

บทที่ 4

วิธีการศึกษา

ในการศึกษาครั้งนี้ จะทำการศึกษาเชิงประจักษ์ โดยใช้ Vector Autoregressive Model (VAR) ซึ่งเป็นแบบจำลองที่ใช้กันอย่างแพร่หลายในงานศึกษาเกี่ยวกับนโยบายการเงิน เนื่องจากตัวแปรทางการเงินส่วนใหญ่มีลักษณะเป็นอนุกรมเวลาที่มีคุณสมบัติเป็น Nonstationary ซึ่งมีความผันผวนในแต่ละช่วงเวลาต่างกัน และผู้ศึกษาไม่ทราบลักษณะความสัมพันธ์ที่แท้จริงของตัวแปรต่างๆ ในแบบจำลอง แต่ทราบว่าตัวแปรต่างๆ ที่ใช้ในการศึกษามีความเกี่ยวข้องกันในทางทฤษฎี และมีความเกี่ยวข้องกับค่าในอดีต (Lagged value)

อย่างไรก็ดี แบบจำลอง VAR อาจจะได้ไม่ได้แสดงความสัมพันธ์ระหว่างตัวแปรต่างๆ อย่างชัดเจน ดังนั้น จึงต้องอาศัยเครื่องมืออื่นเพิ่มเติม เพื่อแสดงให้เห็นถึงความสัมพันธ์ระหว่างตัวแปรในภาพรวมได้ชัดเจนขึ้น โดยเครื่องมือที่จะนำมาใช้ศึกษาเพิ่มเติมในครั้งนี้ ได้แก่ การวิเคราะห์การตอบสนองของตัวแปร (Impulse Response Function) และการวิเคราะห์ขนาดของอิทธิพลของตัวแปรโดยการแยกส่วนความแปรปรวน (Variance Decomposition)

ในบทนี้จะเป็นการนำเสนอเนื้อหาของเครื่องมือแต่ละชนิด โดยเรียงลำดับตามขั้นตอนของเครื่องมือแต่ละชนิดที่นำมาใช้ ส่วนแรกจะกล่าวถึงลักษณะทั่วไปของแบบจำลอง VAR และการคัดเลือกกลุ่มตัวแปรที่นำมาใช้ในการศึกษาครั้งนี้ ส่วนที่สองจะอธิบาย Identification Problem จากการใช้แบบจำลอง VAR ส่วนที่สาม จะอธิบายรายละเอียดของการวิเคราะห์การตอบสนองของตัวแปร (Impulse Response Function) และส่วนที่สี่ จะเป็นการอธิบายรายละเอียดของการวิเคราะห์ขนาดของอิทธิพลของตัวแปรโดยการแยกส่วนความแปรปรวน (Variance Decomposition)

4.1. Vector Autoregressive Model (VAR)

แบบจำลอง Primitive VAR ที่มีตัวแปร Endogenous ทั้งหมด n ตัว มีลักษณะดังต่อไปนี้

$$(4.1) \quad By_t = \Gamma_0 + \sum_{i=1}^p \Gamma_i y_{t-i} + u_t$$

- โดยที่ y_t เป็นเวกเตอร์ตัวแปร Endogenous ขนาด $n \times 1$
 B คือ เมทริกซ์สัมประสิทธิ์ของตัวแปร endogenous ในเวลาปัจจุบัน (y_t) ที่มีขนาด $n \times n$ โดยพจน์ที่อยู่บนเส้นทแยงมุม (diagonal) เท่ากับ 1
 Γ_0 คือ เวกเตอร์ค่าคงที่ ขนาด $n \times 1$
 Γ_i คือ เมทริกซ์สัมประสิทธิ์ของตัวแปร Endogenous ในเวลาอดีต (y_{t-i}) ที่มีขนาด $n \times n$
 u_t คือ เวกเตอร์ของ Disturbance Term โดยมีคุณสมบัติ white noise ขนาด $n \times 1$

แบบจำลอง Primitive VAR ดังกล่าวยังไม่สามารถนำมาประมาณค่าแบบกำลังสองน้อยที่สุด (OLS) ได้ เพราะมี Contemporaneous Effects ระหว่างตัวแปร Endogenous (y_t) ด้วยกัน ทำให้ตัวแปรอิสระในแต่ละสมการมีความสัมพันธ์กับตัวรบกวน (Disturbance Term) ในสมการนั้น ดังนั้น การประมาณค่าโดยวิธี OLS จะทำให้ค่าประมาณของสัมประสิทธิ์มีลักษณะเป็น Biased และ Inconsistent เราจึงต้องปรับเปลี่ยนแบบจำลอง Primitive VAR ให้อยู่ในรูปแบบ Reduced form โดยการคูณ B^{-1} จะได้

$$(4.2) \quad y_t = A_0 + \sum_{i=1}^p A_i y_{t-i} + e_t$$

$$\text{โดย } A_0 = B^{-1}\Gamma_0$$

$$A_i = B^{-1}\Gamma_i$$

$$e_t = B^{-1}u_t$$

โดยที่ A_i คือ $A_i(L)$ ถูกกำหนดจากค่าในอดีต (Lagged Value) ของตัวเองและตัวแปร Endogenous ตัวอื่น

จะเห็นได้ว่า Contemporaneous Effects ระหว่างตัวแปร Endogenous (y_t) ได้ถูกขจัดออกไปเรียบร้อยแล้ว ดังนั้น การประมาณค่าสัมประสิทธิ์โดยวิธี OLS จะทำให้ค่าประมาณที่ได้มีลักษณะเป็น Unbiased และ Consistent

โดยทั่วไป ตัวแปรที่นำมาใส่ในแบบจำลอง VAR จะมี 2 ชนิด ได้แก่

1) ตัวแปร Endogenous คือกลุ่มตัวแปรที่เราต้องการหาความสัมพันธ์ซึ่งกันและกัน โดยตัวแปรกลุ่มนี้จะถูกกำหนดขึ้นจากทฤษฎีหรือแบบจำลองทางเศรษฐศาสตร์ที่เกี่ยวข้องกับเรื่องที่ต้องการศึกษา

2) ตัวแปร Exogenous คือกลุ่มตัวแปรทางนโยบายที่มีอิทธิพลต่อความสัมพันธ์ระหว่างตัวแปร Endogenous ทั้งหมด

เนื่องจากงานวิจัยชิ้นนี้ไม่ได้กำหนดให้มีตัวแปร Exogenous ดังนั้น สมการที่กำหนดขึ้นจึงมีเฉพาะตัวแปร Endogenous เท่านั้น

สำหรับตัวแปร Endogenous ที่ใช้ในการศึกษาค้นครั้งนี้ ประกอบด้วย

1. อัตราดอกเบี้ยซื้อคืนพันธบัตรระยะ 14 วัน (RP) ซึ่งเป็นอัตราดอกเบี้ยนโยบายที่ธนาคารแห่งประเทศไทยใช้เป็นเครื่องมือในการดำเนินนโยบายการเงิน

2. Log ของดัชนีค่าเงินบาทแท้จริง (Real Effective Exchange Rate ; REER) เป็นตัวแทนการดำเนินนโยบายการเงินผ่านช่องทางอัตราแลกเปลี่ยน

3. Log ของดัชนีราคาผู้บริโภค (CPI) ใช้ดัชนีราคาผู้บริโภคสินค้าพื้นฐาน ซึ่งตัดรายการอาหารและพลังงานออก เนื่องจากรายการดังกล่าวมีความผันผวนด้านราคาเข้ามาเกี่ยวข้อง

4. Log ของดัชนีผลผลิตอุตสาหกรรม (MPI) เป็นตัวแทนของผลิตภัณฑ์มวลรวมในประเทศ (GDP) ในการวัดการเจริญเติบโตของระดับผลผลิตภายในประเทศ เนื่องจากไม่สามารถหาข้อมูล GDP รายเดือนได้

5. Log ของมูลค่าการส่งออกแท้จริง (EX)

6. Log ของมูลค่านำเข้าแท้จริง (IM)

แบบจำลอง VAR ในรูปของ Reduced Form ในสมการ 4.2 สามารถนำมาเขียนในรูปเมตริกซ์ได้ดังนี้

$$(4.3) \quad \begin{bmatrix} y_{1t} \\ y_{2t} \\ \vdots \\ y_{nt} \end{bmatrix} = \begin{bmatrix} A_{10} \\ A_{20} \\ \vdots \\ A_{n0} \end{bmatrix} + \begin{bmatrix} A_{11}(L) & A_{12}(L) & \cdots & A_{1n}(L) \\ A_{21}(L) & A_{22}(L) & \cdots & A_{2n}(L) \\ \vdots & \vdots & \ddots & \vdots \\ A_{n1}(L) & A_{n2}(L) & \cdots & A_{nn}(L) \end{bmatrix} \begin{bmatrix} y_{1t-i} \\ y_{2t-i} \\ \vdots \\ y_{nt-i} \end{bmatrix} + \begin{bmatrix} e_{1t} \\ e_{2t} \\ \vdots \\ e_{nt} \end{bmatrix}$$

โดยที่ $A_{ij}(L)$ คือ The Polinomials in the Lag Operator L

สมการ 4.3 แสดงให้เห็นว่า ค่าของตัวแปร Endogenous ตัวหนึ่งจะถูกกำหนดจากค่าในอดีต (Lagged Values) ทั้งจากตัวของมันเองและตัวแปรอื่น ดังนั้น การกำหนดให้จำนวน Lag ที่มากขึ้น จะทำให้ความสามารถในการอธิบายพฤติกรรมเชิงพลวัตของแบบจำลอง VAR ในรูปของ Reduced Form สูงขึ้น แต่ในขณะเดียวกัน Degree of Freedom จะลดลง เนื่องจากค่าสัมประสิทธิ์ที่ถูกประมาณค่าจะสูงขึ้น ทำให้ผลการประมาณมีความน่าเชื่อถือลดลง ดังนั้น เราจึงต้องหาจำนวน Lag ที่เหมาะสม ซึ่งในงานวิจัยนี้ จะใช้วิธี Likelihood Ratio Test (LR Test)

4.1.1. การเลือกระดับ Lag ที่เหมาะสม

Likelihood Ratio Test (LR Test) เป็นการทดสอบนัยสำคัญทางสถิติ โดยการใช้ตัวสถิติแบบ Likelihood Ratio ที่มีการแจกแจงแบบ Chi-squared เพื่อทำการทดสอบหาจำนวน Lag ที่เหมาะสม ซึ่งมีรูปแบบสมการดังนี้

$$LR = (T - k)(\log |\Sigma_R| - \log |\Sigma_u|) \sim \chi^2(q)$$

โดยที่	T	คือ จำนวน Usable Observations ซึ่งเท่ากับจำนวนข้อมูลลบด้วยจำนวน Lag สูงสุดที่ใช้ในการประมาณค่า
	k	คือ จำนวนสัมประสิทธิ์และค่าคงที่ในแต่ละสมการของ Unrestricted Model
	$\log \Sigma_R $	คือ Logarithm ของ Determinant of Restricted Matrices of Cross Products of Residuals
	$\log \Sigma_u $	คือ Logarithm ของ Determinant of Unrestricted Matrices of Cross Products of Residuals
	q	คือ จำนวนของ Parameter Restrictions ของทุกสมการใน Reduced Form VAR Model

สำหรับการหาจำนวน Lag ที่เหมาะสม ในขั้นแรก เราต้องประมาณค่า Reduced Form VAR Model โดยใช้จำนวน Lag สูงสุด จากนั้น ประมาณค่า Reduced Form VAR Model อีกครั้งโดยใช้จำนวน Lag ที่ต่ำกว่า โดยมีสมมติฐานหลัก (Null Hypothesis) ว่า จำนวน Lag ที่ต่ำ

กว่าเป็น Lag ที่มีความเหมาะสม โดยที่ Reduced Form VAR Model ที่มี Lag สูงกว่าเป็น Unrestricted Model ส่วน Reduced Form VAR Model ที่มี Lag ต่ำกว่า เป็น Restricted Model หากค่าสถิติ LR ที่คำนวณได้มีค่าต่ำกว่าค่าวิกฤตอย่างมีนัยสำคัญ ก็สามารถสรุปได้ว่า จำนวน Lag ที่ต่ำกว่ามีความเหมาะสม และทำการทดสอบเช่นนี้ไปเรื่อยๆ โดยสมมติฐานหลัก (Null Hypothesis) ครั้งต่อไป คือ จำนวน Lag ที่ต่ำกว่าจำนวน Lag ที่ได้จากการทดสอบครั้งนี้มีความเหมาะสม เพื่อทำการหาจำนวน Lag ที่เหมาะสมต่อไป

แต่เนื่องจากแบบจำลอง VAR เป็นเครื่องมือที่ใช้สำหรับข้อมูลอนุกรมเวลา (Time Series Data) โดยมีข้อสมมติว่าข้อมูลอนุกรมเวลาที่ใช้จะต้องมีลักษณะเป็น Stationary โดยทั่วไปข้อมูลอนุกรมเวลาทางเศรษฐศาสตร์มหภาค (Macroeconomic Variables) ส่วนใหญ่จะมีลักษณะเป็น Nonstationary ซึ่งหากนำตัวแปรดังกล่าวมาประมาณค่าจะทำให้เกิดปัญหา Spurious Problem นั่นคือค่าสถิติที่ได้แสดงถึงความสัมพันธ์ที่ไม่เป็นจริง และเป็นค่าที่ไม่น่าเชื่อถือ ดังนั้น เราจึงต้องทำการทดสอบคุณสมบัติ Stationary ของตัวแปรก่อน

4.1.2. การทดสอบคุณสมบัติ Stationary

อนุกรมเวลาของตัวแปรจะมีคุณสมบัติ Stationary เมื่อ

1. $E(y_t) = E(y_{t+m}) = \mu_x$: ค่าเฉลี่ย (Mean) มีค่าคงที่ ไม่เปลี่ยนแปลงตามเวลา
2. $\text{Var}(y_t) = \text{Var}(y_{t+m}) = \sigma_x^2$: ความแปรปรวน (Variance) มีค่าคงที่ ไม่เปลี่ยนแปลงตามเวลา
3. $\text{Cov}(y_t, y_{t+m}) = \text{Cov}(y_t, y_{t+k+m}) = \gamma_k$: ความแปรปรวนร่วม (Covariance) มีค่าคงที่ ไม่เปลี่ยนแปลงตามเวลา

การทดสอบคุณสมบัติ Stationary จะใช้วิธี Unit Root Test ซึ่งสามารถทดสอบโดยใช้การทดสอบ DF (Dickey-Fuller Test) ซึ่งเป็นการทดสอบที่อาศัยแนวคิดพื้นฐานจากแบบจำลอง Autoregressive Model โดยใช้สมการดังต่อไปนี้

$$(4.4) \quad y_t = \rho y_{t-1} + u_t$$

โดยที่ y_t คือ ตัวแปรอนุกรมที่ต้องการศึกษา
 ρ คือ สัมประสิทธิ์ของตัวแปรล่าช้า (Lagged) ของอนุกรมเวลา y_t
 ε_t คือ ค่าความคลาดเคลื่อน (Error Term) ที่มีลักษณะ White Noise
 นั่นคือ $\varepsilon_t \sim N(0, \sigma^2)$

การทดสอบ Stationary พิจารณาจากค่าสัมประสิทธิ์ของตัวแปรล่าช้า (ρ) โดยมีเงื่อนไขคือ

1. ถ้า $|\rho| < 1$ แสดงว่า y_t มีลักษณะ Stationary
2. ถ้า $|\rho| \geq 1$ แสดงว่า y_t มีลักษณะ Nonstationary

สมมติฐานที่ใช้ในการทดสอบสมการ คือ

$H_0 : \rho = 1$ (y_t มีลักษณะ Nonstationary)

$H_1 : \rho < 1$ (y_t มีลักษณะ Stationary)

การทดสอบนี้สามารถทำได้อีกทางหนึ่งโดยการเปลี่ยนสมการที่ 4.4 ดังนี้

$$(4.5) \quad y_t = (1 + \theta)y_{t-1} + u_t$$

โดยที่ $\rho = (1 + \theta)$

จากสมการที่ 4.5 จะได้

$$(4.6) \quad \Delta y_t = \theta y_{t-1} + u_t$$

สมมติฐานที่ใช้ในการทดสอบสมการ คือ

$H_0 : \theta = 0$ (y_t มีลักษณะ Nonstationary)

$H_1 : \theta < 0$ (y_t มีลักษณะ Stationary)

ถ้า y_t มีลักษณะ Random walk with drift เราจะสามารถเขียนแบบจำลองที่ใช้ในการทดสอบสมมติฐาน คือ

$$(4.7) \quad \Delta y_t = \alpha + \theta y_{t-1} + u_t$$

ถ้า y_t มีลักษณะ Random walk with drift และมีลักษณะ Linear time trend รวมอยู่ด้วย เราจะสามารถเขียนแบบจำลองที่ใช้ในการทดสอบสมมติฐาน คือ

$$(4.8) \quad \Delta y_t = \alpha + \beta t + \theta y_{t-1} + u_t$$

โดยที่ t คือ เวลา

ซึ่งทั้ง 2 สมการ (4.7 และ 4.8) ก็จะใช้การทดสอบสมมติฐานเช่นเดียวกับสมการที่ 4.6 ซึ่งมีสมมติฐานว่า $H_0 : \theta = 0$ โดยที่ $H_1 : \theta < 0$ โดยการเปรียบเทียบค่าสถิติ t (t-statistic) ที่คำนวณได้กับค่าที่เหมาะสมที่อยู่ในตาราง Dickey-Fuller หรือกับค่าวิกฤติ MacKinnon

ข้อด้อยของ Dickey-Fuller Test คือ การเพิกเฉยปัญหา Autocorrelation ดังนั้น Dickey และ Fuller จึงแก้ปัญหาดังกล่าวด้วยการใช้ Autoregressive Processes โดยนำค่า Lag ของ Δy_t ไปใส่ไว้ในสมการ ดังนี้

$$(4.9) \quad \Delta y_t = \theta y_{t-1} + \sum_{i=1}^p \phi \Delta y_{t-i} + u_t$$

$$(4.10) \quad \Delta y_t = \alpha + \theta y_{t-1} + \sum_{i=1}^p \phi \Delta y_{t-i} + u_t$$

$$(4.11) \quad \Delta y_t = \alpha + \beta t + \theta y_{t-1} + \sum_{i=1}^p \phi \Delta y_{t-i} + u_t$$

อย่างไรก็ดี จำนวนของ Lagged difference terms ที่จะนำเข้ามารวมในสมการนั้นจะมีมากพอที่ทำให้พจน์ค่าความคลาดเคลื่อน (error term) มีลักษณะเป็น serially independent และเมื่อนำเอากการทดสอบ Dickey-Fuller มาใช้กับสมการที่ 4.9 - 4.11 เราจะเรียกการทดสอบนี้ว่า Augmented Dickey-Fuller Test (ADF) ซึ่งค่าสถิติที่ใช้ในการทดสอบจะมีการแจกแจงเหมือนกับสถิติ DF ดังนั้นเราก็สามารถใช้ค่าวิกฤติแบบเดียวกัน

4.2 Identification Problem

Impulse Response Function และ Variance Decomposition เป็นเครื่องมือที่นำเอาความสัมพันธ์ระหว่างตัวแปรใน Endogenous ใน Primitive VAR Model ไปใช้ในการศึกษา ดังนั้นจึงต้องนำค่าที่ประมาณได้จาก Reduced Form VAR Model ไปใช้หาค่าประมาณใน Primitive VAR Model ก่อน

ในสมการที่ 4.2 ซึ่งเป็นสมการ Reduce Form ค่า $e_t = B^{-1}u_t$ ดังนั้น $u_t = Be_t$ เป้าหมายของเรา คือ การหาค่า u_t ซึ่งเป็นเวกเตอร์ของตัวรบกวน (Disturbance Term) ใน Primitive VAR Model ถ้าค่าดังกล่าวหาได้ Primitive VAR Model จะมีลักษณะ Identified

เมื่อใช้วิธี OLS กับ Reduced Form VAR Model จะได้ Variance Covariance Matrix ของ $e_t (\Sigma_e)$ ดังต่อไปนี้ (สมมติให้ตัวแปร Endogenous จำนวน 6 ตัวแปร)

$$\Sigma_e = \begin{bmatrix} \text{Var}(e_{1t}) & \text{Cov}(e_{2t}, e_{1t}) & \text{Cov}(e_{3t}, e_{1t}) & \text{Cov}(e_{4t}, e_{1t}) & \text{Cov}(e_{5t}, e_{1t}) & \text{Cov}(e_{6t}, e_{1t}) \\ \text{Cov}(e_{1t}, e_{2t}) & \text{Var}(e_{2t}) & \text{Cov}(e_{3t}, e_{2t}) & \text{Cov}(e_{4t}, e_{2t}) & \text{Cov}(e_{5t}, e_{2t}) & \text{Cov}(e_{6t}, e_{2t}) \\ \text{Cov}(e_{1t}, e_{3t}) & \text{Cov}(e_{2t}, e_{3t}) & \text{Var}(e_{3t}) & \text{Cov}(e_{4t}, e_{3t}) & \text{Cov}(e_{5t}, e_{3t}) & \text{Cov}(e_{6t}, e_{3t}) \\ \text{Cov}(e_{1t}, e_{4t}) & \text{Cov}(e_{2t}, e_{4t}) & \text{Cov}(e_{3t}, e_{4t}) & \text{Var}(e_{4t}) & \text{Cov}(e_{5t}, e_{4t}) & \text{Cov}(e_{6t}, e_{4t}) \\ \text{Cov}(e_{1t}, e_{5t}) & \text{Cov}(e_{2t}, e_{5t}) & \text{Cov}(e_{3t}, e_{5t}) & \text{Cov}(e_{4t}, e_{5t}) & \text{Var}(e_{5t}) & \text{Cov}(e_{6t}, e_{5t}) \\ \text{Cov}(e_{1t}, e_{6t}) & \text{Cov}(e_{2t}, e_{6t}) & \text{Cov}(e_{3t}, e_{6t}) & \text{Cov}(e_{4t}, e_{6t}) & \text{Cov}(e_{5t}, e_{6t}) & \text{Var}(e_{6t}) \end{bmatrix}$$

เนื่องจาก Σ_e เป็น Symmetric Matrix ดังนั้นเราจะได้พจน์ที่มีค่าต่างกันจำนวน 21 ค่า รวมกับค่าจากเมตริกซ์ A_0 6 ค่า และจากเมตริกซ์ A_i 36 ค่า เป็นค่าที่ทราบจาก Reduce Form ทั้งหมด 63 ค่า โดยค่าเหล่านี้จะถูกใช้เพื่อประมาณค่าหาตัวแปรที่ไม่ทราบค่า (Unknown Variables) ใน Primitive VAR Model จำนวน 84 ค่า ซึ่งประกอบด้วยค่าสัมประสิทธิ์จากเมตริกซ์ B 36 ค่า, จากเมตริกซ์ Γ_0 6 ค่า, จากเมตริกซ์ Γ_i 36 ค่า, และ $\text{Var}(u_t)$ จำนวน 6 ค่า ดังนั้น Primitive VAR Model จะมีลักษณะ Underidentified เพราะจำนวนตัวแปรที่ไม่ทราบค่า (Unknown Variables) มีมากกว่าตัวแปรที่ทราบค่า

เพื่อแก้ปัญหาดังกล่าว จึงต้องใช้เทคนิค Choleski Decomposition โดยกำหนดให้พจน์ต่างๆ ที่อยู่ใต้เส้นทแยงมุมของเมตริกซ์ B เท่ากับศูนย์ (เมตริกซ์ B เป็น upper triangular matrix) ซึ่งเงื่อนไขที่กำหนดโดย Choleski Decomposition นี้ จะบอกถึงการเรียงลำดับ (ordering) ของตัวแปรว่าตัวแปรใดมีผลทางตรงต่อตัวแปรอื่นๆ มากที่สุดจะอยู่ในลำดับสุดท้าย

ถัดขึ้นมาเป็นตัวแปรที่มีผลทางตรงต่อตัวแปรอื่นๆ ในจำนวนที่ลดหลั่นกัน

สำหรับการลำดับตัวแปร (ordering) งานศึกษาเชิงประจักษ์ที่เกี่ยวข้องกับการดำเนินนโยบายการเงินผ่านช่องทางอัตราแลกเปลี่ยนส่วนใหญ่จะเรียงลำดับตัวแปรดังนี้คือ ตัวแปรด้านผลผลิต ตัวแปรด้านราคา อัตราดอกเบี้ย และอัตราแลกเปลี่ยน ซึ่งในงานศึกษาค้างนี้ได้เพิ่มตัวแปรการนำเข้าและการส่งออกเข้าไป ซึ่งคล้ายกับงานของ Cushman and Zha (1997) ดังนั้น การเรียงลำดับจึงคล้ายกับงานศึกษาดังกล่าว โดยมีแนวคิดว่ำนโยบายการเงินจะตอบสนองอย่างทันทีทันใดต่อตัวแปรภายในประเทศก่อน ดังนั้น การกำหนดอัตราดอกเบี้ยนโยบายของธนาคารกลางจะไม่ได้กำหนดเพื่อตอบสนองต่อการเปลี่ยนแปลงของอัตราแลกเปลี่ยนทันที แต่จะพิจารณาจากการเปลี่ยนแปลงของระดับผลผลิต และระดับราคาก่อน ขณะที่อัตราแลกเปลี่ยนจะตอบสนองต่อการเปลี่ยนแปลงของอัตราดอกเบี้ยนโยบายทันที ดังนั้นจึงจัดให้ตัวแปรอัตราแลกเปลี่ยนอยู่เป็นอันดับท้าย ส่วนตัวแปรการนำเข้า และการส่งออกที่เพิ่มเข้ามานั้นจะจัดให้อยู่ในลำดับแรก เนื่องจากการนำเข้าและการส่งออกได้รับผลกระทบเป็นอันดับท้ายๆ ดังนั้น การเรียงลำดับของข้อมูลในการศึกษาค้างนี้จึงเป็นดังนี้ คือ มูลค่าการนำเข้าแท้จริง (IM), มูลค่าการส่งออกแท้จริง (EX), ดัชนีผลผลิตอุตสาหกรรม (MPI), ดัชนีราคาผู้บริโภคพื้นฐาน (CPI), อัตราดอกเบี้ยซื้อคืนพันธบัตรระยะ 14 วัน (RP) และ ดัชนีค่าเงินบาทแท้จริง (REER)

จากการเรียงลำดับ (ordering) ดังกล่าว จะได้แบบจำลองซึ่งสามารถเขียนอยู่ในรูปเมทริกซ์ โดยมี lagged value เท่ากับ i ได้ดังนี้

$$\begin{bmatrix} IM \\ EX \\ MPI \\ CPI \\ RP \\ REER \end{bmatrix} = \begin{bmatrix} A_{10} \\ A_{20} \\ A_{30} \\ A_{40} \\ A_{50} \\ A_{60} \end{bmatrix} + \begin{bmatrix} A_{11}(L) & A_{12}(L) & A_{13}(L) & A_{14}(L) & A_{15}(L) & A_{16}(L) \\ A_{21}(L) & A_{22}(L) & A_{23}(L) & A_{24}(L) & A_{25}(L) & A_{26}(L) \\ A_{31}(L) & A_{32}(L) & A_{33}(L) & A_{34}(L) & A_{35}(L) & A_{36}(L) \\ A_{41}(L) & A_{42}(L) & A_{43}(L) & A_{44}(L) & A_{45}(L) & A_{46}(L) \\ A_{51}(L) & A_{52}(L) & A_{53}(L) & A_{54}(L) & A_{55}(L) & A_{56}(L) \\ A_{61}(L) & A_{62}(L) & A_{63}(L) & A_{64}(L) & A_{65}(L) & A_{66}(L) \end{bmatrix} \begin{bmatrix} IM_{t-i} \\ EX_{t-i} \\ MPI_{t-i} \\ CPI_{t-i} \\ RP_{t-i} \\ REER_{t-i} \end{bmatrix} + \begin{bmatrix} e_{IM_t} \\ e_{EX_t} \\ e_{MPI_t} \\ e_{CPI_t} \\ e_{RP_t} \\ e_{REER_t} \end{bmatrix}$$

4.3 Impulse Response Function

การวิเคราะห์ด้วยวิธี Impulse Response Function มีวัตถุประสงค์เพื่อทราบว่าการเปลี่ยนแปลงของตัวแปรซึ่งวัดในรูป One Standard Deviation มีผลกระทบต่อตัวแปรอื่นๆ ในระบบทั้งในช่วงเวลาเดียวกันและช่วงเวลาในอนาคตอย่างไร นั่นคือ เป็นการวัดผลกระทบจาก Shock ของตัวแปรใดๆ ในแบบจำลองที่มีต่อตัวแปรอื่นๆ ในช่วงเวลาเดียวกันและช่วงเวลาต่างๆ ในอนาคต

จากสมการ 4.2 เราสามารถเขียน VAR Model ให้อยู่ในรูป Vector Moving Average (VMA) ที่ตัวแปรต่างๆ จะถูกกำหนดจากค่าคงที่และตัวรบกวน (Disturbance Terms) ได้ดังนี้

$$(4.12) \quad y_t = \bar{y} + \sum_{i=0}^{\infty} A_i e_{t-i}$$

$\bar{y}$ คือ เวกเตอร์ของค่าดุลยภาพ (Steady state) ของตัวแปร Endogenous แต่ละตัว ดังนั้น สมการ 4.12 ทำให้ทราบว่า การที่ค่าในปัจจุบันของตัวแปร Endogenous แตกต่างจากค่าที่ดุลยภาพในระยะยาว (steady state) เพราะการเกิดเหตุการณ์ที่ไม่สามารถคาดการณ์ได้ (Shocks) ในตัวแปร Endogenous แต่ละตัวนั่นเอง

จากสมการ 4.12 จะได้

$$(4.13) \quad y_t = \bar{y} + \sum_{i=0}^{\infty} A_i B^{-1} u_{t-i}$$

หรือ

$$(4.14) \quad y_t = \bar{y} + \sum_{i=0}^{\infty} \phi_i u_{t-i}$$

$$\text{โดย } \phi_i = AB^{-1}$$

จากสมการ 4.14 เราสามารถเขียนให้อยู่ในรูปเมตริกซ์ได้ดังนี้

$$\begin{bmatrix} IM \\ EX \\ MPI \\ CPI \\ RP \\ REER \end{bmatrix} = \begin{bmatrix} \overline{IM} \\ \overline{EX} \\ \overline{MPI} \\ \overline{CPI} \\ \overline{RP} \\ \overline{REER} \end{bmatrix} + \sum_{i=0}^{\infty} \begin{bmatrix} \phi_{11}(i) & \phi_{12}(i) & \phi_{13}(i) & \phi_{14}(i) & \phi_{15}(i) & \phi_{16}(i) \\ \phi_{21}(i) & \phi_{22}(i) & \phi_{23}(i) & \phi_{24}(i) & \phi_{25}(i) & \phi_{26}(i) \\ \phi_{31}(i) & \phi_{32}(i) & \phi_{33}(i) & \phi_{34}(i) & \phi_{35}(i) & \phi_{36}(i) \\ \phi_{41}(i) & \phi_{42}(i) & \phi_{43}(i) & \phi_{44}(i) & \phi_{45}(i) & \phi_{46}(i) \\ \phi_{51}(i) & \phi_{52}(i) & \phi_{53}(i) & \phi_{54}(i) & \phi_{55}(i) & \phi_{56}(i) \\ \phi_{61}(i) & \phi_{62}(i) & \phi_{63}(i) & \phi_{64}(i) & \phi_{65}(i) & \phi_{66}(i) \end{bmatrix} \begin{bmatrix} u_{IM_t} \\ u_{EX_t} \\ u_{MPI_t} \\ u_{CPI_t} \\ u_{RP_t} \\ u_{REER_t} \end{bmatrix}$$

เราเรียก $\phi_{jk}(i)$ ว่า Impulse Response Function โดย $\phi_{45}(0)$ คือ ตัวคูณผลกระทบ (impact multiplier) หมายถึง ผลกระทบที่เกิดขึ้นทันทีทันใดของ shock ใน RP ที่มีต่อ CPI และ $\phi_{45}(1)$ หมายถึงผลกระทบของ shock ใน RP_{t-1} ที่มีต่อ CPI_t หรือผลกระทบของ shock ใน RP_t ที่มีต่อ CPI_{t+1} ดังนั้น กราฟที่มีแกนตั้ง คือ $\phi_{45}(i)$ และแกนนอน คือ เวลา i จะแสดงถึงการตอบสนองในอนาคตของ CPI ที่มีต่อ shock ที่เกิดขึ้นในปัจจุบันของ RP ดังนั้น ผู้วิจัยจึงสามารถทราบการตอบสนองของตัวแปรตัวหนึ่งๆ ที่มีต่อตัวแปรอื่นๆ ได้

4.4 Variance Decomposition

Variance Decomposition คือ เครื่องมือที่วิเคราะห์ว่าในช่วงเวลาหนึ่ง ความผันผวนของตัวแปร Endogenous ตัวหนึ่งๆ จะมีอิทธิพลมาจากความผันผวนในตัวเองและตัวแปรอื่นๆ เป็นสัดส่วนเท่าใด

จากสมการที่ 4.14 กรณี n คาบเวลา จะได้

$$(4.15) \quad y_{t+n} = \bar{y} + \sum_{i=0}^{\infty} \phi_i u_{t+n-i}$$

ดังนั้น ความคลาดเคลื่อนของการพยากรณ์ n คาบเวลาไปข้างหน้า (n -period forecast error) สามารถเขียนได้ดังนี้

$$(4.16) \quad y_{t+n} - E_t y_{t+n} = \sum_{i=0}^{n-1} \phi_i u_{t+n-i}$$

ถ้าเราพิจารณาเฉพาะ $\{y_{i,t}\}$ sequence (ตัวแปรตัวหนึ่งในเวกเตอร์ y) เท่านั้น เราจะได้ความคลาดเคลื่อนของการพยากรณ์ n คาบเวลาไปข้างหน้า (n -step ahead forecast error) ดังนี้

$$(4.17) \quad y_{i,t+n} - E_t y_{i,t+n} = \phi_{11}(0)u_{y_{i,t+n}} + \phi_{11}(1)u_{y_{i,t+n-1}} + \dots + \phi_{11}(n-1)u_{y_{i,t+1}} \\ + \phi_{12}(0)u_{y_{j,t+n}} + \phi_{12}(1)u_{y_{j,t+n-1}} + \dots + \phi_{12}(n-1)u_{y_{j,t+1}}$$

ถ้าเราให้ $\sigma_y(n)^2$ คือ ความแปรปรวนของความคลาดเคลื่อนของการพยากรณ์ n คาบเวลาไปข้างหน้า เราจะได้ว่า

$$(4.18) \quad \sigma_y(n)^2 = \sigma_{y_i}^2 [\phi_{11}(0)^2 + \phi_{11}(1)^2 + \dots + \phi_{11}(n-1)^2] \\ + \sigma_{y_j}^2 [\phi_{12}(0)^2 + \phi_{12}(1)^2 + \dots + \phi_{12}(n-1)^2]$$

เนื่องจากทุกค่าของ $\phi_{jk}(i)^2$ มีค่าไม่เป็นลบ ความแปรปรวนของความคลาดเคลื่อนของการพยากรณ์จะเพิ่มขึ้นเมื่อ n เพิ่มขึ้น ดังนั้น เราสามารถแยกส่วนประกอบความแปรปรวนของความคลาดเคลื่อนของการพยากรณ์ n คาบเวลาไปข้างหน้าเนื่องจาก shock ตัวอื่นๆ ได้ ดังนี้

สัดส่วนของ $\sigma_y(n)^2$ เนื่องจาก shock จาก y_i เท่ากับ

$$\frac{\sigma_{y_i}^2 [\phi_{11}(0)^2 + \phi_{11}(1)^2 + \dots + \phi_{11}(n-1)^2]}{\sigma_y(n)^2}$$

สัดส่วนของ $\sigma_y(n)^2$ เนื่องจาก shock จาก y_j เท่ากับ

$$\frac{\sigma_{y_j}^2 [\phi_{12}(0)^2 + \phi_{12}(1)^2 + \dots + \phi_{12}(n-1)^2]}{\sigma_y(n)^2}$$

ส่วนประกอบของความแปรปรวนของความคลาดเคลื่อนของการพยากรณ์ (forecast error variance decomposition) จะบอกเราว่าในการเคลื่อนไหวใน sequence มาจาก shock จากตัวมันเองในสัดส่วนเท่าใดเมื่อเทียบกับตัวแปรอื่น

จะเห็นได้ว่า วิธีดังกล่าวจะทำให้เราทราบเพียงสัดส่วนของตัวแปรที่ทำการศึกษาเท่านั้น แต่เราไม่ทราบทิศทางของการตอบสนองของตัวแปรในระบบ ดังนั้น Impulse Response Functions จึงเป็นเครื่องมือที่ช่วยแก้ไขข้อจำกัดที่เกิดขึ้น

ดังนั้น การนำเครื่องมือทั้งการวิเคราะห์การตอบสนองของตัวแปร (Impulse Response Function) และการวิเคราะห์ขนาดของอิทธิพลของตัวแปรโดยการแยกส่วนความแปรปรวน (Variance Decomposition) มาใช้ในงานศึกษาแบบจำลอง VAR จะทำให้ทราบทั้งทิศทางและขนาดของผลกระทบที่เกิดขึ้นจากตัวแปรที่เราสนใจศึกษาต่อตัวแปรอื่นๆ ได้ชัดเจนขึ้น

