

บทที่ 3

ระเบียบวิธีวิจัย

3.1 ข้อมูลที่ใช้ในการศึกษา

ในการศึกษาครั้งนี้ข้อมูลที่ใช้มีลักษณะเป็นข้อมูลอนุกรมเวลา (Time Series Data) ประกอบด้วย ดุลบัญชีเดินสะพัด (Current Account) การเปลี่ยนแปลงการใช้จ่ายภาครัฐบาลประเภทรายจ่ายประจำ (Fixed Government Expenditure) การเปลี่ยนแปลงการใช้จ่ายภาครัฐบาลประเภทรายจ่ายเพื่อการลงทุน (Investment Government Expenditure) และการเปลี่ยนแปลงการลงทุนภาคเอกชน (Private Investment) ซึ่งเป็นข้อมูลรายไตรมาสย้อนหลัง 18 ปี ตั้งแต่ปี พ.ศ. 2536 ถึง พ.ศ. 2553 รวมทั้งสิ้น 288 ตัวอย่าง โดยรวบรวมข้อมูลทุติยภูมิจากธนาคารแห่งประเทศไทย และฐานข้อมูล Data Stream จากศูนย์การเงินและการลงทุน (Financial & Investment Center : FIC)

3.2 แบบจำลองที่ใช้ในการศึกษา

การศึกษานี้ได้ใช้แบบจำลอง Vector Autoregression (VAR) ในการวิเคราะห์ความสัมพันธ์ระหว่างการเปลี่ยนแปลงการใช้จ่ายของภาครัฐบาล การเปลี่ยนแปลงการลงทุนของภาคเอกชนและดุลบัญชีเดินสะพัดของประเทศไทย โดยตัวแปรต่างๆที่นำมาเป็นตัวแปรในแบบจำลอง VAR นั้นพิจารณาตามทฤษฎีการบริโภคข้ามช่วงเวลาประยุกต์กับดุลบัญชีเดินสะพัด (The Intertemporal Approach to the Current Account) ได้แก่ การเปลี่ยนแปลงการลงทุนของภาคเอกชน และการเปลี่ยนแปลงการใช้จ่ายภาครัฐบาลซึ่งได้ประยุกต์แบ่งเป็น การเปลี่ยนแปลงรายจ่ายประจำและการเปลี่ยนแปลงรายจ่ายเพื่อการลงทุน และดุลบัญชีเดินสะพัด รวมทั้งหมด 4 ตัวแปรดังนี้

CA คือ ดุลบัญชีเดินสะพัด (Current Account)

DG^f คือ การเปลี่ยนแปลงการใช้จ่ายภาครัฐบาลประเภทรายจ่ายประจำ (Fixed Government Expenditure)

DG^i คือ การเปลี่ยนแปลงการใช้จ่ายภาครัฐบาลประเภทรายจ่ายเพื่อการลงทุน (Investment Government Expenditure)

DI คือ การเปลี่ยนแปลงการลงทุนของภาคเอกชน (Private Investment)

เมื่อตัวแปรต่างๆ ในแบบจำลอง VAR นั้น แต่ละตัวแปรภายในจะถูกอธิบายโดยค่าความล่าช้าหรือค่าในอดีต (Lag) ของตัวแปรนั้น และจำนวน Lag ของตัวแปรอื่นๆ ในแบบจำลอง ดังนั้นจะได้แบบจำลอง VAR ในรูป Structural VAR หรือ Primitive System โดยใช้เขียนให้อยู่ในรูปเมทริกซ์ได้เป็น

$$\begin{bmatrix} 1 & b_{1,2} & \dots & b_{1,4} \\ b_{2,1} & 1 & \dots & b_{2,4} \\ \vdots & \vdots & \ddots & \vdots \\ b_{4,1} & b_{4,2} & \dots & 1 \end{bmatrix} \begin{bmatrix} CA_t \\ DG_t^f \\ DG_t^i \\ DI_t \end{bmatrix} = \begin{bmatrix} b_{1,0} \\ b_{2,0} \\ b_{3,0} \\ b_{4,0} \end{bmatrix} + \sum_{i=1}^p \begin{bmatrix} \gamma_{1,n} & \gamma_{1,n} & \dots & \gamma_{1,n} \\ \gamma_{2,n} & \gamma_{2,n} & \dots & \gamma_{2,n} \\ \vdots & \vdots & \ddots & \vdots \\ \gamma_{4,n} & \gamma_{4,n} & \dots & \gamma_{4,n} \end{bmatrix} \begin{bmatrix} CA_{t-i} \\ DG_{t-i}^f \\ DG_{t-i}^i \\ DI_{t-i} \end{bmatrix} + \begin{bmatrix} \varepsilon_t^{CA} \\ \varepsilon_t^{DG^f} \\ \varepsilon_t^{DG^i} \\ \varepsilon_t^{DI} \end{bmatrix}$$

$$Bx_t = \Gamma_0 + \sum_{i=1}^p \Gamma_i x_{t-i} + \varepsilon_t$$

หรือ
$$Bx_t = \Gamma_0 + \Gamma_1 x_{t-1} + \Gamma_2 x_{t-2} + \dots + \Gamma_p x_{t-p} + \varepsilon_t \quad (3-1)$$

เมื่อ $x_t = [CA_t \ DG_t^f \ DG_t^i \ DI_t]'$ คือ เวกเตอร์ของตัวแปรขนาด 4×1

$x_{t-i} = [CA_{t-i} \ DG_{t-i}^f \ DG_{t-i}^i \ DI_{t-i}]'$ คือ Random Vector 4×1

$$B = \begin{bmatrix} 1 & b_{1,2} & \dots & b_{1,4} \\ b_{2,1} & 1 & \dots & b_{2,4} \\ \vdots & \vdots & \ddots & \vdots \\ b_{4,1} & b_{4,2} & \dots & 1 \end{bmatrix} \quad \text{คือ เมทริกซ์พารามิเตอร์ของตัวแปรขนาด } 4 \times 4$$

$$\Gamma_0 = [b_{1,0} \ b_{2,0} \ b_{3,0} \ b_{4,0}]' \quad \text{คือ เวกเตอร์ของพารามิเตอร์ขนาด } 4 \times 1$$

$$\Gamma_i = \begin{bmatrix} \gamma_{1,n} & \gamma_{1,n} & \dots & \gamma_{1,n} \\ \gamma_{2,n} & \gamma_{2,n} & \dots & \gamma_{2,n} \\ \vdots & \vdots & \ddots & \vdots \\ \gamma_{4,n} & \gamma_{4,n} & \dots & \gamma_{4,n} \end{bmatrix} \quad \text{คือเมทริกซ์พารามิเตอร์ของตัวแปรขนาด } 4 \times 4$$

$$\varepsilon_t = [\varepsilon_t^{CA} \ \varepsilon_t^{DG^f} \ \varepsilon_t^{DG^i} \ \varepsilon_t^{DI}] \quad \text{คือ เวกเตอร์ของตัวแปรขนาด } 4 \times 1$$

โดย $\varepsilon_t = E(\varepsilon_t) = 0, \text{var}(\varepsilon_t) = \sigma^2 I, \text{cov}(\varepsilon_t \varepsilon_s) = 0 \text{ for } t \neq s,$

$\text{auto cov}(\varepsilon_t \varepsilon_{t-i}) = 0 \text{ for } i \neq 0$

และ Variance/Covariance Matrix of the Structural Innovations หรือ Σ_ε ขนาด 4×4 คือ

$$\Sigma_\varepsilon = E \varepsilon_t \varepsilon_{t-i}' = \begin{bmatrix} \sigma_1^2 & 0 & \dots & 0 \\ 0 & \sigma_2^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_4^2 \end{bmatrix}$$

คูณทั้งสองข้างของสมการ (3-1) ด้วย B^{-1} ทำให้แบบจำลอง VAR ปรับอยู่ในรูปแบบมาตรฐาน
ทั่วไป p^{th} -order Reduced VAR ดังนี้

$$x_t = B^{-1}\Gamma_0 + \sum_{i=1}^p B^{-1}\Gamma_i x_{t-i} + B^{-1}\varepsilon_t$$

หรือ $x_t = A_0 + \sum_{i=1}^p A_i x_{t-i} + e_t$ (3-2)

เมื่อ $A_0 = B^{-1}\Gamma_0$ คือ เมทริกซ์พารามิเตอร์ของตัวแปรขนาด 4×1

$A_i = B^{-1}\Gamma_i$ คือ เมทริกซ์พารามิเตอร์ของตัวแปรขนาด 4×4

$e_t = B^{-1}\varepsilon_t$ คือ เวกเตอร์ของพจน์ความคลาดเคลื่อนขนาด 4×1

โดย $e_t = E(e_t) = 0, \text{var}(e_t) = \sigma^2 I, \text{cov}(e_t e_s) = 0 \text{ for } t \neq s,$
 $\text{auto cov}(e_t e_{t-i}) = 0 \text{ for } i \neq 0$

และ Variance/Covariance Matrix of the Regression Residuals หรือ Σ ขนาด 4×4 คือ

$$\Sigma = E e_t e_t' = \begin{bmatrix} \sigma_1^2 & \sigma_{1,2} & \dots & \sigma_{1,4} \\ \sigma_{2,1} & \sigma_2^2 & \dots & \sigma_{2,4} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{4,1} & \sigma_{4,2} & \dots & \sigma_4^2 \end{bmatrix}$$

และกำหนดให้ $a_{i,0}$ คือ สมาชิกที่ i ของเวกเตอร์ A_0

$a_{i,j}$ คือ สมาชิกในแถวที่ i และคอลัมน์ที่ j ของเวกเตอร์ A_i

e_t^i คือ สมาชิกที่ i ของเวกเตอร์ e_t

ดังนั้นสามารถเขียน VAR ในรูปมาตรฐาน หรือ Standard Form โดยใช้ Matrix Algebra เขียน

ให้กะทัดรัดได้เป็น

$$\begin{bmatrix} CA_t \\ DG_t^f \\ DG_t^i \\ DI_t \end{bmatrix} = \begin{bmatrix} a_{1,0} \\ a_{2,0} \\ a_{3,0} \\ a_{4,0} \end{bmatrix} + \sum_{i=1}^p \begin{bmatrix} a_{1,j} & a_{1,j} & \dots & a_{1,j} \\ a_{2,j} & a_{2,j} & \dots & a_{2,j} \\ \vdots & \vdots & \ddots & \vdots \\ a_{4,j} & a_{4,j} & \dots & a_{4,j} \end{bmatrix} \begin{bmatrix} CA_{t-i} \\ DG_{t-i}^f \\ DG_{t-i}^i \\ DI_{t-i} \end{bmatrix} + \begin{bmatrix} e_t^1 \\ e_t^2 \\ e_t^3 \\ e_t^4 \end{bmatrix}$$

เมื่อแบบจำลอง VAR อยู่ในรูปแบบ p^{th} -order Reduced VAR จะเห็นได้ว่าจากสมการ (3-2) จะมีเฉพาะตัวแปรที่ถูกกำหนดมาก่อน (Predetermined Variables) และพจน์ความคลาดเคลื่อน (Error Terms) ถูกสมมติว่าเป็น Serially Uncorrelated ด้วยความแปรปรวนคงที่ ดังนั้นแต่ละสมการในระบบสามารถที่จะประมาณค่าโดยใช้วิธีกำลังสองน้อยที่สุด (Ordinary Least Squares : OLS) ได้ ซึ่งค่าประมาณ OLS จะมีลักษณะสอดคล้อง (Consistent) และมีประสิทธิภาพเชิงเส้นกำกับ

(Asymptotically Efficient) แม้ว่าพจน์ความคลาดเคลื่อนจะมีความสัมพันธ์ข้ามสมการกันก็ตาม ทั้งนี้ Seemingly Unrelated Regression (SUR) ไม่ได้เพิ่มประสิทธิภาพของการประมาณค่า เนื่องจากการถดถอยของทุกสมการจะมีตัวแปรทางขวามือเหมือนกันทุกประการ (Identical Right-hand-side Variables)

3.3 วิธีการวิจัย

3.3.1 การทดสอบความนิ่งของข้อมูล (Unit Root Test)

ในการศึกษานี้ใช้ข้อมูลที่มีลักษณะเป็นข้อมูลอนุกรมเวลา ค่าของตัวแปรในปัจจุบันและอดีตมีความสัมพันธ์กัน ทำให้ตัวแปรมีลักษณะไม่นิ่ง (Non-stationary) ถ้าหากตัวแปรที่ใช้ประมาณค่าในแบบจำลองมีคุณสมบัติไม่นิ่ง จะทำให้เกิดปัญหาความสัมพันธ์ไม่แท้จริง ดังนั้นจึงต้องมีการทดสอบความนิ่งของข้อมูล เพื่อพิจารณาคุณสมบัติความนิ่ง (Stationary) ของข้อมูล โดยวิธี Augmented Dickey-Fuller (ADF) ซึ่งพิจารณาสมการถดถอย 3 รูปแบบที่แตกต่างกันในการทดสอบว่ามี Unit root หรือไม่ ดังนี้

$$\Delta x_t = \theta x_t + \sum_{i=1}^p \phi \Delta x_{t-i} + \varepsilon_t \quad (3-3)$$

$$\Delta x_t = \alpha + \theta x_{t-1} + \sum_{i=1}^p \phi \Delta x_{t-i} + \varepsilon_t \quad (3-4)$$

$$\Delta x_t = \alpha + \beta T + \theta x_{t-1} + \sum_{i=1}^p \phi \Delta x_{t-i} + \varepsilon_t \quad (3-5)$$

โดยมีสมมติฐานการทดสอบ ดังนี้

$$H_0 : \theta = 0 \quad \text{ข้อมูลมีลักษณะไม่นิ่ง (Non-stationary)}$$

$$H_1 : \theta < 0 \quad \text{ข้อมูลมีลักษณะนิ่ง (Stationary)}$$

การทดสอบ Unit Root ถ้ากรณีผลการทดสอบปฏิเสธสมมติฐานหลัก หมายความว่าข้อมูลมีลักษณะนิ่ง (Stationary) ที่ Integration of Order Zero หรือ $I(0)$ แต่กรณีผลการทดสอบข้อมูลมีลักษณะไม่นิ่ง สามารถแก้ไขโดยทำให้ตัวแปรอยู่ในรูปส่วนต่างแล้วทดสอบ Unit Root อีกครั้ง จนตัวแปรที่อยู่ในรูปส่วนต่างมีลักษณะนิ่ง ที่ลำดับที่ d หรือ $I(d)$

3.3.2 การเลือกความล่าช้า (Lag) ที่เหมาะสม

ในการศึกษานี้ใช้เกณฑ์ Akaike Information Criteria (AIC) และ Schwarz's Bayesian Information Criterion (SBC หรือ SC) เป็นเกณฑ์การพิจารณาความเหมาะสมของจำนวนความล่าช้า หรือ Lag ของแบบจำลอง มีสูตรดังนี้

$$AIC = \log \hat{\sigma}^2 + 2 \frac{p+q}{T} \quad (3-6)$$

โดย $\hat{\sigma}$ คือ ค่าประมาณของความแปรปรวนของ e_t

$$SC = \log \hat{\sigma}^2 + 2 \frac{p+q}{T} \log T \quad (3-7)$$

เกณฑ์การพิจารณาทั้งสองนี้อาศัยความควรจะเป็น (Likelihood-based) และแสดงให้เห็นถึงความสมดุล (ที่มีผลในทางตรงกันข้าม) สำหรับหลักเกณฑ์ในการตัดสินใจเลือกแบบจำลองคือ จะเลือกแบบจำลองที่มีค่า AIC หรือ SC ที่มีค่าน้อยที่สุด โดยค่า AIC หรือ SC จะมีค่าน้อยเนื่องจากสาเหตุดังต่อไปนี้ มีค่าความแปรปรวนและความแปรปรวนรวมน้อย มีจำนวนของตัวแปรและจำนวน Lag น้อย รวมถึงมีจำนวนข้อมูลในการประมาณค่ามาก

ถ้าเกณฑ์การพิจารณาทั้งสองดังกล่าวมีความแตกต่างกันให้เลือกใช้ค่า SC ก่อน เนื่องจากค่า SC มีคุณสมบัติในการเลือกแบบจำลองที่ถูกต้องและค่อนข้างแน่นอน สำหรับ AIC นั้น มีแนวโน้มเป็นลักษณะเชิงเส้นกำกับในแบบจำลองที่มีพารามิเตอร์มากเกินไป

3.3.3 แบบจำลอง Vector Autoregression

เพื่อตอบคำถามของการศึกษา การศึกษานี้ได้กำหนดแบบจำลอง VAR เป็นแบบจำลองที่เหมาะสมเพื่อใช้ในการศึกษา เนื่องจากลักษณะและความสัมพันธ์ของตัวแปรอาจไม่ชัดเจนและเป็นความสัมพันธ์ในเชิงพลวัต ประกอบกับข้อสมมติให้ตัวแปรแต่ละตัวไม่ส่งผลกระทบต่อตัวแปรอื่นๆ ในช่วงเวลาเดียวกัน

เนื่องจากความสัมพันธ์ของตัวแปรแต่ละตัวมีความสัมพันธ์ที่ไม่แน่นอน และส่งผลกระทบระหว่างกันทั้งทางตรงและทางอ้อม ข้อสมมติประการหนึ่งที่จำเป็นและเหมาะสมต่อการศึกษาในครั้งนี้ คือ ตัวแปรแต่ละตัวจะไม่ส่งผลกระทบต่อตัวแปรอื่นในช่วงเวลาเดียวกัน หรือไม่ส่งผลกระทบอย่างทันทีเมื่อตัวแปรหนึ่งเปลี่ยนแปลง เพราะการตอบสนองต่อ Shock ที่เกิดขึ้นและที่มีผลต่อตัวแปรต่างๆ ในระบบเศรษฐกิจนั้นมีความล่าช้า (Non-contemporaneous Effect)

สามารถสร้างแบบจำลองของเวกเตอร์ในรูปค่าที่ผ่านมาในอดีตของเวกเตอร์ดังกล่าว ผลที่ได้คือ Vector Autoregression (VAR) สามารถเขียนได้ดังนี้

$$y_t = m + A_1 y_{t-1} + A_2 y_{t-2} + \dots + A_p y_{t-p} + \varepsilon_t \quad (3-8)$$

Ender(1995) ได้ยกตัวอย่างระบบอย่างง่ายที่มีสองตัวแปรดังนี้

$$y_t = b_{10} + b_{12}z_t + \gamma_{11}y_{t-1} + \gamma_{12}z_{t-1} + \varepsilon_{yt} \quad (3-9)$$

$$z_t = b_{20} + b_{21}y_t + \gamma_{21}y_{t-1} + \gamma_{22}z_{t-1} + \varepsilon_{zt} \quad (3-10)$$

3.3.4 การวิเคราะห์ปฏิกิริยาตอบสนองต่อความแปรปรวน (Impulse Response Function: IRF)

เนื่องจากการวิเคราะห์แบบจำลอง VAR ไม่สามารถวิเคราะห์จากค่าสัมประสิทธิ์ที่ได้จากการประมาณค่า จึงต้องอาศัยวิธีการ Impulse Response Function: IRF ช่วยในการวิเคราะห์ ซึ่งอาศัยแนวคิด Moving Average เพื่อพิจารณาการเคลื่อนไหวของตัวแปรที่เป็นอนุกรมเวลา โดยแบบจำลอง VAR จะอาศัยคุณสมบัติ Stability ของแบบจำลองในการเขียนแบบจำลองให้อยู่ในรูป Vector Moving Average (VMA) ดังนี้

$$\begin{bmatrix} y_t \\ z_t \end{bmatrix} = \begin{bmatrix} \bar{y} \\ \bar{z} \end{bmatrix} + \sum_{i=0}^{\infty} \begin{bmatrix} \phi_{11}(i) & \phi_{12}(i) \\ \phi_{21}(i) & \phi_{22}(i) \end{bmatrix} \begin{bmatrix} \varepsilon_{yt-i} \\ \varepsilon_{zt-i} \end{bmatrix} \quad (3-11)$$

จากนั้นทำการหาตัวคูณ Multiplier ($\phi_{ij}(i)$) ของค่าความผิดพลาด (ε_i) ในแบบจำลอง VMA แต่ละช่วงเวลา แล้วนำตัวคูณนั้นมาวาดกราฟเทียบกับเวลา จะได้ IRF จะสามารถวิเคราะห์ความสัมพันธ์ของตัวแปรหนึ่งต่ออีกตัวแปรหนึ่งในแต่ละช่วงเวลา ซึ่งในการศึกษานี้ สามารถบอกทิศทาง แนวโน้มการเปลี่ยนแปลงและขนาดของผลกระทบในแต่ละช่วงเวลาได้

3.3.5 การวิเคราะห์การแยกส่วนของความแปรปรวน (Variance Decomposition)

จาก IRF เป็นการวิเคราะห์ตัวแปรที่ศึกษาแบบเป็นคู่ เนื่องจากสัมประสิทธิ์ของค่าความผิดพลาด (ε_i) ที่คำนวณได้เป็นค่าที่เกิดจากพจน์ความคลาดเคลื่อน ของตัวแปรเดียว Variance Decomposition (VD) เป็นวิธีการหนึ่งในการวิเคราะห์ภาพรวมในระบบ โดยจากแบบจำลอง VMA ที่ได้จากการหา IRF เราสามารถพยากรณ์ (Forecast) ตัวแปรได้ (หรือพยากรณ์จาก VAR หรือ VEC ก็ได้)

ดังนั้นส่วนประกอบของความแปรปรวนของความคลาดเคลื่อนของการพยากรณ์จะแสดงสัดส่วนการเคลื่อนไหวในหนึ่ง Sequence อันเนื่องมาจาก Shocks ของตัวแปรนั่นเอง เมื่อเทียบกับ Shocks อันเนื่องมาจากตัวแปรอื่น โดยการพิจารณาสัดส่วนของผลกระทบของตัวแปร