่ดีโดยทำหน้าที่เชื่อมโยง TL และ OJ ไปยัง COMNT และ OCB พบว่า OJ มีอิทธิพลทางตรงจาก POS มากกว่า TL แต่ก็พบว่า TL มีอิทธิพลต่อ OJ แล้วอ้อมผ่านไปยังมีอิทธิพลต่อ POS ค่อนข้างสูง หมายความว่าหน้าที่พนักงานจะมีความเชื่อว่าองค์กรจะให้การสนับสนุนแก่ตนหรือไม่ มากน้อยเพียงใดย่อมขึ้นอยู่กับความรู้สึกว่าองค์กรมีความยุติธรรมหรือไม่ มีวิธีปฏิบัติที่เป็นธรรม ไม่เลือกปฏิบัติ กระจายผลประโยชน์และค่าตอบแทนที่เหมาะสม และเปิดโอกาสให้ตนได้สื่อสารกับผู้นำได้ยากง่ายเพียงใด

ผลการศึกษาชี้ว่าการรับรู้ภาวะผู้นำมีอิทธิพลต่อทุก Construct โดยมีอิทธิพลทางตรงต่อ POS น้อยกว่าอิทธิพลทางอ้อม สื่อว่าความเชื่อในการสนับสนุนจากองค์กรเกิดจากความสามารถในเชิงการบริหารของผู้หน้าที่สร้างความเป็นธรรมให้เกิดขึ้นจนพนักงานรู้สึกได้ว่าตนได้รับการสนับสนุนด้านต่าง ๆ ทั้งที่เป็นรูปธรรมคือการจัดสิ่งของเครื่องใช้ เงินทอง สวัสดิการอย่างเหมาะสม และที่นามธรรม เช่น การสนับสนุน ส่งเสริม ปกป้อง ให้เกียรติ

จากภาพยังพบอีกว่า POS จะส่งผลไปยัง COMNT และ OCB หมายความว่ากรณีที่พนักงานเชื่อในการสนับสนุนที่เหมาะสมทั้งที่เป็นรูปธรรมและนามธรรมจากองค์กรพนักงานย่อมมีความผูกพันต่อองค์กรและพร้อมที่จะบำเพ็ญตนเป็นพนักงานที่ดี จากภาพจะเห็นได้ว่า POS มีอิทธิพลต่อ COMNT สูงมากถึง 0.613 ซึ่งสูงกว่าอิทธิพลของทุกตัวแปรในภาพเส้นทางและอิทธิพลนี้ยังส่งผลไปยัง OCB หมายความว่ากรณีที่พนักงานจะมีพฤติกรรมการเป็นพนักงานที่ดีได้ พนักงานจะต้องมีความรักผูกพันและเห็นว่าจะองกรให้ความเป็นธรรมในด้านต่าง ๆ แก่ตน

เมื่อพิจารณาระดับอิทธิพลของบุพปัจจัย (Antecedent) ของตัวแปรตามต่าง ๆ ทั้ง external endogenous variable และ internal endogenous variable ในภาพเส้นทางจะพบว่า TL, OJ และ POS มีอิทธิพลต่อ OCB โดย OJ มีอิทธิพลสูงที่สุดเพราะมีทั้งอิทธิพลทางตรงและทางอ้อม ส่วน TL และ POS มีเฉพาะอิทธิพลทางอ้อมและทางตรงตามลำดับ

เมื่อพิจารณา COMNT พบว่า TL, OJ และ POS มีอิทธิพลต่อ COMNT โดย TL มีอิทธิพลทั้งทางตรงและทางอ้อมแต่ก็ยังคงมีอิทธิพลต่ำกว่า POS ที่มีเฉพาะอิทธิพลทางตรงแต่ก็สูงที่สุดคือสูงกว่าทุกตัวแปรในภาพเส้นทาง สำหรับ POS ซึ่งเป็น mediator ของภาพเส้นทางพบว่า TL และ OJ มีอิทธิพลต่อ POS ค่อนข้างสูงโดยที่ OJ มีอิทธิพลสูงกว่า TL แต่ TL มีทั้งอิทธิพลทั้งทางตรงและทางอ้อม โดยจะสังเกตได้ TL ที่อิทธิพลแผ่กระจายไปทั่วทั้งกรอบ คือมีอิทธิพลต่อ COMNT และ OCB ผ่าน POS ดังนั้น POS จึงทำหน้าที่ที่ดีในการส่งผ่านอิทธิพลของ TL ไปยัง COMNT และ OCB โดย OJ มีบทบาทเสริมแรงของ TL ต่อ POS

ตาราง 2 อิทธิพลของบุพปัจจัยที่มีผลตัวแปรตาม

Dependent Variable	R ²	Effect	Antecedents		
			TL	OJ	POS
OCB	0.443	DE	0.000	0.491***	0.261***
		IE	0.369	0.116	0.000
		TOTAL	0.369	0.607	0.261
COMNT	0.569	DE	0.245***	0.000	0.627***
		IE	0.237**	0.280	0.000
		TOTAL	0.482	0.280	0.627
POS	0.282	DE	0.132*	0.446***	N/A
		IE	0.246	0.000	N/A
		TOTAL	0.378	0.446	N/A
OJ	0.305	DE	0.552***	N/A	N/A
		IE	0.000	N/A	N/A
		TOTAL	0.552	N/A	N/A

หมายเหตุ DE = direct effect, IE = Indirect effect, N/A = not applicable, *** หมายถึง $p \leq .01$, ** หมายถึง $p \leq .05$, * หมายถึง $p \leq .10$

ตาราง 3 ผลการทดสอบสมมติฐานการวิจัย

Hypothesis	coef.	t-stat	ผล
H1: การรับรู้ภาวะผู้นำเพื่อการเปลี่ยนแปลงมีอิทธิพลต่อการรับรู้ความยุติธรรมในองค์กร TL→OJ	0.552	11.259	สนับสนุน
H2: การรับรู้ภาวะผู้นำเพื่อการเปลี่ยนแปลงมีอิทธิพลต่อการรับรู้ในการสนับสนุนจากองค์กร TL→POS	0.132	1.886	สนับสนุน
H3: การรับรู้ภาวะผู้นำเพื่อการเปลี่ยนแปลงมีอิทธิพลต่อความผูกพันขององค์กร TL →COMNT	0.245	4.260	สนับสนุน
H4: การรับรู้ความยุติธรรมในองค์กรมีอิทธิพลต่อการรับรู้ ในการสนับสนุนจากองค์กร OJ →POS	0.446	4.998	สนับสนุน
H5: การรับรู้ความยุติธรรมในองค์กรมีอิทธิพลต่อความเป็นพนักงานที่ดีในองค์กร OJ → OCB	0.491	7.290	สนับสนุน
H6: การรับรู้ในการสนับสนุนจากองค์กรมีอิทธิพลต่อความผูกพันในองค์กร POS → COMNT	0.627	12.463	สนับสนุน
H7: การรับรู้ในการสนับสนุนจากองค์กรมีอิทธิพลต่อความเป็นพนักงานที่ดีในองค์กร POS→OCB	0.261	3.103	สนับสนุน

ความเที่ยงตรงและความเชื่อถือได้ของมาตรวัด

ความเที่ยงตรงเชิงเหมือน (convergent validity) คือความเที่ยงตรงของมาตรวัดที่ใช้แสดงให้เห็นว่าตัวชี้วัดสามารถวัด construct เดียวกันได้ เกณฑ์การพิจารณาคือตัวชี้วัดจะต้องมีค่า loading มากกว่า 0.700 มีค่า Cronbach's α สูงกว่า 0.707 มีค่า AVE สูงกว่า 0.50 และ loading จะต้องมียุทธศาสตร์ทางสถิติ จากตาราง 4 พบว่า loading มีค่าสูงกว่า 0.707 ทุกค่า และมีนัยสำคัญทางสถิติทุกค่า (สังเกต $|t| \geq 1.96$) รวมทั้ง AVE มีค่าสูงกว่า 0.50 ทุกค่าเช่นกัน และพบว่า Cronbach's α มีค่าสูงกว่า 0.707 หรือมีนัยสำคัญทุกค่า แสดงว่ามาตรวัดมีความเที่ยงตรงเชิงเหมือน

ตาราง 4 ค่าสถิติแสดงความเที่ยงตรงเชิงเหมือน (Convergent validity)

Construct/Item			
TL(Transformational Leadership)			
	Loading	AVE	t-stat
L1 ผู้บริหารมีความรู้ความสามารถเป็นที่ยอมรับของพนักงาน	0.6782	0.566	8.173
L2 ผู้บริหารมีวิสัยทัศน์ที่กว้างไกล	0.6853		7.746
L3 ผู้บริหารรับฟังความคิดเห็นที่แตกต่างของพนักงาน	0.8215		24.831
L4 ผู้บริหารเป็นกันเองกับพนักงาน	0.7374		15.07
L5 ผู้บริหารปฏิบัติตนเป็นแบบอย่างที่ดี	0.827		20.441
OJ (Organization Justice)			
	Loading	AVE	t-stat
J1 องค์กรมีหลักเกณฑ์ด้าน โอนย้าย,เลื่อนตำแหน่ง ที่เหมาะสม	0.7567	0.624	15.505
J2 องค์กรใช้หลักธรรมาภิบาลในการบริหารอย่างยุติธรรม	0.8538		32.299
J3 องค์กรกำหนดระเบียบปฏิบัติงานและบังคับใช้อย่างเสมอภาค	0.7345		36.741
J4 องค์กรเปิดโอกาสให้พนักงานได้รับรู้ข่าวสารอย่างทั่วถึง	0.7276		13.76
J5 องค์กรกำหนดผลตอบแทนให้พนักงานสอดคล้องกับผลปฏิบัติงาน	0.7701		20.167
Construct/Item			
POS (Perceived Organization Support)			
	Loading	AVE	t-stat
P1 มีสภาพแวดล้อมที่ดีต่อการทำงาน	0.6539	0.585	10.823
P2 มีการจัดอบรมและพัฒนาความสามารถอย่างเหมาะสมและทั่วถึง	0.7293		16.202
P3 องค์กรมีการสนับสนุน และเห็นคุณค่าผลงานของพนักงาน	0.8511		41.639
P4 องค์กรมีการสนับสนุน วัสดุ อุปกรณ์ เครื่องมือที่ทันสมัย	0.7288		12.428
P5 องค์กรสร้างความปลอดภัยในการทำงานให้กับพนักงาน	0.8435		40.249

COMNT (Organization Commitment)		Loading	AVE	t-stat
C1	มีการสร้างวัฒนธรรมและค่านิยมองค์กรให้แก่พนักงาน	0.7645	0.651	22.572
C3	มีทัศนคติที่ดีต่อองค์กร	0.795		24.901
C4	องค์กรมีการบริหารจัดการที่ดี	0.8345		31.515
C5	องค์กรคำนึงถึงผลประโยชน์ และความรู้สึกของพนักงาน	0.6325		25.286
OCB (Organization Citizenship Behavior)		Loading	AVE	t-stat
O1	พนักงานมีความภาคภูมิใจในองค์กร	0.7438	0.594	17.000
O2	พนักงานมีจิตสำนึกต่อการทำงาน	0.6903		8.778
O3	พนักงานมีทัศนคติที่ดีต่อองค์กร	0.8776		42.987
O4	การให้ความช่วยเหลือ สนับสนุนซึ่งกันและกัน	0.7579		21.817

ความเที่ยงตรงเชิงจำแนก (discriminant validity) หมายถึงความเที่ยงตรงของมาตรวัดของแต่ละ construct ที่สามารถแยกวัดได้เฉพาะเรื่องของตน ไม่ปนเปื้อนกับมาตรวัดของ construct อื่น วิธีพิจารณาคือ ให้พิจารณาจากค่า \sqrt{AVE} โดยให้พิจารณาที่ละสมรรถมาตรวัดของ construct ใดมีค่า \sqrt{AVE} สูงกว่าค่า cross construct correlation ระหว่าง construct ในสมรรถที่พิจารณากับ construct อื่นแสดงว่ามาตรวัดของ construct นั้นมีความเที่ยงตรงเชิงจำแนก สำหรับความเชื่อถือได้ของมาตรวัดให้พิจารณาที่ค่า composite reliability (CR) โดย CR จะต้องสูงกว่า 0.60

จากตาราง 5 จะพบว่า \sqrt{AVE} ในสมรรถที่สนใจมีค่าสูงกว่าค่า cross construct correlation ทุกค่า ในสมรรถเดียวกัน แสดงว่ามาตรวัดมีความเที่ยงตรงเชิงจำแนกในทุก construct และพบว่า CR มีค่าสูงกว่า 0.60 ทุกค่า และ R^2 มีค่าสูงกว่า 0.20 แสดงว่ามาตรวัดมีความเชื่อถือได้

ตาราง 5 ค่าสถิติแสดงความเที่ยงตรงเชิงจำแนก (Discriminant validity) และความเชื่อถือได้ (reliability) ของมาตรวัด

Construct	CR	R ²	AVE	Construct				
				TL	OJ	POS	COMNT	OCB
TL	0.866	0.000	0.566	0.752				
OJ	0.892	0.305	0.624	0.552	0.790			
POS	0.875	0.282	0.585	0.378	0.519	0.765		
COMN	0.882	0.569	0.651	0.482	0.644	0.719	0.807	
OCB	0.853	0.443	0.594	0.470	0.627	0.516	0.665	0.771

หมายเหตุ ค่าตัวเลขใน Main diagonal คือ \sqrt{AVE}

เอกสารอ้างอิง

บุญทวารณ วิงวอน และ มนตรี พิริยะกุล. (2553). ตัวแบบเส้นทางกำลังสองน้อยที่สุดบางส่วนของบุพปัจจัยและผลลัพธ์ของการรับรู้ในการสนับสนุนจากองค์กรของพนักงานวิสาหกิจขนาดกลางและขนาดย่อม อำเภอเมือง จังหวัดลำปาง, รายงานการวิจัย

- Benner, Axel (2009). Resampling and the Bootstrap, Retrieved March 3, 2010, from <http://www.bioconductor.org/workshop/203/NGFN03/resamplig.pdf>.
- Boomsma, A. and Hoogland, J. J. (2001) The Robustness of LISREL Modeling Revisited, Retrieved Dec 13, 2010, from <http://www.ppsw.rug.nl/~boomsma/ssi.pdf>.
- Chatelin, Y.M. (2002), Vinzi, V.E., and Tenenhaus, M. (2002) State of Art on PLS Path Modeling through the available software, Retrieved Feb 12, 2010, fro <http://www.sinopai.com/sinopai2/repository/ppt/20041227005.pdf>.
- Chin, W.W. (2001). PLS Graph User's Guide Version 3.0, Retrieved March 15, 2008, from <http://www.pubinfo.vcu.edu/carma/Documents/OCT1405/PLSGRAPH3.0Manual.hubona.pdf>
- Henselen, J., Rianger, M. and Synkovics, R.R. (2009). The Use of partial least Squares Path Modeling in International Marketing New Challenges to International Marketing: Advance in International Marketing, vol 20, pp. 227-319.
- Hsu, S., Chen, W. and Hsieh, M. (2006). Robustness Testing of PLS, LISREL, EQS and ANN –based SEM for Measuring Customer Satisfaction, Total Quality Management (17, 3), pp. 355-371.
- Lauro, C. and Vinzi, V.E.(2004), Some Contributions to PLS Path Modeling and System for the European Customer Satisfaction, Retrieved Jan 13,2010,from <http://www.sis-statistica.it/files.pdf/atti/RMi0602p201-210.pdf>.
- Martin, Nicolas. (2008). Development of a Satisfaction Survey analyzer using partial Least Square Path Modeling (PLS-PM), Retrieved Jan 10, 2010, from <http://noco.mart.free.fr/martin.pdf>.
- Sahinler, S. and Topuz, D. (2007). Bootstrap and Jackknife Resampling Algorithms for Estimation of Regression Parameters, Retrieved Feb 1, 2010,from http://www.jaqm.ro/issue/volume-2/issue-2/pdfs/sahinler_topuz.pdf.
- Stan, V and Saporta, G. (2006). Customer Satisfaction and PLS Structural equation modeling An Application to automobile market, Received Feb 7,2010, from <http://cedric.cnam.fr/PUBLIS/RC825.pdf>.
- Tenenhaus, M. (2008). A Bridge between PLS path Modeling and ULS-SEM, Retrieved March 13, 2010, from <http://web.upmf-grenoble.fr/labsad/pages/ecas2007/pages/Abstracts/abs12.pdf>.