

บทที่ 4

ทฤษฎีและแนวคิดที่ใช้ในการศึกษา

ในการศึกษาถึงความสัมพันธ์ระหว่างราคาปิดของหลักทรัพย์กับช่วงเวลาต่างๆ ในอดีต ความผันผวนของข้อมูลและการนำข้อมูลไปพยากรณ์ราคาที่คาดว่าจะเกิดขึ้นในอนาคต โดยใช้แนวคิดและทฤษฎีเกี่ยวกับการวิเคราะห์อนุกรมเวลาการทดสอบความเป็น Stationary ของข้อมูล และการทดสอบ Unit Root, แบบจำลอง Autoregressive Conditional Heteroscedasticity (ARCH), แบบจำลอง Generalized Autoregressive Conditional Heteroscedasticity (GARCH), แบบจำลอง ARCH-in-mean (ARCH-M), แบบจำลอง GARCH-in-mean (GARCH-M) และการตรวจสอบรูปแบบ ดังต่อไปนี้

4.1 การวิเคราะห์อนุกรมเวลา (Time Series Analysis)

การวิเคราะห์อนุกรมเวลาเป็นวิธีที่ใช้ในการวิเคราะห์ข้อมูลหรือค่าสังเกตที่มีการเปลี่ยนแปลงไปตามลำดับเวลาที่เกิดขึ้น หรือการเปลี่ยนแปลงของตัวแปรในช่วงเวลาที่ผ่านไป ลักษณะของการเปลี่ยนแปลงอาจมีหรือไม่มีรูปแบบก็ได้ แต่ถ้าอนุกรมเวลาแสดงให้เห็นรูปแบบการเปลี่ยนแปลงในช่วงเวลาที่ผ่านมาในอดีต ก็จะทำให้สามารถคาดการณ์ได้ว่าในอนาคตลักษณะการเปลี่ยนแปลงควรอยู่ในรูปแบบใดและสามารถพยากรณ์การเปลี่ยนแปลงข้อมูลในอนาคตได้ การวิเคราะห์ข้อมูลอนุกรมเวลาจะขึ้นอยู่กับการเปลี่ยนแปลงของเวลาในอดีตเป็นพื้นฐาน (ศิริลักษณ์ เล็กสมบูรณ์, 2531)

4.2 การทดสอบความนิ่งของข้อมูล (Stationary) และการทดสอบ Unit root

ข้อมูลอนุกรมเวลาที่มีลักษณะนิ่ง (Stationary) คือข้อมูลที่ค่าเฉลี่ยและความแปรปรวนของกระบวนการเชิงสุ่มนั่น มีค่าคงที่เมื่อเวลาได้เปลี่ยนไปและค่าความแปรปรวนระหว่างสองค่าเวลารีบุนย์พงศ์, 2542) โดยสามารถเขียนเป็นสมการทางคณิตศาสตร์ตามสมการที่ (4.1) – (4.3)

$$\text{ค่าเฉลี่ย (Mean)} : E(x_t) \text{ constant} = \mu \quad (4.1)$$

$$\text{ความแปรปรวน (Variance)} : V(x_t) \text{ constant} = \sigma^2 \quad (4.2)$$

$$\text{ความแปรปรวนร่วม (Covariance)} : \text{cov}(x_t, x_{t+k}) = E(x_t - \mu)(x_{t+k} - \mu) = \sigma_k - \mu \quad (4.3)$$

โดยที่ x_t แทนข้อมูลอนุกรมเวลาซึ่งเป็นกระบวนการเชิงสุ่ม

ในการวิเคราะห์ข้อมูลที่เป็นอนุกรมเวลาอันนี้ ข้อมูลจะต้องมีลักษณะนึง เนื่องด้วยข้อมูลอนุกรมเวลาอันนี้มาจากกระบวนการเชิงสุ่ม (Random Process) การนำข้อมูลอนุกรมเวลาไปใช้โดยไม่ได้ทำการตรวจสอบว่าข้อมูลนั้นมีลักษณะนึงนั้น ถ้าข้อมูลอนุกรมเวลาอันนี้ไม่นึงจะทำให้ค่าสถิติที่เกิดขึ้นมีการแจกแจงไม่มาตรฐาน (Nonstandard Distributions) ซึ่งทำให้การนำไปใช้เปรียบเทียบกับค่าในตารางมาตรฐาน (Standard Tables) ไม่ถูกต้องเนื่องจากค่าต่าง ๆ นั้นมีสมนติฐานว่าข้อมูลนั้นมีการแจกแจงมาตรฐาน (Standard Distributions) ทำให้นำไปสู่การลงความเห็นที่ผิดพลาดและความสัมพันธ์ที่ไม่แท้จริง (Spurious Regression) กล่าวคือค่า R^2 มีค่าสูงมากและได้ค่าสถิติ t มีนัยสำคัญหรือสูงเกินกว่าความเป็นจริง (ทวงศักดิ์ ศรีบุญจิตร และอารีวิบูลย์พงศ์, 2542)

ในการใช้ข้อมูลอนุกรมเวลาจึงต้องทำการทดสอบว่าข้อมูลที่นำมาใช้มีลักษณะนึงหรือไม่ซึ่งจะใช้การทดสอบ Unit Root โดยในการศึกษานี้จะพิจารณาเฉพาะวิธีของ Dickey-Fuller โดยวิธี DF (Dickey-Fuller Test) และ ADF (Augmented Dickey-Fuller Test) ซึ่งกำหนดโดยสมการที่ (4.4)

$$x_t = \rho x_{t-1} + \varepsilon_t \quad (4.4)$$

โดยกำหนดสมมติฐานหลัก

$$H_0 : \rho = 1$$

และ

$$H_1 : |\rho| < 1$$

ถ้ายอมรับ H_0 แสดงว่าข้อมูลมีลักษณะไม่นึง แต่ถ้าปฏิเสธ H_0 แสดงว่าข้อมูลนั้นมีลักษณะนึง และการทดสอบนี้ยังสามารถแปลงสมการได้ดังนี้ คือ

กรณีไม่มีค่าคงที่และแนวโน้มเวลา

$$\Delta x_t = \theta x_{t-1} + \varepsilon_t \quad (4.5)$$

กรณีมีค่าคงที่

$$\Delta x_t = \alpha + \theta x_{t-1} + \varepsilon_t \quad (4.6)$$

กรณีมีทั้งค่าคงที่และแนวโน้มเวลา

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

โดยกำหนดสมมติฐานหลัก

$$H_0 : \theta = 0$$

และสมมติฐานรอง

$$H_1 : \theta < 0$$

การยอมรับ H_0 แสดงว่าข้อมูลมีลักษณะไม่นิ่ง แต่ถ้าปฏิเสธ H_0 แสดงว่าข้อมูลนั้นมีลักษณะนิ่ง นอกจากนี้ถ้าสมการที่ (4.5) (4.6) และ (4.7) นำไปเข้ากระบวนการอัตโนมัติ (Autoregressive Processes) จะได้ดังนี้

$$\text{กรณีไม่มีทั้งค่าคงที่และแนวโน้มเวลา } \Delta x_t = \theta x_{t-1} + \sum_{i=1}^p \Phi_i \Delta x_{t-i} + \varepsilon_t \quad (4.8)$$

$$\text{กรณีมีเฉพาะค่าคงที่ } \Delta x_t = \alpha + \theta x_{t-1} + \sum_{i=1}^p \Phi_i \Delta x_{t-i} + \varepsilon_t \quad (4.9)$$

$$\text{กรณีมีทั้งค่าคงที่และแนวโน้มเวลา } \Delta x_t = \alpha + \beta t + \theta x_{t-1} + \sum_{i=1}^p \Phi_i \Delta x_{t-i} + \varepsilon_t \quad (4.10)$$

ซึ่งสมการที่ (4.8) (4.9) และ (4.10) เป็นการทดสอบ Augmented Dickey-Fuller Test (ADF) นั้นเอง ซึ่งพัฒนามาจากวิธี Dickey-Fuller Test เพื่อแก้ปัญหา Serial Correlation ในการตรวจสอบว่าข้อมูลมีลักษณะนิ่งหรือไม่โดยการเปรียบเทียบค่าสถิติ t ที่คำนวณได้กับค่าวิกฤติ (Critical Value) ในตาราง ADF (Enders, 1995)

4.3 แบบจำลอง Autoregressive Conditional Heteroscedasticity (ARCH)

ในการวิเคราะห์อนุกรมเวลาส่วนใหญ่แล้วจะมีการกำหนด Stochastic Variable ให้มีความแปรปรวนคงที่ (Homoscedastic) ซึ่งในการประยุกต์ใช้กับบางข้อมูลนั้นค่าความแปรปรวนของค่าความคลาดเคลื่อน (Error Term) จะไม่ใช่ฟังก์ชันของตัวแปรอิสระแต่มีค่าเปลี่ยนแปลงไปตามช่วงเวลาขึ้นอยู่กับขนาดของความคลาดเคลื่อนที่เกิดขึ้นในอดีต และในบางงานศึกษา เช่น แบบจำลองของเงินเพื่อ อัตราดอกเบี้ยหรือผลตอบแทนจากการลงทุนที่มีความผันผวน (Volatility) สูง (และความคลาดเคลื่อนขนาดใหญ่) ตามด้วยความเวลาที่มีค่าความผันผวน (Volatility) ต่ำ (และความคลาดเคลื่อนที่มีขนาดเล็ก) สูงได้ว่าความแปรปรวนของค่าความคลาดเคลื่อนจากการตลาดจะขึ้นอยู่กับค่าความผันผวน (Volatility) ของความคลาดเคลื่อนในอดีตที่ผ่านมา (Enders, 1995)

ความเป็นไปได้ในการหาค่าเฉลี่ยและความแปรปรวนของอนุกรมเวลาไปพร้อมกันนั้น ในขั้นตอนการพยากรณ์อย่างมีเส้นทางจะมีความแม่นยำเนื่องจากว่าการพยากรณ์อย่างไม่มีเส้นทางมาก ซึ่งจากแบบจำลอง Autoregressive Moving Average (ARMA) ซึ่งแสดงได้ดังสมการ (4.11)

$$x_t = a_0 + a_1 x_{t-1} + \varepsilon_t \quad (4.11)$$

แล้วต้องการพยากรณ์ x_{t+1} การพยากรณ์อย่างมีเงื่อนไขของ x_{t+1} ดังนี้ คือ

$$E_t x_{t+1} = a_0 + a_1 x_t \quad (4.12)$$

ถ้าเราใช้ค่าเฉลี่ยอย่างมีเงื่อนไขในการพยากรณ์ x_{t+1} ค่าความคลาดเคลื่อนของความแปรปรวนอย่างมีเงื่อนไขที่พยากรณ์ได้ดังสมการ (4.13)

$$E_t [(x_{t+1} - a_0 - a_1 x_t)^2] = E_t \varepsilon_{t+1}^2 = \sigma^2 \quad (4.13)$$

ถ้าเปลี่ยนไปใช้การพยากรณ์อย่างไม่มีเงื่อนไขแล้ว ผลที่จะใช้เป็นค่าเฉลี่ยในช่วง Long-Run ของลำดับ $\{x_t\}$ ซึ่งเท่ากับ $\frac{a_0}{(1-a_1)}$ จะได้ค่าความคลาดเคลื่อนของการพยากรณ์อย่างไม่มีเงื่อนไขตามสมการ (4.14) คือ

$$\begin{aligned} E\left\{\left[x_{t+1} - \frac{a_0}{1-a_1}\right]^2\right\} &= E[(\varepsilon_{t+1} + a_1 \varepsilon_t + a_1^2 \varepsilon_{t-1} + a_1^3 \varepsilon_{t-2} + \dots)^2] \\ &= \frac{\sigma^2}{(1-a_1^2)} \end{aligned} \quad (4.14)$$

เมื่อ $\frac{1}{(1-a_1^2)} > 1$ ค่าความแปรปรวนที่ได้จากการพยากรณ์อย่างไม่มีเงื่อนไขจะสูงกว่าแบบมีเงื่อนไข ดังนั้น ในการพยากรณ์อย่างมีเงื่อนไขจะมีความหมายมากกว่า ในลักษณะเดียวกัน ถ้าความแปรปรวนของ $\{\varepsilon_t\}$ ไม่เป็นค่าคงที่ จะสามารถประมาณค่าแนวโน้มของการเปลี่ยนแปลงความแปรปรวนโดยใช้ ARMA model อธิบายได้โดยให้ $\{\hat{\varepsilon}_t\}$ แทนส่วนที่เหลือ (Residuals) ที่ได้จากการประมาณจากสมการ (4.11) ดังนั้น ค่าความแปรปรวนอย่างมีเงื่อนไข (Conditional Variance) ของ x_{t+1} จะได้ดังสมการ (4.15)

$$\begin{aligned} \text{Var}(x_{t+1} | x_t) &= E_t [(x_{t+1} - a_0 - a_1 x_t)^2] \\ &= E_t \varepsilon_{t+1}^2 \end{aligned} \quad (4.15)$$

และจากที่ให้ $E_t \hat{\varepsilon}_{t+1}^2$ เท่ากับ σ_{t+1}^2 จึงแสดงว่าค่าความแปรปรวนอย่างมีเงื่อนไขไม่ใช่ค่าคงที่และจะได้แบบจำลองในการประมาณค่าส่วนที่เหลือ (Residuals) ออกมานั้นสมการ (4.16)

$$\hat{\varepsilon}_t^2 = \alpha_0 + \alpha_1 \hat{\varepsilon}_{t-1}^2 + \dots + \alpha_q \hat{\varepsilon}_{t-q}^2 + v_t \quad (4.16)$$

เมื่อ v_t = white noise process

ถ้าค่าของ $\alpha_1, \alpha_2, \dots, \alpha_q$ เท่ากับศูนย์ ค่าความแปรปรวนจากการประมาณจะเท่ากับค่าคงที่ α_0 อีกนัยหนึ่ง คือ ค่าความแปรปรวนอย่างมีเงื่อนไขของ x_t จะมีการเปลี่ยนแปลงตลอดไปในสมการ (4.16) ดังนั้น จะสามารถใช้สมการ (4.16) ในการพยากรณ์ค่าความแปรปรวนอย่างมีเงื่อนไขที่เวลา $t+1$ ดังสมการ (4.17)

$$E_t \hat{\varepsilon}_{t+1}^2 = \alpha_0 + \alpha_1 \hat{\varepsilon}_t^2 + \alpha_2 \hat{\varepsilon}_{t-1}^2 + \dots + \alpha_q \hat{\varepsilon}_{t+1-q}^2 \quad (4.17)$$

หากเหตุผลที่กล่าวมา สมการที่ (4.16) เรียกว่า Autoregressive Conditional Heteroscedastic (ARCH) model และสมการ (4.17) เป็น ARCH(q) สมการ (4.17) ค่า $E_t \hat{\varepsilon}_{t+1}^2$ หรือ σ_{t+1}^2 จะประกอบด้วย 2 องค์ประกอบ คือค่าคงที่และความผันผวน (Volatility) ในความเวลาที่ผ่านมา ซึ่งเขียนได้เป็นส่วนเหลือกำลังสองของ cabin ในอดีต (ARCH term) ส่วนค่าสัมประสิทธิ์ ($\alpha_0, \alpha_1, \dots, \alpha_q$) สามารถหาค่าได้โดยใช้วิธี Maximum Likelihood

4.4 แบบจำลอง Generalized Autoregressive Conditional Heteroscedasticity (GARCH)

Bollerslev (1986) ได้ขยายมาจาก ARCH model โดยมีขั้นตอน คือให้ค่าความคลาดเคลื่อนจากกระบวนการเป็นดังสมการ (4.18)

$$\varepsilon_t = v_t \sqrt{h_t} \quad (4.18)$$

เมื่อ $\sigma_v^2 = 1$

และ

$$h_t = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^p \beta_i h_{t-i} \quad (4.19)$$

เมื่อ $\{v_t\}$ คือ white noise process ที่เป็นค่าอิสระจากเหตุการณ์ในอดีต (ε_{t-i}) ค่าเฉลี่ยอย่างมีเงื่อนไขและไม่มีเงื่อนไขของ ε_t จะมาจากการ h_t ในสมการ (4.19)

GARCH (p,q) นั้นใช้กระบวนการ Autoregressive และ Moving Average ในการหา Heteroscedastic Variance ได้ดังสมการ (4.20)

$$\varepsilon_{t-i} \varepsilon_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^p \beta_i h_{t-i} \quad (4.20)$$

ถ้ากำหนดให้ค่า $p = 0$ และ $q = 1$ จะได้เป็น ARCH(1) หรือถ้าค่า β_i ทั้งหมดมีค่าเป็น 0 แบบจำลอง GARCH(p,q) จะเทียบเท่ากับแบบจำลอง ARCH(q) คุณสมบัติที่สำคัญของแบบจำลอง GARCH คือค่าความแปรปรวนอย่างมีเงื่อนไขของ disturbances ของค่า x_t สร้างขึ้นมาจากการกระบวนการ ARMA จึงสามารถคาดได้ว่าส่วนเหลือจากการทำ ARMA จะแสดงถึงรูปแบบคุณลักษณะเดียวกัน เช่น ถ้าการประมาณค่า $\{x_t\}$ ด้วยกระบวนการ ARMA ค่าสหสมพันธ์ในตัวเอง (Autocorrelation Function หรือ ACF) ซึ่งเป็นสหสมพันธ์ระหว่างตัวแปรสูมที่หน่วยเวลาห่างกันของกระบวนการเดียวกันและสหสมพันธ์ในตัวเองส่วนย่อย (Partial Autocorrelation Function หรือ PACF) (รายละเอียดดังภาคผนวก ๑) ของส่วนเหลือควรจะบ่งถึงกระบวนการ white noise และ ACF ของกำลังสองของส่วนเหลือนำมาช่วยในการระบุถึงลำดับของกระบวนการ GARCH

4.5 แนวคิดเกี่ยวกับแบบจำลอง ARCH-in-mean (ARCH-M)

พื้นฐานจากแนวคิด ARCH ได้มีการขยายเพื่อให้ค่าเฉลี่ยของลำดับอนุกรมขึ้นอยู่กับความแปรปรวนอย่างมีเงื่อนไขของตัวเอง ซึ่งเรียกว่า ARCH-M เพื่อที่จะมีความเหมาะสมในการศึกษา โดยมีหลักการพื้นฐาน คือผู้ที่มีลักษณะหลีกเลี่ยงความเสี่ยง (Risk Averter) จะต้องการชดเชยสำหรับการถือสินทรัพย์ที่มีความเสี่ยง (Risk Premium) เมื่อให้ความเสี่ยงในทรัพย์สินสามารถวัดค่าได้จากความแปรปรวนของผลตอบแทน ค่าชดเชยความเสี่ยงจะเป็นฟังก์ชันเพิ่มของความแปรปรวนอย่างมีเงื่อนไขของผลตอบแทน Engle (1987) ที่ได้แสดงแนวคิดนี้โดยนำส่วนที่เหลือของผลตอบแทนจากการถือครองทรัพย์สินที่มีความเสี่ยงดังสมการ (4.21)

$$x_t = \mu_t + \varepsilon_t \quad (4.21)$$

- เมื่อ x_t = ผลตอบแทนส่วนเกินจากการถือครองทรัพย์สินในระยะยาวเบรี่ยบเที่ยบกับหนึ่งคาบเวลาของผลตอบแทนข้างต้น
- μ_t = ค่าคาดคะเนความเสี่ยงที่จำเป็นในการนิ่มน้ำผู้ที่มีลักษณะหลีกเลี่ยงความเสี่ยงให้ถือครองทรัพย์สินในระยะยาวแทนที่จะเป็นแค่คาบเวลาเดียว
- ε_t = Unforecastable Shock ของส่วนที่เหลือของผลตอบแทนในการถือทรัพย์สินในระยะยาว

ในการอธิบายสมการ (4.21) จะให้ค่าคาดหวังของส่วนที่เหลือของผลตอบแทนจากการถือครองทรัพย์สินในระยะยาวมีค่าเท่ากับค่าคาดคะเนความเสี่ยงดังสมการ (4.22)

$$E_{t-1}x_t = \mu_t \quad (4.22)$$

สมมติว่าค่าคาดคะเนความเสี่ยงเป็นฟังก์ชันเพิ่มของความแปรปรวนอย่างมีเงื่อนไขของ ε_t อีกนัยหนึ่ง คืออย่างค่าความแปรปรวนอย่างมีเงื่อนไขของผลตอบแทนมีขนาดใหญ่ ผลตอบแทนของการนิ่มน้ำให้คนหันมาถือครองทรัพย์สินในระยะยาวก็จะยิ่งมีค่ามากขึ้นตาม ถ้า h_t เป็นความแปรปรวนอย่างมีเงื่อนไขของ ε_t ค่าคาดคะเนความเสี่ยงสามารถแสดงได้เป็น

$$\mu_t = \beta + \delta h_t, \delta > 0 \quad (4.23)$$

เมื่อ h_t คือ ARCH(q) process

$$h_t = \alpha_0 + q \sum_{i=0}^q \alpha_i \varepsilon_{t-i}^2 \quad (4.24)$$

จากสมการ (4.21) (4.23) และ (4.24) ประกอบขึ้นเป็นพื้นฐานของแบบจำลอง ARCH-M จากสมการ (4.21) และ (4.23) ค่าเฉลี่ยอย่างมีเงื่อนไขของ x_t จะขึ้นอยู่กับค่าความแปรปรวนอย่างมีเงื่อนไข h_t จากสมการ (4.24) ความแปรปรวนอย่างมีเงื่อนไขได้จากกระบวนการ ARCH(q) ซึ่งเป็นการอธิบายว่า ถ้าความแปรปรวนอย่างมีเงื่อนไขเป็นค่าคงที่ (เช่น ถ้า

$\alpha_1 = \alpha_2 = \dots = \alpha_q = 0$) แบบจำลอง ARCH-M จะกลับไปสู่กรณีเดิมของค่าคาดคะเนความเสี่ยงคงที่

4.6 แบบจำลอง GARCH-in-mean (GARCH-M)

จากแบบจำลอง GARCH(p,q) ในสมการ (4.19) ความแปรปรวนอย่างมีเงื่อนไขของข้อมูลอนุกรมเวลาขึ้นอยู่กับส่วนเหลือกำลังสองของกระบวนการนี้ (Bollerslev, 1986) Engle (1987) ขยายแนวคิดนี้โดยให้ค่าเฉลี่ยอย่างมีเงื่อนไขเป็นพิงก์ชันของความแปรปรวนอย่างมีเงื่อนไขโดยรู้จักกันในชื่อ GARCH-in-mean หรือ GARCH-M ผลตอบแทนจากหลักทรัพย์สามารถแสดงในรูปของแบบจำลอง GARCH(p,q)-M ดังสมการ (4.25) ถึง (4.27)

$$x_t = \mu_t + \delta_1 h_t^{1/2} + \varepsilon_t \quad (4.25)$$

$$\varepsilon_t / \psi_{t-1} \sim N(0, h_t) \quad (4.26)$$

$$h_t = \varpi + \sum_{i=1}^p \beta_i h_{t-i} + \sum_{i=1}^q \alpha_i (\varepsilon_{t-i})^2 \quad (4.27)$$

เมื่อ x_t คือผลตอบแทนจากหลักทรัพย์

μ_t คือค่าเฉลี่ย x_t อย่างมีเงื่อนไขต่อข้อมูลในอดีต (ψ_{t-1}) และตามสมการข้อจำกัด $\gamma > 0, \alpha_i > 0$ และ $\beta_i \geq 0$ เพื่อให้แน่ใจว่าความแปรปรวนอย่างมีเงื่อนไข (h_t) นั้นเป็นบวก

$h_t^{1/2}$ ในสมการที่ (4.5) เพื่อใช้แสดงความสัมพันธ์โดยตรงถึง trade off ระหว่างความเสี่ยงและผลตอบแทนที่คาดหวัง

อิทธิพลอย่างมีนัยสำคัญของความผันผวนในผลตอบแทนจากหลักทรัพย์ถูกตรวจจับด้วยสัมประสิทธิ์ $h_t^{1/2}$ (δ_1) ในสมการ (4.25) ซึ่งอธิบายแทนดัชนีของความสัมพันธ์ของการหลอกเลี้ยงความเสี่ยง ค่าสัมประสิทธิ์ δ_1 ที่เป็นบวกอย่างมีนัยสำคัญบอกร่องรอยผลุนในหลักทรัพย์ เมื่อเช็คกับระดับความเสี่ยงที่สูงขึ้นก็ต้องการค่าคาดคะเนความเสี่ยงที่มากขึ้นตามไปด้วย

4.7 การตรวจสอบรูปแบบ (Diagnostic Checking)

การสร้างสมการพร้อมทั้งประมาณค่าพารามิเตอร์แล้วนั้น จะต้องทำการตรวจสอบรูปแบบว่าสมการพยากรณ์ที่ได้มา มีความเหมาะสมหรือไม่ และรูปแบบใดของสมการที่ดีที่สุด โดยใช้การทดสอบต่าง ๆ ดังนี้

4.7.1 การทดสอบ Box-Pierce Q -Statistics

เป็นการทดสอบว่าสหสมพันธ์ในตัวเองในส่วนเหลือทุกช่วงเวลาที่ห่างกัน K มีความเป็นอิสระต่อกันหรือไม่

โดยมีสมมติฐานหลัก $H_0 : \rho_1(\hat{a}_t) = \rho_2(\hat{a}_t) = \dots = \rho_k(\hat{a}_t) = 0$

และสมมติฐานรอง $H_1 : \rho_1(\hat{a}_t) \neq \rho_2(\hat{a}_t) \neq \dots \neq \rho_k(\hat{a}_t) \neq 0$

คำนวณตามสมการที่ (4.28) คือ

$$Q\text{-stat} = T \sum_{j=1}^k P_j^2 \quad (4.28)$$

เมื่อ P_j คือสหสมพันธ์ในตัวเองลำดับที่ j โดยที่ $j = 1, \dots, k$

T คือจำนวนของค่าสังเกต (Observations)

ภายใต้ส่วนเหลือจากการประมาณด้วยแบบจำลอง ARIMA ค่า Q-stat มีการแจกแจงแบบไคสแควร์ (χ^2) ด้วยระดับความเป็นอิสระ (Degree of Freedom) เท่ากับจำนวนของสหสมพันธ์ในตัวเอง ลบด้วยจำนวนของพารามิเตอร์ Autoregressive (AR) และ Moving Average (MA) ที่ได้มาจากการประมาณหรือ $k-m$

และจะยอมรับสมมติฐานหลักเมื่อ $Q\text{-stat} \leq \chi^2_{\alpha, k-m}$ คือส่วนเหลือเป็นอิสระต่อกันที่ความล่า k และถ้าปฎิเสธสมมติฐานหลักเมื่อ $Q\text{-stat} > \chi^2_{\alpha, k-m}$ คือ เกิดสหสมพันธ์ในตัวเองอย่างน้อยหนึ่งค่าในส่วนเหลือที่ไม่เท่ากับศูนย์

4.7.2 เกณฑ์การเลือกรูปแบบของแบบจำลองที่ดีที่สุด (Information Criteria)

ในการหารูปแบบของแบบจำลอง เมื่อได้รูปแบบของแบบจำลองที่เหมาะสมหมาย รูปแบบจึงต้องมีแนวทางในการเลือกรูปแบบของแบบจำลองที่ดีที่สุด โดยพิจารณาค่า Akaike Information Criterion (AIC) รูปแบบที่ให้ค่า AIC น้อยที่สุดจะเป็นรูปแบบที่ดีที่สุด โดย Akaike Information Criterion (AIC) คำนวณตามสมการที่ (4.29)

$$\text{Akaike Information Criterion (AIC)} = -2\ell/\theta + 2k/\theta \quad (4.29)$$

โดยที่ k เป็นจำนวนของพารามิเตอร์ที่ทำการประมาณค่า

θ เป็นจำนวนของค่าสังเกต

ℓ เป็นค่าของ log likelihood function ที่ใช้พารามิเตอร์ที่ถูกประมาณค่า k ตัว