

บทที่ 3

แนวความคิดและระเบียบวิธีวิจัย

3.1 แนวความคิดที่ใช้ในการศึกษา

การศึกษาการประมาณค่าความผันผวนของผลตอบแทนของราคาน้ำมันดิบ ถ่านหินและก๊าซธรรมชาติ ใช้แนวคิดและทฤษฎีเกี่ยวกับการวิเคราะห์อนุกรมเวลา การทดสอบความนิ่งของข้อมูล การทดสอบ unit root แบบจำลอง Autoregressive Conditional Heteroscedasticity (ARCH) แบบจำลอง Generalized Conditional Heteroscedasticity (GARCH) แบบจำลอง GARCH-in-mean และแบบจำลอง Exponential GARCH ดังต่อไปนี้

3.1.1 การวิเคราะห์อนุกรมเวลา (Time Series Analysis)

การวิเคราะห์อนุกรมเวลาเป็นวิธีที่ใช้ในการวิเคราะห์ข้อมูลหรือค่าสังเกตที่มีการเปลี่ยนแปลงไปตามลำดับเวลาที่เกิดขึ้น หรือการเปลี่ยนแปลงของตัวแปรในช่วงเวลาที่ผ่านไป ลักษณะของการเปลี่ยนแปลงอาจมีหรือไม่มีรูปแบบก็ได้ แต่ถ้าอนุกรมเวลาแสดงให้เห็นรูปแบบการเปลี่ยนแปลงในช่วงเวลาที่ผ่านมามีแนวโน้มที่จะทำให้สามารถคาดการณ์ได้ว่าในอนาคตลักษณะการเปลี่ยนแปลงควรอยู่ในรูปแบบใดและสามารถพยากรณ์การเปลี่ยนแปลงข้อมูลในอนาคตได้ การวิเคราะห์ข้อมูลอนุกรมเวลานี้จะขึ้นอยู่กับเปลี่ยนแปลงของเวลาในอดีตเป็นพื้นฐาน (ศิริลักษณ์ เล็กสมบูรณ์, 2531)

3.1.2 การทดสอบความนิ่งของข้อมูล (Stationary) และการทดสอบ Unit Root

ในการวิเคราะห์ข้อมูลทางเศรษฐศาสตร์ ซึ่งข้อมูลที่ใช้เป็นข้อมูลแบบอนุกรมเวลา (Time series data) มีความจำเป็นที่จะต้องมีการทดสอบว่า ข้อมูลที่เราใช้นั้นมีความนิ่ง (Stationary) หรือไม่ เพราะหากเราละเลยที่จะทดสอบข้อมูล แล้วข้อมูลเกิดมีความไม่นิ่ง (Nonstationary) จะทำให้เวลาที่หาสมการถดถอยระหว่างตัวแปรอนุกรมเวลาสองตัวแปรออกมา จะได้ค่า R^2 ที่สูงมาก และค่าสถิติ t จะมีนัยสำคัญ ทั้งที่ไม่มีความสัมพันธ์ของตัวแปรทั้งสองในทางเศรษฐศาสตร์เลย

(Enders, 1995: 216 and Gujarati, 1995: 709 อ้างถึงในทรงศักดิ์ ศรีบุญจิตต์ และอารี วิบูลย์พงศ์, 2542)

เหตุที่ทำให้ได้ค่า R^2 สูงเช่นนี้เป็นเพราะอนุกรมเวลาได้รับอิทธิพลจากแนวโน้ม (Trend) ไม่ใช่เนื่องจากความสัมพันธ์ที่แท้จริงระหว่างตัวแปรอนุกรมเวลาทั้งสองตัวแปร ส่วนกรณีที่ค่าสถิติ t มีนัยสำคัญเป็นเพราะอนุกรมเวลาทั้งสองมีแนวโน้มที่แข็งแกร่งมาก (Strong Trend) โดยสรุปแล้วการละเลยการทดสอบความนิ่งของข้อมูลอาจนำไปสู่การลงความเห็นที่ผิดพลาดได้ในที่สุด

การทดสอบว่าข้อมูลที่น่ามาศึกษามีความนิ่งหรือไม่ สามารถทำได้โดยการทดสอบ Unit Root ซึ่งทำได้โดยใช้การทดสอบ DF (Dickey-Fuller Test) ซึ่งเสนอโดย Dickey และ Fuller ในปี 1981 และวิธีการทดสอบ ADF (Augmented Dickey-Fuller Test) ซึ่งเสนอโดย Said และ Dickey ในปี 1984

ข้อมูลที่มีลักษณะนิ่ง (Stationary) หมายถึง ข้อมูลอนุกรมเวลาที่มีค่าเฉลี่ย (Mean) และความแปรปรวน (Variance) เท่ากันตลอดระยะเวลาที่ศึกษา

ส่วนข้อมูลที่มีลักษณะไม่นิ่ง (Nonstationary) หมายถึง ข้อมูลอนุกรมเวลาที่มีค่าเฉลี่ย (Mean) และความแปรปรวน (Variance) ไม่เท่ากันตลอดระยะเวลาที่ศึกษา

ทั้งนี้การวิเคราะห์ข้อมูลที่เป็นอนุกรมเวลาส่วนมากจะพบปัญหาความไม่นิ่งของข้อมูล ซึ่งสามารถแก้ไขได้ด้วยการทำให้ข้อมูลมีความนิ่งเสียก่อน โดยอาจใช้วิธีการหาผลต่าง (Difference) ของข้อมูล การแปลงให้อยู่ในรูป Logarithm หรือการทดสอบหาความสัมพันธ์ของตัวแปรในระยะยาว (Cointegration) เป็นต้น

วิธีการทดสอบ Unit Root (ทรงศักดิ์ ศรีบุญจิตต์ และอารี วิบูลย์พงศ์, 2542) สามารถทดสอบได้โดยใช้การทดสอบ DF (Dickey-Fuller (DF) Test) ซึ่งเสนอโดย Dickey และ Fuller ในปี 1981 หรือใช้การทดสอบ ADF (Augmented Dickey-Fuller (ADF) Test) ซึ่งเสนอโดย Said และ Dickey ในปี 1984 สมมติฐานว่าง (null hypothesis) ของการทดสอบ DF (DF test) คือ $H_0 : \rho = 1$ จากสมการ

$$X_t = \rho X_{t-1} + \varepsilon_t \quad (3.1)$$

ซึ่งเรียกว่าการทดสอบ unit root โดยถ้า $|\rho| < 1$ X_t จะมีลักษณะนิ่ง (stationary) และถ้า $\rho = 1$ X_t จะมีลักษณะไม่นิ่ง (nonstationary) อย่างไรก็ตามการทดสอบนี้สามารถทำได้อีกทางหนึ่งซึ่งเหมือนกับสมการ (3.1) กล่าวคือ

$$\Delta X_t = \theta X_{t-1} + \varepsilon_t \quad (3.2)$$

ซึ่งก็คือ $X_t = (1 + \theta)X_{t-1} + \varepsilon_t$ ซึ่งคือสมการที่ (1) นั่นเอง โดยที่ $\rho = (1 + \theta)$ ถ้า θ ในสมการ (2) มีค่าเป็นลบ จะได้ว่า ρ ในสมการ (1) จะมีค่าน้อยกว่า 1 ดังนั้นสามารถจะสรุปได้ว่า การปฏิเสธ $H_0 : \theta = 0$ ซึ่งเป็นการยอมรับ $H_a : \theta < 0$ หมายความว่า $\rho < 1$ และ X_t มี integration of order zero นั่นคือ X_t มีลักษณะนิ่ง (stationary) และถ้าเราไม่สามารถปฏิเสธ $H_0 : \theta = 0$ ได้ ก็จะหมายความว่า X_t มีลักษณะไม่นิ่ง (nonstationary)

ถ้า X_t เป็นแนวเดินเชิงสุ่มซึ่งมีความโน้มเอียงทั่วไปรวมอยู่ด้วย (random walk with drift) สามารถจะเขียนแบบจำลองได้ดังนี้

$$\Delta X_t = \alpha + \theta X_{t-1} + \varepsilon_t \quad (3.3)$$

และถ้า X_t เป็นแนวเดินเชิงสุ่มซึ่งมีความโน้มเอียงทั่วไปรวมอยู่ด้วย (random walk with drift) และมีแนวโน้มตามเวลาเชิงเส้น (linear time trend) สามารถเขียนแบบจำลองได้ดังนี้

$$\Delta X_t = \alpha + \beta t + \theta X_{t-1} + \varepsilon_t \quad (3.4)$$

โดยที่ $t =$ เวลา ซึ่งก็จะทำการทดสอบ $H_0 : \theta = 0$ โดยมี $H_a : \theta < 0$ เช่นเดียวกับที่กล่าวมาข้างต้น โดยสรุปแล้ว Dickey and Fuller ได้พิจารณาสมการถดถอย 3 รูปแบบที่แตกต่างกันในการทดสอบว่ามี unit root หรือไม่ ซึ่ง 3 สมการดังกล่าว ได้แก่

$$\Delta X_t = \theta X_{t-1} + \varepsilon_t$$

$$\Delta X_t = \alpha + \theta X_{t-1} + \varepsilon_t$$

$$\Delta X_t = \alpha + \beta t + \theta X_{t-1} + \varepsilon_t$$

โดยตัวพารามิเตอร์ที่อยู่ในความสนใจในทุกสมการ คือ θ นั่นคือ ถ้า $\theta = 0$; X_t จะมี unit root โดยการเปรียบเทียบค่าสถิติ t (t -statistic) ที่คำนวณได้กับค่าที่เหมาะสมที่อยู่ในตาราง Dickey-Fuller (Dickey-Fuller tables) หรือกับ ค่าวิกฤติ MacKinnon (MacKinnon critical values) (Enders, 1995: 221 and Gujarati, 1995: 769 อ้างถึงใน ทรงศักดิ์ ศรีบุญจิตต์ และอารี วิบูลย์พงศ์, 2542)

อย่างไรก็ตามค่าวิกฤติ (Critical values) จะไม่เปลี่ยนแปลง ถ้าสมการ (3.2), (3.3), (3.4) ถูกแทนที่โดยกระบวนการเชิงอัตถถดถอย (autoregressive processes)

$$\Delta X_t = \theta X_{t-1} + \sum_{i=1}^p \phi_i \Delta X_{t-i} + \varepsilon_t \quad (3.5)$$

$$\Delta X_t = \alpha + \theta X_{t-1} + \sum_{i=1}^p \phi_i \Delta X_{t-i} + \varepsilon_t \quad (3.6)$$

$$\Delta X_t = \alpha + \beta t + \theta X_{t-1} + \sum_{i=1}^p \phi_i \Delta X_{t-i} + \varepsilon_t \quad (3.7)$$

จำนวนของ lagged difference terms ที่จะนำเข้ามารวมในสมการนั้นจะต้องมีมากพอที่จะทำให้พจน์ค่าความคลาดเคลื่อน (error terms) มีลักษณะเป็น serially independent และเมื่อนำเอาการทดสอบ DF (Dickey – Fuller (DF) test) มาใช้กับสมการ (3.5) – (3.7) เราจะเรียกว่าการทดสอบ ADF (augmented Dickey – Fuller (ADF) test) ค่าสถิติทดสอบ ADF (ADF test statistic) มีการแจกแจงเชิงเส้นกำกับ (asymptotic distribution) เหมือนกับสถิติ DF (DF statistic) ดังนั้นก็สามารถใช้ค่าวิกฤติ (critical values) แบบเดียวกัน (Enders, 1995: 221 and Gujarati, 1995: 720)

3.1.3 การเลือกแบบจำลองที่เหมาะสมจากการทดสอบ Unit Root โดยการทดสอบสัมประสิทธิ์การถดถอย (Deterministic Regressors)

เป็นการทดสอบว่า แบบจำลองใดเป็นแบบจำลองที่มีความเหมาะสมที่สุดระหว่างกรณีของแบบจำลองที่ไม่มีค่าคงที่และแนวโน้มเวลา (None) แบบจำลองที่มีค่าคงที่ (Intercept) และแบบจำลองที่มีทั้งค่าคงที่และแนวโน้มเวลา (Trend and Intercept) โดยการทดสอบความมีนัยสำคัญทางสถิติของสัมประสิทธิ์ของตัวถดถอย (ค่าคงที่หรือค่าแนวโน้มเวลา) โดยมีขั้นตอนการทดสอบดังนี้

ขั้นตอนที่ 1 เริ่มการทดสอบจากแบบจำลองกรณีที่มีทั้งค่าคงที่และแนวโน้มเวลาตามสมการ (3.8)

$$\Delta y_t = a_0 + \gamma y_{t-1} + a_2 t + \sum \beta_i \Delta y_{t-i} + \varepsilon_t \quad (3.8)$$

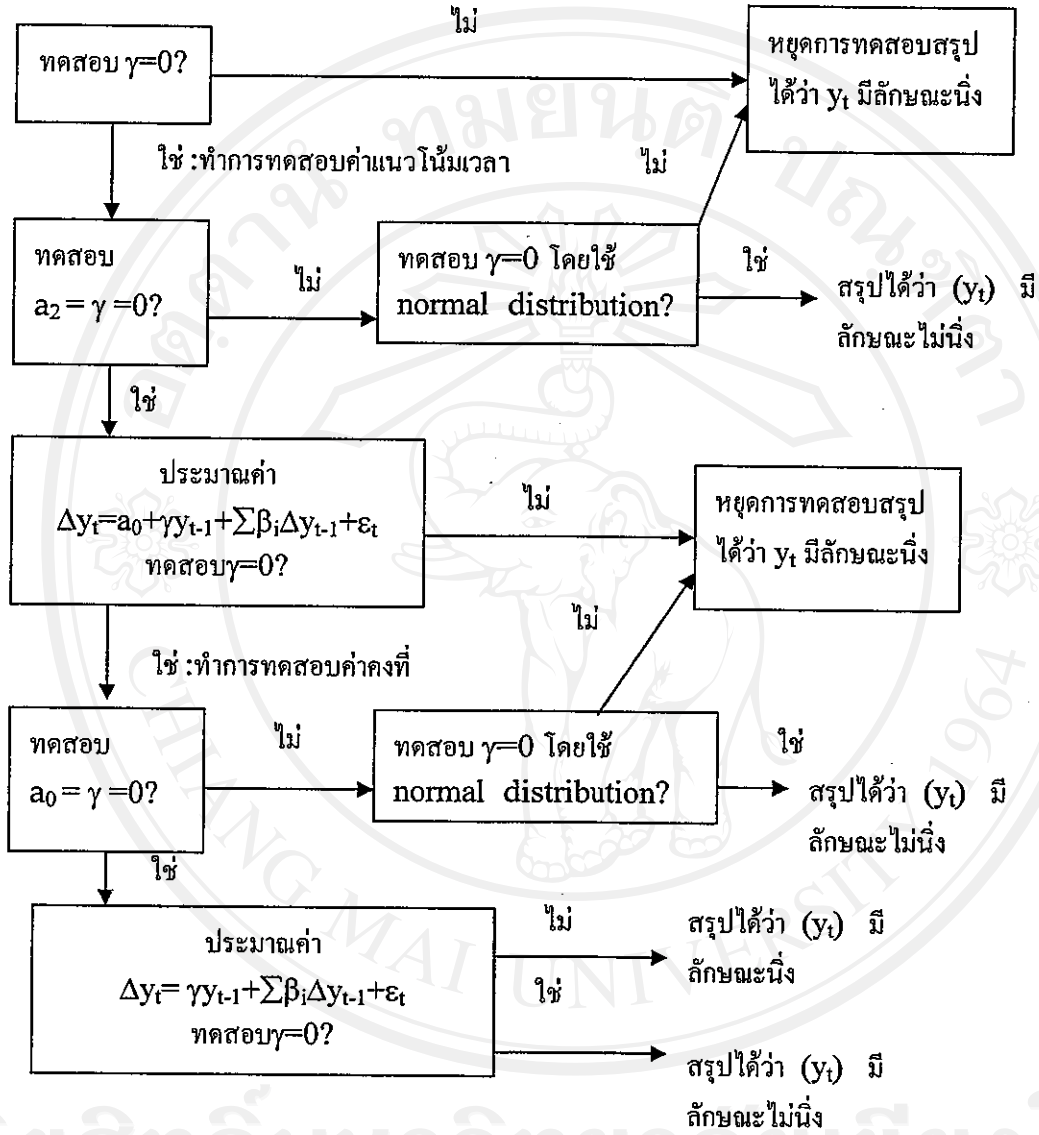
ทำการทดสอบสมมติฐานว่าง $H_0: \gamma = 0$ โดยใช้ τ_τ statistic ถ้าเกิดการปฏิเสธสมมติฐานว่าง แสดงว่า ข้อมูล y_t มีลักษณะนิ่งแล้ว และเลือกใช้แบบจำลองที่มีทั้งค่าคงที่และแนวโน้มเวลา

ขั้นตอนที่ 2 ถ้าเกิดการยอมรับสมมติฐานว่างในขั้นตอนที่ 1 แสดงว่าในแบบจำลองดังกล่าวมีตัวคล้อยที่ไม่จำเป็นอยู่ในสมการ ซึ่งอาจทำให้อำนาจการทดสอบของสมการลดลง ดังนั้นจึงต้องมีการทดสอบความมีนัยสำคัญทางสถิติของค่าแนวโน้ม (a_2) ที่อยู่ในสมการ โดยการทดสอบสมมติฐานว่าง $H_0: a_2 = \gamma = 0$ โดยใช้ ϕ_3 statistic ถ้าค่าสัมประสิทธิ์ของค่าแนวโน้ม ไม่มีนัยสำคัญทางสถิติให้ข้ามไปขั้นตอนที่ 3 อย่างไรก็ตามถ้าค่าสัมประสิทธิ์ของค่าแนวโน้มมีนัยสำคัญทางสถิติให้ทำการทดสอบความไม่นิ่งของข้อมูลอีกครั้งโดยใช้ การแจกแจงแบบปกติมาตรฐาน (standardized normal distribution) ถ้าเกิดการปฏิเสธสมมติฐานว่างแสดงว่า ข้อมูล y_t มีลักษณะนิ่งแล้วและเลือกใช้แบบจำลองที่มีทั้งค่าคงที่และแนวโน้มเวลาแต่ถ้าเกิดการยอมรับสมมติฐานว่าง แสดงว่าข้อมูล y_t มีลักษณะไม่นิ่ง

ขั้นตอนที่ 3 ทำการประมาณค่าแบบจำลองตามสมการ (3.8) ที่ปราศจากค่าแนวโน้มเวลา และทดสอบ unit root โดยใช้ τ_μ statistic ถ้าเกิดการปฏิเสธสมมติฐานว่างแสดงว่าข้อมูล y_t มีลักษณะนิ่งแล้วและเลือกใช้แบบจำลองที่ปราศจากค่าแนวโน้มเวลา แต่ถ้าเกิดการยอมรับสมมติฐานว่างให้ทำการทดสอบความมีนัยสำคัญทางสถิติของค่าคงที่ โดยมีสมมติฐานว่าง $H_0: a_0 = \gamma = 0$ โดยใช้ ϕ_1 statistic ถ้าค่าคงที่ไม่มีนัยสำคัญให้ข้ามไปขั้นตอนที่ 4 อย่างไรก็ตามถ้าค่าคงที่มีนัยสำคัญทางสถิติ ให้ทำการทดสอบความไม่นิ่งของข้อมูลอีกครั้งโดยใช้ การแจกแจงแบบปกติมาตรฐาน (standardized normal distribution) ถ้าเกิดการปฏิเสธสมมติฐานว่างแสดงว่า ข้อมูล y_t มีลักษณะนิ่งแล้วและเลือกใช้แบบจำลองที่มีทั้งค่าคงที่และแนวโน้มเวลาแต่ถ้าเกิดการยอมรับสมมติฐานว่าง แสดงว่าข้อมูล y_t มีลักษณะไม่นิ่ง

ขั้นตอนที่ 4 ทำการประมาณค่าแบบจำลองตามสมการ (3.8) ที่ปราศจากค่าแนวโน้มเวลา และค่าคงที่และทดสอบ unit root โดยใช้ τ statistic ถ้าเกิดการปฏิเสธสมมติฐานว่างแสดงว่าข้อมูล y_t มีลักษณะนิ่งแล้วและเลือกใช้แบบจำลองที่ปราศจากค่าแนวโน้มเวลาและค่าคงที่แต่ถ้าเกิดการยอมรับสมมติฐานว่าง แสดงว่าข้อมูล y_t มีลักษณะไม่นิ่ง

รูปที่ 3.1 ขั้นตอนการเลือกแบบจำลองที่เหมาะสม



ที่มา: Enders (1995)

3.1.4 แบบจำลอง Autoregressive Conditional Heteroscedasticity (ARCH)

ในการวิเคราะห์หอนุกรมเวลาส่วนใหญ่แล้วจะมีการกำหนด stochastic variable ให้มีความแปรปรวนคงที่ (homoscedastic) ซึ่งในการประยุกต์ใช้กับบางข้อมูลนั้นค่าความ

แปรปรวนของค่าความคลาดเคลื่อน (error term) จะไม่ใช่ฟังก์ชันของตัวแปรอิสระแต่มีค่าเปลี่ยนแปลงไปตามช่วงเวลาขึ้นอยู่กับขนาดของความคลาดเคลื่อนที่เกิดขึ้นในอดีต และในบางงานศึกษา เช่น แบบจำลองของเงินเฟ้อ อัตราดอกเบี้ยหรือผลตอบแทนจากตลาดหลักทรัพย์ ในบางคาบเวลาจะมีค่าความผันผวน (volatility) สูง (และความคลาดเคลื่อนขนาดใหญ่) ตามด้วยคาบเวลาที่มีค่าความผันผวน (volatility) ต่ำ (และมีค่าความคลาดเคลื่อนที่มีขนาดเล็ก) สรุปได้ว่าค่าความแปรปรวนของค่าความคลาดเคลื่อนจากการถดถอยจะขึ้นอยู่กับค่าความผันผวน (volatility) ของความคลาดเคลื่อนในอดีตที่ผ่านมา (สธนพล วิเชียรรัตนพันธ์, 2547: 29 อ้างถึงใน ทรงศักดิ์ ศรีบุญจิตต์, 2547: 641)

ความเป็นไปได้ในการหาค่าเฉลี่ยและความแปรปรวนของอนุกรมเวลาไปพร้อมกันนั้น ในขั้นตอนการพยากรณ์อย่างมีเงื่อนไขจะมีความแม่นยำเหนือกว่าการพยากรณ์อย่างไม่มีเงื่อนไขมาก ซึ่งจากแบบจำลอง Autoregressive Moving Average (ARMA) ซึ่งแสดงดังสมการ

$$X_t = a_0 + a_1 X_{t-1} + \varepsilon_t \quad (3.9)$$

และการพยากรณ์อย่างมีเงื่อนไขของ X_{t+1} ดังนี้คือ

$$E_t X_{t+1} = a_0 + a_1 X_t \quad (3.10)$$

ถ้าเราใช้ค่าเฉลี่ยอย่างมีเงื่อนไขในการพยากรณ์ X_{t+1} ค่าความคลาดเคลื่อนของความแปรปรวนอย่างมีเงื่อนไขที่พยากรณ์ได้ดังนี้คือ

$$E_t \left[(X_{t+1} - a_0 - a_1 X_t)^2 \right] = E_t \varepsilon_{t+1}^2 = \sigma^2 \quad (3.11)$$

ถ้าเปลี่ยนไปใช้การพยากรณ์อย่างไม่มีเงื่อนไขแล้ว ผลที่จะใช้เป็นค่าเฉลี่ยในช่วง Long-Run ของลำดับ $\{X_t\}$ ซึ่งเท่ากับ $\frac{a_0}{1-a_1}$ จะได้ค่าความคลาดเคลื่อนของการพยากรณ์อย่างไม่มีเงื่อนไขตามสมการดังนี้

$$E \left\{ \left(X_{t+1} - \frac{a_0}{1-a_1} \right)^2 \right\} = E \left[(\varepsilon_{t+1} + a_1 \varepsilon_t + a_1^2 \varepsilon_{t-1} + a_1^3 \varepsilon_{t-2} + \dots)^2 \right] \quad (3.12)$$

เนื่องจาก $\frac{1}{(1-\alpha_1)^2} > 1$ เพราะฉะนั้นความแปรปรวน (variance) จากการพยากรณ์แบบไม่มีเงื่อนไข (unconditional variance) จึงมีค่าสูงกว่าความแปรปรวนของการพยากรณ์แบบมีเงื่อนไข ในลักษณะเดียวกันถ้าความแปรปรวนของ $\{\varepsilon_t\}$ ไม่เป็นค่าคงที่ จะสามารถประมาณค่าแนวโน้มของการเปลี่ยนแปลงความแปรปรวนโดยใช้ ARMA Model ความแปรปรวนแบบมีเงื่อนไขของ X_{t+1} คือ

$$\text{Var}(X_{t+1}|X_t) = E[(X_{t+1} - \alpha_0 - \alpha_1 X_t)^2] = E_t \varepsilon_{t+1}^2 \quad (3.13)$$

และจากที่ให้ $E_t \varepsilon_{t+1}^2 = \sigma_{t+1}^2$ จึงแสดงว่าความแปรปรวนอย่างมีเงื่อนไขไม่ใช่ค่าคงที่และจะได้แบบจำลองในการประมาณค่าส่วนที่เหลือ (residuals) ออกมาดังสมการ

$$\hat{\varepsilon}_t^2 = \alpha_0 + \alpha_1 \hat{\varepsilon}_{t-1}^2 + \dots + \alpha_q \hat{\varepsilon}_{t-q}^2 + V_t \quad (3.14)$$

เมื่อ $V_t = \text{white noise process}$

ถ้าค่าของ $\alpha_1, \alpha_2, \dots, \alpha_q$ มีค่าเท่ากับศูนย์ ความแปรปรวนที่ประมาณค่ามาได้ (estimated variance) จะมีค่าคงที่หรือคงตัว (constant variance) α_0 อีกนัยหนึ่ง คือ ค่าความแปรปรวนอย่างมีเงื่อนไขของ X_t จะมีการเปลี่ยนแปลงสอดคล้องกับในสมการ (14) และค่าพยากรณ์สามารถเขียนได้ดังนี้

$$E \hat{\varepsilon}_t^2 = \alpha_0 + \alpha_1 \hat{\varepsilon}_{t-1}^2 + \alpha_2 \hat{\varepsilon}_{t-2}^2 + \dots + \alpha_q \hat{\varepsilon}_{t+1-q}^2 \quad (3.15)$$

สมการที่มีลักษณะเช่นสมการ (3.14) เราเรียกว่า an autoregressive conditional heteroscedastic (ARCH) model และสมการ (3.15) เป็น ARCH(q) โดยค่า $E_t \hat{\varepsilon}_{t+1}^2$ หรือ σ_{t+1}^2 จะประกอบด้วย 2 องค์ประกอบ คือค่าคงที่และความผันผวน (volatility) ในคาบเวลาที่ผ่านมา ซึ่งเขียนได้เป็นส่วนเหลือกำลังสองของคาบในอดีต (ARCH term) ส่วนค่าสัมประสิทธิ์ ($\alpha_0, \alpha_1, \dots, \alpha_q$) สามารถหาค่าได้โดยใช้วิธี Maximum likelihood

3.1.5 แบบจำลอง Generalized Autoregressive Conditional Heteroscedasticity (GARCH)

แบบจำลอง ARCH ของ Engle, Robert F. ได้มีการพัฒนาต่อโดย Bollerslev ในปี 1986 ด้วยการให้ความแปรปรวนแบบมีเงื่อนไข (conditional variance) มีลักษณะเป็น ARMA process โดยที่ให้ error process มีลักษณะดังนี้

$$\varepsilon_t = V_t \sqrt{C_t}$$

$$\text{และ } C_t = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^p \beta_i C_{t-i} \quad (3.16)$$

เมื่อ $\{V_t\}$ คือ white noise process ที่เป็นค่าอิสระจากเหตุการณ์ในอดีต (ε_{t-1}) ค่าเฉลี่ยเคลื่อนที่อย่างมีเงื่อนไขและไม่มีเงื่อนไขของ ε_t จะมาจาก C_t ในสมการ (3.16)

GARCH(p,q) นั้นใช้กระบวนการ Autoregressive และ Moving Average ในการหา Heteroscedastic Variance ได้ดังนี้

$$E_{t-1} \varepsilon_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^p \beta_i C_{t-i}$$

ถ้ากำหนดให้ค่า $p=0$ และ $q=1$ จะได้เป็น ARCH(1) หรือถ้าค่า β_1 ทั้งหมดมีค่าเป็นศูนย์แบบจำลอง GARCH(p,q) จะเทียบเท่ากับแบบจำลอง ARCH(q) คุณสมบัติที่สำคัญของแบบจำลอง GARCH คือค่าความแปรปรวนอย่างมีเงื่อนไขของ disturbances ของค่า X_t สร้างขึ้นมาจากกระบวนการ ARMA จึงสามารถคาดได้ว่าส่วนเหลือจากการทำ ARMA จะแสดงถึงรูปแบบคุณสมบัติเดียวกัน เช่น ถ้าการประมาณค่า $\{X_t\}$ ด้วยกระบวนการ ARMA ค่า Autocorrelation Function (ACF) ซึ่งเป็นสหสัมพันธ์ระหว่างตัวแปรสุ่มที่หน่วยเวลาห่างกันของกระบวนการเดียวกันและ Partial Autocorrelation Function (PACF) ของส่วนที่เหลือ (residuals) ควรจะบ่งถึงกระบวนการ white noise และ ACF ของกำลังสองของส่วนเหลือ (squared residuals) นำมาช่วยในการระบุถึงลำดับ (order) ของกระบวนการ GARCH (สรณพล วิเชียรรัตนพันธ์, 2547: 30 อ้างถึงใน ทรงศักดิ์ ศรีบุญจิตต์, 2547: 648)

3.1.6 แบบจำลอง GARCH-in-mean (GARCH-M)

จากแบบจำลอง GARCH (p, q) ในสมการ (3.16) ความแปรปรวนอย่างมีเงื่อนไขของข้อมูลอนุกรมเวลาขึ้นอยู่กับส่วนที่เหลือกำลังสอง (squared residual) ของกระบวนการนี้ โดย Engle, Robert F. ขยายแนวคิดนี้โดยให้ค่าเฉลี่ยอย่างมีเงื่อนไขเป็นฟังก์ชันของความแปรปรวนอย่างมีเงื่อนไขโดยรู้จักกันในชื่อ GARCH-in-mean หรือ GARCH-M (Baillie and Bollerslve, 1992 อ้างถึงใน สธนพล วิเชียรรัตนพันธ์, 2547: 34)

ผลตอบแทนจากหลักทรัพย์สามารถแสดงในรูปของแบบจำลอง GARCH (p, q) – M ดังสมการ (3.17), (3.18) และ (3.19)

$$X_t = \mu_t + \delta_1 C_t^{\frac{1}{2}} + \varepsilon_t \quad (3.17)$$

$$\varepsilon_t / \Psi_{t-1} \sim N(0, C_t) \quad (3.18)$$

$$C_t = V + \sum_{i=1}^p \beta_i C_{t-i} + \sum_{i=1}^q \alpha_i (\varepsilon_{t-i})^2 \quad (3.19)$$

เมื่อ X_t คือผลตอบแทนจากหลักทรัพย์

μ_t คือค่าเฉลี่ย X_t อย่างมีเงื่อนไขในอดีต (φ_{t-1}) และตามสมการข้อจำกัด

$\varphi > 0, \alpha_1 > 0$ และ $\beta_1 \geq 0$ เพื่อให้แน่ใจว่าค่าความแปรปรวนอย่างมีเงื่อนไข (C_t) นั้นเป็นบวก

$C_t^{\frac{1}{2}}$ ในสมการ (3.17) เพื่อใช้แสดงความสัมพันธ์โดยตรงถึง trade off ระหว่างความเสี่ยงและผลตอบแทนที่คาดหวัง

อิทธิพลอย่างมีนัยสำคัญของความผันผวนในผลตอบแทนจากหลักทรัพย์ถูกตรวจจับด้วยสัมประสิทธิ์ $C_t^{\frac{1}{2}}$ (δ_1) ในสมการ (3.17) ซึ่งอธิบายแทนดัชนีของความสัมพันธ์ของการหลีกเลี่ยงความเสี่ยง ค่าสัมประสิทธิ์ δ_1 ที่เป็นบวกอย่างมีนัยสำคัญบอกถึงผู้ลงทุนในตลาดหลักทรัพย์เมื่อเผชิญกับระดับความเสี่ยงที่สูงขึ้นก็ต้องการค่าชดเชยความเสี่ยงที่มากขึ้นตามไปด้วย

3.1.7 แบบจำลอง Exponential GARCH (EGARCH)

EGARCH หรือ Exponential GARCH model ถูกเสนอโดย Nelson (1991) EGARCH model ให้ความแปรปรวนอย่างมีเงื่อนไขมีค่าดังสมการ (3.20)

$$\log(\sigma_t^2) = \omega + \beta \log(\sigma_{t-1}^2) + \alpha \left| \frac{\varepsilon_{t-1}}{\sigma_{t-1}} \right| + \gamma \frac{\varepsilon_{t-1}}{\sigma_{t-1}} \quad (3.20)$$

ข้อแตกต่าง EGARCH model ระหว่างโปรแกรม Eviews กับโมเดลเดิมของ Nelson มีอยู่ 2 ข้อคือ ข้อแรก Nelson ได้ตั้งสมมติฐานว่า error มีการแจกแจงแบบ general distribution ส่วน Eview ได้ตั้งสมมติฐานว่า error มีการแจกแจงแบบ normal distribution ข้อที่สอง ค่า log ของความแปรปรวนอย่างมีเงื่อนไขของ Nelson แตกต่างกับของ Eview เล็กน้อยดังสมการ (3.21)

$$\log(\sigma_t^2) = \omega + \beta \log(\sigma_{t-1}^2) + \alpha \left(\left| \frac{\varepsilon_{t-1}}{\sigma_{t-1}} \right| - \sqrt{\frac{2}{\pi}} \right) + \gamma \frac{\varepsilon_{t-1}}{\sigma_{t-1}} \quad (3.21)$$

การประมาณค่าสมการภายใต้สมมติฐานที่ error มีการแจกแจงแบบปกติจะให้ค่าที่เหมือนกันยกเว้นค่า intercept term ω ที่แตกต่างกันเท่ากับ $\alpha \sqrt{\frac{2}{\pi}}$

และการประมาณค่า EGARCH Model โดยโปรแกรม Eviews ได้ดังสมการที่ (3.22)


$$\log(\sigma_t^2) = \omega + \sum_{j=1}^p \beta_j \log(\sigma_{t-1}^2) + \sum_{i=1}^q \left(\alpha_i \left| \frac{\varepsilon_{t-1}}{\sigma_{t-1}} \right| + \gamma \frac{\varepsilon_{t-1}}{\sigma_{t-1}} \right) \quad (3.22)$$

3.1.8 การพยากรณ์ (Forecasting)

การศึกษานี้ได้แบ่งการพยากรณ์ออกเป็น 3 ช่วงคือ Historical Forecast Ex-post Forecast และ Ex-ante Forecast โดย Historical Forecast คือ การพยากรณ์ข้อมูลในอดีตจนถึงช่วงเวลาที่พิจารณา และเนื่องจากการพยากรณ์ข้อมูลล่วงหน้าจะทำให้เกิดข้อจำกัดที่ว่าความแม่นยำของข้อมูลที่ได้จากการพยากรณ์นั้น มีความน่าเชื่อถือมากน้อยเพียงใด และแบบจำลองอาร์มาเหมาะสำหรับการพยากรณ์ในระยะสั้น ดังนั้นเพื่อที่จะทราบว่าแบบจำลองที่ประมาณขึ้นมาสามารถที่จะพยากรณ์ได้ถูกต้องแม่นยำเพียงใด จึงได้ใช้การพยากรณ์แบบ Ex-post Forecast กล่าวคือ เป็นการพยากรณ์ข้อมูล ณ ช่วงเวลาที่มีข้อมูลจริงเกิดขึ้นแล้ว ยกตัวอย่างเช่น จะลดจำนวนค่าสังเกตการณ์ของอนุกรมเวลาจากข้อมูลที่มีทั้งหมด n ข้อมูล เหลือ $n-5$ ข้อมูล แล้วทำการถอดหายข้อมูลใหม่เพื่อดูค่า RMSE (Root Mean Squared Error) และทำการพยากรณ์ล่วงหน้า (Ex-post

Forecast) จำนวน 5 ข้อมูล เพื่อเปรียบเทียบกับข้อมูลจริงที่มีอยู่ และก็จะได้ค่า RMSE แล้วใช้ค่าสถิติดังกล่าวประกอบการพิจารณาเลือกแบบจำลองที่มีความเหมาะสม เมื่อได้แบบจำลองที่เหมาะสม ภายหลังจากการวิเคราะห์ความถูกต้องแล้ว ก็สามารถนำแบบจำลองดังกล่าวใช้ในการพยากรณ์

รูปที่ 3.2 แสดงช่วงเวลาที่ใช้ในการพยากรณ์



ที่มา: Pindyck and Rubinfeld (1998)

ภายหลังจากที่เลือกแบบจำลองที่ใช้เป็นตัวแทนอนุกรมเวลาข้อมูลได้แล้ว จะทำการพยากรณ์ล่วงหน้า (Ex-ante Forecast) กล่าวคือเป็นการพยากรณ์ในช่วงเวลาที่ยังไม่มีข้อมูลจริงเกิดขึ้นต่อไป

3.1.9 การตรวจสอบรูปแบบ (Diagnostic Checking)

การสร้างสมการพร้อมทั้งประมาณค่าพารามิเตอร์แล้วนั้น จะต้องทำการตรวจสอบรูปแบบว่าสมการที่ได้มามีความเหมาะสมหรือไม่และรูปแบบใดของสมการที่ดีที่สุด โดยใช้การทดสอบต่าง ๆ ดังนี้

1) การทดสอบ Ljung-Box Q-Statistic

การทดสอบ Ljung-Box Q-Statistic เป็นการทดสอบว่าสหสัมพันธ์ในตัวเองในส่วนเหลือทุกช่วงเวลาที่ห่างกัน k มีความเป็นอิสระกันหรือไม่ โดยมีสมมติฐานดังนี้

$$H_0: \rho(a_1) = \rho(a_2) = \dots = \rho(a_k) = 0$$

$$H_1: \rho(a_1) \neq \rho(a_2) \neq \dots \neq \rho(a_k) \neq 0$$

คำนวณตามสมการที่ (3.23) คือ

$$Q_{LB} = T(T+2) \sum (r_j^2 / T-j) \quad (3.23)$$

เมื่อ r_j คือสหสัมพันธ์ในตัวเองลำดับที่ j โดยที่ $j=1, \dots, k$

T คือจำนวนค่าสังเกต

ภายใต้ส่วนเหลือจากการประมาณด้วยแบบจำลอง ARIMA ค่า Q_{LB} มีการแจกแจงแบบไคสแควร์ (χ^2) ด้วยระดับความเป็นอิสระ (Degree of Freedom) เท่ากับจำนวนของสหสัมพันธ์ในตัวเองลบด้วยจำนวนของพารามิเตอร์ Autoregressive (AR) และ Moving Average (MA) ที่ได้มาจากการประมาณหรือ $k-m$

จะยอมรับสมมติฐานหลักเมื่อ $Q_{LB} \leq \chi^2_{\alpha, k-m}$ คือส่วนเหลือเป็นอิสระต่อกันที่ความล่า k และถ้าปฏิเสธสมมติฐานหลักเมื่อ $Q_{LB} > \chi^2_{\alpha, k-m}$ คือเกิดสหสัมพันธ์ในตัวเองอย่างน้อยหนึ่งค่าในส่วนเหลือที่ไม่เท่ากับศูนย์

2) เกณฑ์การเลือกรูปแบบของแบบจำลองที่ดีที่สุด (Information criteria)

ในการหารูปแบบของแบบจำลอง เมื่อได้รูปแบบของแบบจำลองที่เหมาะสมหลายรูปแบบต้องมีแนวทางในการเลือกรูปแบบของแบบจำลองที่ดีที่สุด โดยพิจารณาจากค่า Akaike Information Criterion (AIC) และ Schwartz Criterion (SC) รูปแบบของแบบจำลองที่ให้ค่า AIC และ SC น้อยที่สุดจะเป็นรูปแบบที่ดีที่สุด โดย Akaike Information Criterion (AIC) สามารถคำนวณได้ตามสมการที่ (3.24) และ Schwartz Criterion (SC) คำนวณตามสมการที่ (3.25)

$$\text{Akaike Information Criterion (AIC)} \quad -2l/\eta + 2k/\eta \quad (3.24)$$

$$\text{Schwartz Criterion (SC)} \quad -2l/\eta + k \log \eta / \eta \quad (3.25)$$

โดยที่ k เป็นจำนวนของพารามิเตอร์ที่ทำการประมาณค่า

η เป็นจำนวนของค่าสังเกต

l เป็นค่าของ log likelihood function ที่ใช้พารามิเตอร์ที่ถูกประมาณค่า k ตัว

All rights reserved

3.2.0 การทดสอบความแม่นยำของผลการพยากรณ์ที่ได้

ในการศึกษาครั้งนี้จะทำการประเมินผลด้วย RMSE (Root Mean Square Error) ซึ่งมีสูตรการคำนวณตามลำดับ ดังนี้

RMSE คือ การวัดค่าความแตกต่างระหว่างค่าจริง และค่าที่ประมาณได้จากแบบจำลอง หาก RMSE มีค่าน้อย แสดงว่าแบบจำลองสามารถประมาณค่าประมาณได้ใกล้เคียงกับค่าจริง (Pindyck and Rubinfeld, 1998) ดังนั้นหากนี้มีค่าเท่ากับศูนย์แล้ว จะหมายความว่าไม่เกิดความคลาดเคลื่อนในแบบจำลองนี้เลย RMSE คำนวณได้ดังนี้

$$RMSE = \sqrt{\frac{1}{T} \sum_{t=1}^T (Y_t^s - Y_t^a)^2} \quad (3.26)$$

โดยกำหนด Y_t^s = ค่าประมาณจากแบบจำลอง

Y_t^a = ค่าที่แท้จริง

T = จำนวนคาบเวลาที่ใช้ในการประมาณแบบจำลอง

3.2 วิธีกรวิจัย

1) ดำเนินการปรับข้อมูลให้อยู่ในรูปผลตอบแทนราคาของพลังงานแต่ละชนิด โดยใช้ log (relative price) ซึ่งมีสูตรในการคำนวณดังนี้

$$R_t = \ln (P_t/P_{t-1})$$

โดยที่ R_t คือ ผลตอบแทนของราคา (Price Return)

P_t คือ ราคาพลังงานที่สนใจในคาบเวลาปัจจุบัน

P_{t-1} คือ ราคาพลังงานที่สนใจในคาบเวลาที่ผ่านมา

2) นำข้อมูลผลตอบแทนราคา ซึ่งเป็นข้อมูลทุติยภูมิ (Secondary Data) ของราคาน้ำมันดิบ ราคาก๊าซหุงต้ม และราคาก๊าซธรรมชาติ ซึ่งเป็นข้อมูลลักษณะอนุกรมเวลา (Time Series Data) มาตรวจสอบความนิ่งของข้อมูล โดยวิธี Unit Root Test ดังนี้

ทดสอบความนิ่งของตัวแปรที่นำมาทำการศึกษาดังกล่าวโดยวิธี Dickey - Fuller (DF) หรือ Augmented Dickey - Fuller (ADF) ซึ่งมีสมการในการทดสอบดังนี้

$$R_t = \rho R_{t-1} + \varepsilon_t \quad (3.27)$$

กำหนดให้ R_t คือ ตัวแปรที่เราทำการศึกษา ได้แก่ ผลตอบแทนของราคาพลังงานที่ทำการศึกษา ซึ่งประกอบด้วยราคาน้ำมันดิบ ราคาถ่านหิน และราคาก๊าซธรรมชาติ โดยที่

α, ρ คือ ค่าคงที่

t คือ แนวโน้มเวลา

ε_t คือ ตัวแปรสุ่ม โดยมีการแจกแจงแบบปกติที่เป็นอิสระต่อกันและเหมือนกัน

โดยสมการ (3.28) ถึง (3.30) เป็นสมการที่ใช้ในการทดสอบตามวิธี DF

$$\Delta R_t = \theta R_{t-1} + \varepsilon_t \quad (3.28)$$

$$\Delta R_t = \alpha + \theta R_{t-1} + \varepsilon_t \quad (3.29)$$

$$\Delta R_t = \alpha + \beta t + \theta R_{t-1} + \varepsilon_t \quad (3.30)$$

โดยสมการ (3.31) ถึง (3.33) เป็นสมการที่ใช้ในการทดสอบตามวิธี ADF

$$\Delta R_t = \theta R_{t-1} + \sum_{j=1}^p \lambda_j \Delta R_{t-j} + \varepsilon_t \quad (3.31)$$

$$\Delta R_t = \alpha + \theta R_{t-1} + \sum_{j=1}^p \lambda_j \Delta R_{t-j} + \varepsilon_t \quad (3.32)$$

$$\Delta R_t = \alpha + \beta t + \theta R_{t-1} + \sum_{j=1}^p \lambda_j \Delta R_{t-j} + \varepsilon_t \quad (3.33)$$

การทดสอบ Unit root ทั้ง มีขั้นตอนดังนี้ทั้ง 2 วิธี คือ DF และ ADF มีขั้นตอนดังนี้

- ตั้งสมมติฐานในการทดสอบ คือ $H_0: \theta = 0$ และ $H_1: \theta \neq 0$
- ทำการเปรียบเทียบค่าสถิติที่คำนวณได้กับค่าในตาราง Dickey - Fuller

เปรียบเทียบกับค่าวิกฤติ Mackinnon แบ่งได้เป็น 2 กรณี

- ถ้าไม่สามารถปฏิเสธ H_0 หรือยอมรับ แสดงว่าตัวแปรที่นำมาทดสอบมี Unit root หรือมีลักษณะไม่นิ่ง ต้องมีการทำ Differencing ตัวแปรไปเรื่อย ๆ จนสามารถปฏิเสธ H_0 ได้

- ปฏิเสธ ทำให้ทราบ Order of Integration

3) นำค่าผลตอบแทนราคาที่มีลักษณะนิ่งแล้ว มาสร้างแบบจำลองที่ดีที่สุด เพื่อประมาณการความผันผวนของราคาในอนาคต โดยมีขั้นตอนในการสร้างและประมาณค่าแบบจำลองดังนี้

3.1 สร้าง Correlogram แสดง ACF และ PACF เพื่อใช้ในการพิจารณาเลือกรูปแบบที่เหมาะสมของอนุกรมเวลา RAMA (p,q)

3.2 ประมาณค่าสมการค่าเฉลี่ยโดยเลือกใช้ lag p และ q ที่ได้จากการวิเคราะห์ Correlogram

3.3 ทดลองเลือก p และ q สำหรับรูปแบบที่เหมาะสมของกระบวนการ GARCH (p,q)

3.4 ทำการประมาณค่าพารามิเตอร์ของแบบจำลองที่ได้จากการทดลองเลือกตามข้อ 3.2 และ 3.3 และพิจารณาว่าค่าพารามิเตอร์ที่ได้มีความแตกต่างจากศูนย์อย่างมีนัยสำคัญหรือไม่โดยทดสอบค่า t-statistic และตรวจสอบเงื่อนไขสแตชันนารี (Stationary) ของแบบจำลอง ARMA ถ้าค่าที่ได้ไม่ตรงตามเงื่อนไขให้ทดลองเปลี่ยนค่า p และ q อื่น ๆ แทน

3.5 ตรวจสอบรูปแบบที่เหมาะสมเพื่อพิจารณาว่าส่วนที่เหลือ (Residual) ไม่เกิด Serial Correlation กัน โดยทำการทดสอบค่า Q_{LB} -Statistic โดยถ้ายอมรับสมมติฐานหลักแสดงว่าแบบจำลองมีความเหมาะสมแล้ว

3.6 เลือกรูปแบบที่ดีที่สุดให้กับแบบจำลอง ARMA-EGARCH ARIMA-GARCH-M และ ARIMA-GARCH โดยพิจารณาค่า Akaike Information Criterion (AIC) และ Schwarz Criterion (SC) ที่น้อยที่สุดจะเป็นรูปแบบที่ดีที่สุด

4) นำแบบจำลองที่ดีที่สุดจากแต่ละแนวคิดมาพยากรณ์ผลตอบแทนของราคาในอนาคต และนำค่าที่ได้มาเปรียบเทียบกับข้อมูลจริงเพื่อหาแนวคิดที่ดีที่สุดในการพยากรณ์ผลตอบแทนเพื่อประมาณการความผันผวนของผลตอบแทนของราคาพลังงานแต่ละชนิดโดยใช้เกณฑ์ RMSE (Root Mean Square Error) ที่ต่ำที่สุด ซึ่งแสดงถึงความสามารถในการพยากรณ์ที่สูงกว่า

ลิขสิทธิ์มหาวิทยาลัยเชียงใหม่

Copyright © by Chiang Mai University

All rights reserved