

บทที่ 4

ระเบียบวิธีการศึกษา

เนื่องจากข้อมูลที่นำมาใช้ในการศึกษาเป็นข้อมูลอนุกรมเวลา ซึ่งในการวิเคราะห์ข้อมูลที่เป็นอนุกรมเวลา (time series) สิ่งที่เราจำเป็นต้องพิจารณาก็คือข้อมูลนั้นเป็นข้อมูลที่เป็นลักษณะนิ่งหรือไม่ เพราะข้อมูลอนุกรมเวลาที่จะสามารถนำไปวิเคราะห์จะต้องมีลักษณะนิ่งซึ่งหากไม่ทำการตรวจสอบจะทำให้เกิดปัญหา non – stationary ได้

ในการศึกษาครั้งนี้ผู้เขียนได้ใช้วิธีการวิเคราะห์ข้อมูลแบบ GARCH ซึ่งเป็นเครื่องมือที่ใช้วิเคราะห์ข้อมูลที่มีความแปรปรวนของพจน์ความคลาดเคลื่อนมีลักษณะไม่คงที่ในการหาผลกระทบของความผันผวนของตัวแปรทางเศรษฐกิจมหภาคที่มีต่อความผันผวนของการส่งออก และการลงทุนโดยตรงจากต่างประเทศ

ขั้นตอนในการวิเคราะห์ข้อมูล

- 1) ใช้แบบจำลอง GARCH หาค่าความผันผวนของปัจจัยทางเศรษฐกิจมหภาค เพื่อนำมาเป็นตัวแปรในการศึกษาผลกระทบที่เกิดขึ้นในความผันผวนของการส่งออก และการลงทุน
- 2) ทำการทดสอบ Unit Root Test ด้วยวิธีของ Dickey and Fuller เพื่อทดสอบระดับความนิ่งของข้อมูล
- 3) ทำการทดสอบปัจจัยที่ส่งผลกระทบต่อความผันผวนของตัวแปรในแบบจำลองโดยใช้ GARCH

4.1 การทดสอบ Unit Root

ก่อนอื่นเราต้องทดสอบก่อนว่า ตัวแปรที่อาศัยข้อมูลอนุกรมเวลาที่เราใช้มีลักษณะนิ่ง (Stationary) หรือไม่ โดยที่เรานิยามความหมายของคำว่า “นิ่ง” ไว้ดังนี้

กระบวนการเฟ้นสุ่ม (X_t) จะถูกเรียกว่า “นิ่ง” (Stationary) ถ้า

1. Mean : $E(x_t) = \text{constant} = \mu$
2. Variance : $V(x_t) = \text{constant} = \sigma^2$
3. Covariance : $COV(x_t, x_{t+k}) = E(x_t - \mu)(x_{t+k} - \mu) = \sigma_k - \mu$

ซึ่งถ้าค่าเฉลี่ย (Means) และความแปรปรวนมีค่าคงที่เมื่อเวลาเปลี่ยนไป ในขณะที่ค่าความแปรปรวนร่วมเกี่ยว (Covariance) ระหว่างสองคาบเวลาขึ้นอยู่กับช่องว่าง (Gap) ระหว่างคาบเวลาเท่านั้นไม่ได้ขึ้นอยู่กับเวลาที่เกิดขึ้นจริง จะเรียกได้ว่า ตัวแปรนั้นมีลักษณะนิ่ง แต่ถ้าหากเงื่อนไขใดเงื่อนไขหนึ่งไม่เป็นไปตามที่กล่าวมา กระบวนการเฟ้นสุ่มดังกล่าว จะถูกเรียกว่า มีลักษณะ “ไม่นิ่ง” (Non-Stationary)

ในการทดสอบว่าตัวแปรแต่ละตัวมีลักษณะนิ่งหรือไม่นั้น เราใช้วิธีการทดสอบที่เรียกว่า Unit root การทดสอบ Unit Root หรือ อันดับความสัมพันธ์ของข้อมูล (Orders of Integration) ที่นิยมใช้กันอยู่ในปัจจุบันมีอยู่ 2 วิธี คือ

1) วิธีการทดสอบของ Dickey and Fuller (1979, 1981) เนื่องจากวิธีการทดสอบของ Dickey and Fuller (1979, 1981) มักจะนิยมประยุกต์ใช้กับนักศึกษาที่มีจำนวนข้อมูลไม่มากนัก (Dejong et al. 1992) โดย Dickey and Fuller (1979, 1981) ได้เสนอวิธีการทดสอบ Unit Root ไว้ 2 วิธี คือ การทดสอบ DF (Dickey-Fuller (DF) test) และการทดสอบ ADF (Augmented Dickey-Fuller (ADF) test) ซึ่งทั้งสองมีลักษณะคล้ายกัน เพียงแต่การทดสอบ ADF จะสามารถทดสอบค่า Unit Root ได้ดีกว่าโดยเฉพาะอย่างยิ่งในกรณีที่ ตัวแปรสุ่ม มีความสัมพันธ์กันในอันดับที่สูงขึ้น (Higher-order Autoregressive Moving Average Processes)

2) วิธีการทดสอบของ Phillips and Perron (1988) : เป็นอีกวิธีหนึ่งในการทดสอบ Stationary ของตัวแปร

การทดสอบ Unit Root แบบ Dickey and Fuller (1979)

วิธีที่ใช้กันอย่างแพร่หลายที่เสนอโดย Dickey and Fuller (1979) คือ สมมติว่ามีค่าสังเกต n ค่า ดังนี้ X_1, X_2, \dots, X_n ซึ่งค่าสังเกต ณ เวลาปัจจุบัน อธิบายได้ในเทอมของค่าสังเกตในอดีตหนึ่งหน่วยเวลาข้างหน้า และตัวแปรถวนสุ่ม ณ เวลาปัจจุบัน เรียกว่า กระบวนการ First-Order Autoregressive : AR(1) ดังนี้

$$x_t = \rho(x_{t-1}) + \varepsilon_t \quad ; \quad t = 1, 2, \dots \quad (4.1)$$

เมื่อ ρ = จำนวนจริง
 $\{\varepsilon_t\}$ = ลำดับของตัวรบกวนสุ่มที่เป็นอิสระจากกัน โดยมีการแจกแจงแบบปกติ
 ที่มีค่าเฉลี่ยเท่ากับ 0 และความแปรปรวน คือ σ^2 ($\varepsilon_t \sim NID(0, \sigma^2)$)

โดยมีสมมติฐานที่ใช้ในการทดสอบ ดังนี้

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

$$H_1 : |\rho| < 0 \quad (\text{Stationary})$$

นั่นคือ ถ้ายอมรับ H_0 แสดงว่า อนุกรมเวลามีคุณสมบัติ “ไม่นิ่ง” (Non-stationary) และความแปรปรวนของ $X_t = t\sigma^2$ กรณีนี้ เรียกว่า Random Walk ซึ่งสามารถแปลงให้มีคุณสมบัติ stationary ด้วยการหาผลต่าง ถ้าปฏิเสธ H_0 แสดงว่า X_t จะลู่เข้าหาอนุกรมเวลาที่มีคุณสมบัติ Stationary (เมื่อ t เพิ่มขึ้นอย่างไม่มีการสิ้นสุด)

ถ้าการทดสอบครั้งแรก พบว่า ตัวแปร x_t มีลักษณะเป็น Non-stationary สามารถทำการทดสอบต่อมาในรูปแบบผลต่าง (Δx_t) ซึ่งลักษณะคล้ายสมการที่ (4.1) ดังนี้

$$\Delta x_t = \theta(x_{t-1}) + \varepsilon_t \quad (\text{Random Walk Process}) \quad (4.2)$$

$$\Delta x_t = \alpha + \theta(x_{t-1}) + \varepsilon_t \quad (\text{Random Walk with Drift}) \quad (4.3)$$

$$\Delta x_t = \alpha + \beta t + \theta(x_{t-1}) + \varepsilon_t \quad (\text{Random Walk with Drift and Time Trend}) \quad (4.4)$$

โดยที่ $\rho = 1 + \theta$ หรือ $\theta = \rho - 1$ และ $t =$ เวลา

ซึ่งจากทั้ง 3 สมการข้างต้น นำมาทดสอบ โดยมีสมมติฐานว่า

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

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

วิธีการดูว่า X_t จะมี Unit root หรือไม่ โดยการเปรียบเทียบค่าสถิติ t (t-statistic) ที่คำนวณได้กับค่าที่เหมาะสมที่อยู่ในตาราง Dickey-Fuller (Dickey-Fuller table) ซึ่งวิธีการนี้เรียกว่า เป็นการทดสอบ DF (Dickey-Fuller Test)

ส่วนอีกวิธีเป็นการทดสอบ ADF (Augmented Dickey-Fuller Test) โดยการแปลงสมการที่ (4.2), (4.3), (4.4) ให้ถูกแทนที่ด้วยกระบวนการเชิงอัตถคอดอย (Autoregressive Process) โดยการเพิ่มตัวแปรในรูป Lag เข้าไปเป็นตัวแปรอธิบายตัวหนึ่ง เพื่อไม่ให้เกิดปัญหาเรื่อง Autocorrelation ของตัวรบกวนสุ่ม เนื่องจากจำนวน Lagged Difference Term ที่จะนำมารวมในสมการนั้นจะมีมากพอที่จะทำให้พจน์ค่าความคลาดเคลื่อน (Error Terms) มีลักษณะเป็น Serially Independent จะได้เป็นสมการที่ (4.5), (4.6), (4.7) ดังนี้

$$\Delta x_t = \theta x_{t-1} + \sum_{i=1}^p \phi \Delta x_{t-i} + \varepsilon_t \quad (4.5)$$

$$\Delta x_t = \alpha + \theta x_{t-1} + \sum_{i=1}^p \phi \Delta x_{t-i} + \varepsilon_t \quad (4.6)$$

$$\Delta x_t = \alpha + \beta t + \theta x_{t-1} + \sum_{i=1}^p \phi \Delta x_{t-i} + \varepsilon_t \quad (4.7)$$

โดยที่ p คือ ความล่าช้าที่เหมาะสม (Optimal Lag) หรือจำนวนตัวแปรในรูป lag ที่มีความเหมาะสม ที่ทำให้ตัวรบกวนสุ่มในสมการไม่เกิดปัญหา Autocorrelation

และเมื่อนำเอาการทดสอบ DF มาใช้กับสมการข้างต้น (4.5)-(4.7) เราจะเรียกว่าเป็นการทดสอบ ADF โดยค่าสถิติทดสอบ ADF จะมีการแจกแจงเส้นกำกับ (Asymptotic Distribution) มีลักษณะเหมือนกับสถิติ DF

ดังนั้นในการทดสอบ Unit root ทำให้เราทราบลักษณะความนิ่งของตัวแปร ถ้าตัวแปรมีลักษณะไม่นิ่ง ก็พยายามหา Order of Integration ในลำดับที่ทำให้ตัวแปรมีลักษณะนิ่ง เพื่อนำไปทดสอบในขั้นถัดมา

ในการศึกษาครั้งนี้จะใช้ทดสอบ Unit Root ที่นำเสนอโดย Dickey and Fuller (1979) ซึ่งเป็นการทดสอบแบบ ADF test โดยสมการที่ใช้ในการทดสอบครั้งนี้ คือ สมการที่ (4.5)-(4.7) ตัวแปรที่ใช้ในการทดสอบความนิ่ง (Stationary) สามารถนำมาทดสอบในขั้นต่อไป ด้วย GARCH ได้

4.2 แบบจำลองที่ใช้วิเคราะห์ความแปรปรวน

1) แบบจำลอง Autoregressive Conditional Heteroscedasticity (ARCH)

ในการวิเคราะห์อนุกรมเวลาส่วนใหญ่แล้วจะมีการกำหนด stochastic variable ให้มีความแปรปรวนคงที่ (homoscedastic) ซึ่งในการประยุกต์ใช้กับบางข้อมูลนั้นค่าความแปรปรวนของค่าความคาดเคลื่อนที่เกิดขึ้นในอดีต และในบางงานศึกษาเช่น แบบจำลองเงินเพื่อ อัตราดอกเบี้ยหรือผลตอบแทนจากตลาดหลักทรัพย์ และในบางคาบเวลาจะมีค่าความผันผวนสูง (มีค่าความคาดเคลื่อนที่มีขนาดใหญ่) ตามด้วยคาบเวลาที่มีค่าความผันผวนต่ำ (มีค่าความคาดเคลื่อนที่มีขนาดเล็ก) สรุปได้ว่าค่าความแปรปรวนของค่าความคาดเคลื่อนจากการถดถอย จะขึ้นอยู่กับค่าความผันผวนของความคาดเคลื่อนในอดีตที่ผ่านมา (Enders, Walter, 1995)

ความเป็นไปได้ในการหาค่าเฉลี่ย และค่าความแปรปรวนของอนุกรมเวลาพร้อมกันนั้นซึ่งในขั้นต้นนั้นการพยากรณ์อย่างมีเงื่อนไข จะมีความแม่นยำเหนือกว่าการพยากรณ์อย่างไม่มีเงื่อนไขอย่างมาก ดังนั้นแบบจำลอง Autoregressive Moving Average (ARMA) สามารถแสดงได้ดังสมการ (4.8)

$$x_t = a_0 + a_1 x_{t-1} + \varepsilon_t \quad (4.8)$$

พยากรณ์อย่างมีเงื่อนไขของ x_{t+1} ดังสมการ (4.9)

$$E_t x_{t+1} = a_0 + a_1 x_t \quad (3.9)$$

ถ้าใช้ค่าเฉลี่ยอย่างมีเงื่อนไขพยากรณ์ x_{t+1} ดังนั้นค่าความคาดเคลื่อนของความแปรปรวนอย่างมีเงื่อนไขพยากรณ์ดังสมการ (4.10)

$$E_t [(x_{t+1} - a_0 - a_1 x_t)^2] = E_t \varepsilon_{t+1}^2 = \sigma^2 \quad (4.10)$$

ถ้าเปลี่ยนไปใช้พยากรณ์อย่างไม่มีเงื่อนไขแล้ว ผลที่ใช้เป็นค่าเฉลี่ยในช่วงระยะยาวตามลำดับ $\{x_t\}$ ซึ่งเท่ากับ $\frac{a_0}{(1-a_1)}$ จะได้ค่าความคาดเคลื่อนของการพยากรณ์อย่างมีเงื่อนไขดังสมการ (4.11)

$$E_t \left\{ \left[x_{t+1} - \frac{a_0}{(1-a_1)} \right]^2 \right\} = E \left[(\varepsilon_{t+1} + a_1 \varepsilon_t + a_1^2 \varepsilon_{t-1} + a_1^3 \varepsilon_{t-2} + \dots)^2 \right]$$

$$= \frac{\sigma^2}{(1-a_1^2)} \quad (4.11)$$

เมื่อ $\frac{1}{(1-a_1^2)} > 1$ ค่าความแปรปรวนที่ได้จากการพยากรณ์อย่างมีเงื่อนไขจะสูงกว่าแบบมีเงื่อนไข ดังนั้นในการพยากรณ์อย่างมีเงื่อนไขจึงมีความเหมาะสมกว่า ในลักษณะเดียวกันถ้าความแปรปรวนของ $\{\varepsilon_t\}$ ไม่เป็นค่าคงที่ จะสามารถประมาณค่าแนวโน้มของการเปลี่ยนแปลงความแปรปรวนโดยใช้ ARMA model อธิบายโดยให้ $\{\hat{\varepsilon}_t\}$ แทนส่วนที่เหลือ (residuals) ที่ได้จาก การประมาณจากสมการ (4.11) ดังนั้นค่าความแปรปรวนอย่างมีเงื่อนไข (conditional variance) ของ x_{t+1} จะได้สมการ (4.12)

$$\text{Var}(x_{t+1} | x_t) = E_t \left[(x_{t+1} - a_0 - a_1 x_t)^2 \right]$$

$$= E_t \varepsilon_{t+1}^2 \quad (4.12)$$

และจากที่ให้ $E_t \varepsilon_{t+1}^2$ เท่ากับ σ_{t+1}^2 แสดงว่าค่าความแปรปรวนอย่างมีเงื่อนไขไม่ใช่ค่าคงที่และจะได้แบบจำลองในการประมาณค่าส่วนที่เหลือ ดังสมการ (4.13)

$$\hat{\varepsilon}_t^2 = \alpha_0 + \alpha_1 \hat{\varepsilon}_{t-1}^2 + \dots + \alpha_q \hat{\varepsilon}_{t-q}^2 + v_t \quad (4.13)$$

เมื่อ v_t = กระบวนการ White Noise

ถ้าค่าของ $\alpha_1 = \alpha_2 = \dots = \alpha_q = 0$ ค่าความแปรปรวนจากการประมาณจะเท่ากับค่าคงที่ α_0 อีกนัยหนึ่ง คือ ค่าความแปรปรวนอย่างมีเงื่อนไขของ x_t จะมีการเปลี่ยนแปลงสอดคล้องกับสมการที่ (4.13) ดังนั้นสามารถใช้สมการที่ (4.13) ในการพยากรณ์ค่าความแปรปรวนอย่างมีเงื่อนไขที่เวลา $t+1$ ดังสมการ (4.14)

$$E_t \hat{\varepsilon}_{t+1}^2 = \alpha_0 + \alpha_1 \hat{\varepsilon}_t^2 + \alpha_1 \hat{\varepsilon}_{t-1}^2 + \dots + \alpha_q \hat{\varepsilon}_{t+1-q}^2 \quad (4.14)$$

จากที่กล่าวมาในสมการ (4.13) เรียกว่า Autoregressive Conditional Heteroscedasticity (ARCH) model และสมการที่ (4.14) เป็น ARCH (q) ค่า $E_t \hat{\mathcal{E}}_{t+1}^2$ หรือ σ_{t+1}^2 จะประกอบด้วย 2 องค์ประกอบ คือค่าคงที่และความผันผวนใสคาบเวลาที่ผ่านมา ซึ่งเขียนได้เป็นส่วนเหลือกำลังสองของคาบในอดีต (ARCH term) ส่วนค่าสัมประสิทธิ์ $\alpha_1 = \alpha_2 = \dots = \alpha_q$ สามารถหาค่าได้โดยใช้วิธี Maximum Likelihood

2) แบบจำลอง Generalized Autoregressive Conditional Heteroscedasticity (GARCH)

แบบจำลอง GARCH model เป็นแบบจำลองที่ถูกพัฒนาขึ้นจากแบบจำลอง ARCH model (Bollerslev, 1986) โดยมีขั้นตอนคือให้ค่าความคาดเคลื่อนจากกระบวนการดังสมการ (4.15)

$$\varepsilon_t = V_t \sqrt{h_t} \quad (4.15)$$

โดยที่ค่าความแปรปรวนของ $V_t = \sigma_v^2 = 1$

และ
$$h_t = \alpha_0 \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^p \beta_i h_{t-i} \quad (4.16)$$

เมื่อ $\{V_t\}$ คือ กระบวนการ White Noise ที่เป็นค่าอิสระจากเหตุการณ์ในอดีต (ε_{t-i}) ค่าเฉลี่ยอย่างมีเงื่อนไขและไม่มีเงื่อนไขของ ε_t จะมาจาก h_t ในสมการ (4.16)

GARCH (p,q) นั้นใช้กระบวนการ Autoregressive และ Moving Average ในการหา heteroscedastic variance ดังสมการ (4.17)

$$E_{t-1} \varepsilon_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^p \beta_i h_{t-i} \quad (4.17)$$

ถ้ากำหนดให้ $p=0$ และ $q=1$ จะได้เป็น ARCH (1) หรือถ้าค่า β_i ทั้งหมดที่ค่าเป็น 0 แบบจำลอง GARCH (p,q) จะเทียบเท่ากับแบบจำลอง ARCH (q) คุณสมบัติที่สำคัญของแบบจำลอง GARCH คือความแปรปรวนอย่างมีเงื่อนไขของการรบกวน (disturbances) ของค่า x_t สร้างขึ้นมาจากกระบวนการ ARCH ค่าสหพันธ์ในตัวเอง (autocorrelation function หรือ ACF)

ซึ่งเป็นสหพันธ์ระหว่างตัวแปรสุ่มที่หน่วยเวลาห่างกันของกระบวนการเดียวกัน และสหพันธ์ในตัวเองส่วนย่อย (partial autocorrelation function หรือ PACF) ของส่วนเหลือ ควรจะบ่งบอกถึง White Noise และค่าสหพันธ์ในตัวเองของส่วนที่เหลือกำลังสอง (squared residuals) นำมาใช้ระบุถึงลำดับของกระบวนการ GARCH



ลิขสิทธิ์มหาวิทยาลัยเชียงใหม่
Copyright© by Chiang Mai University
All rights reserved