

บทที่ 4

ทฤษฎีและแนวคิดที่ใช้ในการศึกษา

ในการศึกษาถึงความสัมพันธ์ระหว่างราคาปีคงของหลักทรัพย์กับช่วงเวลาต่างๆ ในอดีต ความผันผวนของข้อมูลและการนำข้อมูลไปพยากรณ์ราคาที่คาดว่าจะเกิดขึ้นในอนาคต โดยใช้แนวคิดและทฤษฎีเกี่ยวกับการวิเคราะห์อนุกรมเวลาการทดสอบความเป็น Stationary ของข้อมูล และการทดสอบ Unit Root, แบบจำลอง Autoregressive Conditional Heteroskedasticity (ARCH), แบบจำลอง Generalized Autoregressive Conditional Heteroskedasticity (GARCH), แบบจำลอง ARCH-in-mean (ARCH-M), แบบจำลอง GARCH-in-mean (GARCH-M) และการตรวจทดสอบรูปแบบดังต่อไปนี้

4.1 การวิเคราะห์อนุกรมเวลา (Time Series Analysis)

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

4.2 การทดสอบความนิ่งของข้อมูล (Stationary) และการทดสอบ Unit root

ข้อมูลอนุกรมเวลาที่มีลักษณะนิ่ง (Stationary) คือข้อมูลที่ค่าเฉลี่ยและความแปรปรวนของกระบวนการเชิงสุ่มนั้นมีค่าคงที่เมื่อเวลาได้เปลี่ยนไปและค่าความแปรปรวนระหว่างสองค่าเวลา

ขึ้นอยู่กับความล้าหลัง (Lag) ระหว่างความเวลาทั้งสอง (ทรงศักดิ์ ศรีบุญจิตร์ และอารี วินูลย์พงศ์, 2542) โดยสามารถเขียนเป็นสมการทางคณิตศาสตร์ตามสมการที่ (4.1)-(4.3) ได้ดังนี้

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

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

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

โดยที่ x_t แทนข้อมูลอนุกรมเวลาซึ่งเป็นกระบวนการเชิงสุ่ม

ในการวิเคราะห์ข้อมูลที่เป็นอนุกรมเวลาในนี้ ข้อมูลจะต้องมีลักษณะนิ่งนี้องค์วิชัยข้อมูลอนุกรมเวลาในนี้มาจากการกระบวนการเชิงสุ่ม (Random Process) การนำข้อมูลอนุกรมเวลาไปใช้โดยไม่ได้ทำการตรวจสอบว่าข้อมูลนี้มีลักษณะนิ่งนี้ ถ้าข้อมูลอนุกรมเวลาในนี้ไม่นิ่งจะทำให้ค่าสถิติที่เกิดขึ้นมีการแยกແง้ไม่มาตรฐาน (Nonstandard Distributions) ซึ่งทำให้การนำไปใช้เปรียบเทียบกับค่าในตารางมาตรฐาน (Standard Tables) ไม่ถูกต้องเนื่องจากค่าต่างๆนี้มีสมบูรณ์ฐานว่าข้อมูลนี้มีการแยกແง้มาตรฐาน (Standard Distributions) ทำให้นำไปสู่การลงความเห็นที่ผิดพลาดและความสัมพันธ์ที่ไม่แท้จริง (Spurious Regression) ก่อรากีอค่า R^2 มีค่าสูงมากและได้ค่าสถิติ, มีนัยสำคัญหรือสูงเกินกว่าความเป็นจริง (ทรงศักดิ์ ศรีบุญจิตร์ และอารี วินูลย์พงศ์, 2542)

ในการใช้ข้อมูลอนุกรมเวลาจึงต้องทำการทดสอบว่าข้อมูลที่นำมาใช้มีลักษณะนิ่งหรือไม่ซึ่งจะใช้การทดสอบ 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 แสดงว่าข้อมูลมีลักษณะไม่นิ่ง แต่ถ้าปฏิเสธ H_0 แสดงว่าข้อมูลนี้มีลักษณะนิ่ง และการทดสอบนี้ยังสามารถแปลงสมการได้ดังนี้ คือ

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

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

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

โดยกำหนดสมมติฐานหลัก $H_0 : \theta = 0$

และสมมติฐานรอง $H_1 : \theta < 0$

การยอมรับ H_0 แสดงว่าข้อมูลมีลักษณะไม่นิ่ง แต่ถ้าปฏิเสธ H_0 และแสดงว่าข้อมูลนั้นมีลักษณะนิ่ง นอกจากนี้ถ้าสมการที่ (4.5) (4.6) และ (4.7) นำไปใช้กระบวนการอัตโนมัติ (Autoregressive Processes) จะได้คังนี้

$$\text{กรณีไม่มีทึ่งค่าคงที่และแนวโน้มเวลา } \Delta x_t = \theta x_{t-1} + \sum_{i=1}^{\rho} \phi_i \Delta x_{t-i} + \varepsilon_t \quad (4.8)$$

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

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

ซึ่งสมการที่ (4.8) (4.9) และ (4.10) เป็นการทดสอบ Augmented Dickey-Fuller Test (ADF) นั่นเอง ซึ่งพัฒนามาจากวิธี Dickey-Fuller Test เพื่อแก้ปัญหา Serial Correlation ในการตรวจสอบว่าข้อมูลมีลักษณะนิ่งหรือไม่ โดยการเบริญเทียนค่าสถิติ t ที่คำนวณได้กับค่าวิกฤติ (Critical Value) ในตาราง ADF

4.3 แบบจำลอง Autoregressive Conditional Heteroskedasticity (ARCH)

ในการวิเคราะห์อนุกรมเวลาต่างๆ ในทฤษฎีแล้วจะมีการกำหนด Stochastic Variable ให้มีความแปรปรวนคงที่ (Homoskedastic) ซึ่งในการประยุกต์ใช้กับบางข้อมูลนั้นค่าความแปรปรวนของค่าความคลาดเคลื่อน (Error Term) จะไม่ใช้ฟังก์ชันของค่าวัปรอิสระแต่มีค่าเปลี่ยนแปลงไปตามช่วงเวลาซึ่งอยู่กับขนาดของความคลาดเคลื่อนที่เกิดขึ้นในอดีต และในบางงานศึกษา เช่น แบบจำลองของเงินเพื่อ อัตราดอกเบี้ยหรือผลตอบแทนจากตลาดหลัก ในบางสถานะจะมีค่าความผันผวน (Volatility) สูง (และความคลาดเคลื่อนขนาดใหญ่) ตามด้วยสถานะที่มีค่าความผันผวน (Volatility) ต่ำ (และมีความคลาดเคลื่อนที่มีขนาดเล็ก) สรุปได้ว่าค่าความแปรปรวนของค่าความคลาดเคลื่อนจากการทดลองจะขึ้นอยู่กับค่าความผันผวน (Volatility) ของความคลาดเคลื่อนในอดีตที่ผ่านมา (Enders, 1995)

ความเป็นไปได้ในการหาค่าเฉลี่ยและความแปรปรวนของอนุกรมเวลาไปพร้อมกันนั้น ในขั้นตอนการพยากรณ์อย่างมีเงื่อนไขจะมีความแม่นยำเหนือกว่าการพยากรณ์อย่างไม่มีเงื่อนไขมาก ซึ่งจากแบบจำลอง Autoregressive Moving Average (ARMA) ซึ่งแสดงให้ดังสมการ (4.11)

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

และต้องการพยากรณ์ 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)

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

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

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

เมื่อ $\frac{1}{(1-a_1^2)} > 1$ ค่าความแปรปรวนที่ได้จากการพยากรณ์อย่างไม่มีเงื่อนไขจะสูงกว่าแบบมีเงื่อนไข ดังนั้นในการพยากรณ์อย่างมีเงื่อนไขจึงมีความหมายมากกว่า ในลักษณะเดียวกันถ้าความแปรปรวนของ $\{\epsilon_t\}$ ไม่เป็นค่าคงที่ จะสามารถประมาณค่าแนวโน้มของการเปลี่ยนแปลงความแปรปรวนโดยใช้ ARMA model อธิบายได้โดยให้ $\{\hat{\epsilon}_t\}$ แทนส่วนที่เหลือ (Residuals) ที่ได้จากการประมาณจากสมการ (4.11) ดังนั้นค่าความแปรปรวนอย่างมีเงื่อนไข (Conditional Variance) ของ x_{t+1} จะได้ดังสมการ (4.15)

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

และจากที่ให้ $E_t \in_{t+1}^2$ เท่ากับ σ_{t+1}^2 จึงแสดงว่าค่าความแปรปรวนอย่างมีเงื่อนไขไม่ใช่ค่าคงที่และจะได้แบบจำลองในการประมาณค่าส่วนที่เหลือ (Residuals) ของ模型ดังสมการ (4.16)

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

เมื่อ v_t = white noise process

ถ้าค่าของ $\alpha_1, \alpha_2, \dots, \alpha_q$ เท่ากับศูนย์ ค่าความแปรปรวนจากการประมาณจะเท่ากับค่าคงที่ α_0 อีกนัยหนึ่ง คือ ค่าความแปรปรวนอย่างมีเงื่อนไขของ x_t จะมีการเปลี่ยนแปลงตลอดเวลา กับ Autoregression ในสมการ (4.16) ดังนั้นสามารถใช้สมการ (4.16) ในการพยากรณ์ค่าความแปรปรวนอย่างมีเงื่อนไขที่เวลา $t+1$ ดังสมการ (4.17)

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

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

4.4 แบบจำลอง Generalized Autoregressive Conditional Heteroskedasticity (GARCH)

Bollerslev (1986) ได้ขยายมาจาก ARCH model โดยมีขั้นตอน คือ ให้ค่าความคาดเคลื่อนจากกระบวนการเป็นดังสมการ (4.18)

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

เมื่อ $\sigma_v^2 = 1$

และ

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

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

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

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

ถ้ากำหนดให้ค่า $p = 0$ และ $q = 1$ จะได้เป็น ARCH(1) หรือถ้าค่า β_1 ทั้งหมดมีค่าเป็น 0 แบบจำลอง GARCH(p,q) จะเทียบเท่ากับแบบจำลอง ARCH (q) คุณสมบัติสำคัญของแบบจำลอง GARCH คือค่าความแปรปรวนของย่างมีเงื่อนไขของ disturbances ของค่า x_t สร้างขึ้นมาจากกระบวนการ ARMA จึงสามารถคาดได้ว่าส่วนเหลือของการทำ ARMA จะแสดงถึงรูปแบบคุณลักษณะเดียวกัน เช่น ถ้าการประมาณค่า $\{x_t\}$ ด้วยกระบวนการ ARMA ค่าสหสัมพันธ์ในตัวเอง (Autocorrelation Function หรือ ACF) ซึ่งเป็นสหสัมพันธ์ระหว่างตัวแปรสุ่มที่หน่วยวเวลาห่างกันของกระบวนการเดียวกันและสหสัมพันธ์ในตัวเองส่วนย่อย (Partial Autocorrelation Function หรือ PACF) (รายละเอียดดังภาคผนวก ง) ของส่วนเหลือควรจะบ่งถึงกระบวนการ white noise และ ACF ของกำลังสองของส่วนเหลือนำมาช่วยในการระบุถึงลำดับของกระบวนการ GARCH

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

พื้นฐานจากแนวคิด ARCH ได้มีการขยายเพื่อให้ค่าเฉลี่ยของลำดับอนุกรมขึ้นอยู่กับความแปรปรวนของย่างมีเงื่อนไขของตัวเอง ซึ่งเรียกว่า ARCH-M เพื่อที่จะมีความเหมาะสมในการศึกษาโดยมีหลักการพื้นฐาน คือ ผู้ที่มีลักษณะหลีกเลี่ยงความเสี่ยง (Risk Averter) จะต้องการจะเรียกสำหรับการถือสินทรัพย์ที่มีความเสี่ยง (Risk Premium) เมื่อให้ความเสี่ยงในทรัพย์สินสามารถวัดค่าได้จากความแปรปรวนของผลตอบแทน ค่าเฉลี่ยความเสี่ยงจะเป็นพิจารณาเพิ่มของความแปรปรวนอย่างมีเงื่อนไขของผลตอบแทน Engle et al. (1987) ที่ได้แสดงแนวคิดนี้โดยนำเสนอส่วนที่เหลือของผลตอบแทนจากการถือครองทรัพย์สินที่มีความเสี่ยง ดังสมการ (4.21)

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

เมื่อ x_t = ผลตอบแทนส่วนเกินจากการถือครองทรัพย์สินในระยะยาวเบริญเที่ยงกับหนึ่งค่าความเวลาของผลตอบแทนอ้างอิง

μ_t = ค่าคาดคะเนความเสี่ยงที่จำเป็นในการโอนน้ำผู้ที่มีลักษณะหลักเดี่ยงความเสี่ยงให้ถือครองทรัพย์สินในระยะยาวแทนที่จะเป็นแค่ค่าความเดียว

ϵ_t = Unforecastable Shock ของส่วนที่เหลือของผลตอบแทนในการถือครองทรัพย์สินในระยะยาว

ในการอธิบายสมการ (4.21) จะให้ค่าคาดหวังของส่วนที่เหลือของผลตอบแทนจากการถือครองทรัพย์สินในระยะยาวมีค่าเท่ากับค่าคาดคะเนความเสี่ยงดังสมการ (4.22)

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

สมมติว่า ค่าคาดคะเนความเสี่ยงเป็นฟังก์ชันเพิ่มของความแปรปรวนอย่างมีเสื่อนໄขของ ϵ , อีกนัยหนึ่ง คือ ยิ่งค่าความแปรปรวนอย่างมีเสื่อนໄขของผลตอบแทนมีขนาดใหญ่ ผลตอบแทนของ การโอนน้ำให้คนหันมาถือครองทรัพย์สินในระยะยาวก็จะยิ่งมีค่ามากขึ้นตาม ถ้า h_t เป็นความแปรปรวนอย่างมีเสื่อนໄขของ ϵ , ค่าคาดคะเนความเสี่ยงสามารถแสดงได้เป็น

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

เมื่อ h_t คือ ARCH(q) process

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

จากสมการ (4.21) (4.23) และ (4.24) ประกอบเข้าเป็นพื้นฐานของแบบจำลอง ARCH-M จากสมการ (4.21) และ (4.23) ค่าเฉลี่ยอย่างมีเสื่อนໄขของ x_t จะขึ้นอยู่กับค่าความแปรปรวนอย่างมีเสื่อนໄข h_t จากสมการ (4.24) ความแปรปรวนอย่างมีเสื่อนໄขได้จากการวนการ ARCH(q) ซึ่งเป็นการอธิบายว่า ถ้าความแปรปรวนอย่างมีเสื่อนໄขเป็นค่าคงที่ (เช่น ถ้า $\alpha_1 = \alpha_2 = \dots = \alpha_q = 0$) แบบจำลอง ARCH-M จะกลับไปสู่กรณีเดิมของค่าคาดคะเนความเสี่ยงคงที่

4.6 แบบจำลอง GARCH – in – mean (GARCH-M)

หากแบบจำลอง GARCH(p,q) ในสมการ (4.19) ความแปรปรวนอย่างมีเงื่อนไขของข้อมูลอนุกรมเวลาขึ้นอยู่กับส่วนเหลือกำลังสองของกระบวนการนี้ (Bollerslev, 1986) Engel(1987) ขยายแนวคิดนี้โดยให้คำเฉลี่ยอย่างมีเงื่อนไขเป็นพัจกรชั้นของความแปรปรวนอย่างมีเงื่อนไขโดยรู้จักกันในชื่อ GARCH-in-mean หรือ GARCH-M ผลตอบแทนจากหลักทรัพย์สามารถแสดงในรูปของแบบจำลอง GARCH(p,q)-M ดังสมการ (4.25) ถึง (4.27)

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

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

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

- เมื่อ x_t คือ ผลตอบแทนจากหลักทรัพย์
 μ_t คือ ค่าเฉลี่ย x_t อย่างมีเงื่อนไขค่าข้อมูลในอดีต (ψ_{t-1}) และความสมการข้อจำกัด $\omega > 0, \alpha_i > 0$ และ $\beta_i \geq 0$ เพื่อให้แน่ใจว่าค่าความแปรปรวนอย่างมีเงื่อนไข (h_t) นั้นเป็นบวก
 $h_t^{1/2}$ ในสมการที่ (4.25) เพื่อใช้แสดงความสัมพันธ์โดยตรงถึง trade off ระหว่างความเสี่ยงและผลตอบแทนที่คาดหวัง

อิทธิพลอย่างมีนัยสำคัญของความผันผวนในผลตอบแทนจากหลักทรัพย์ถูกตรวจสอบด้วยสัมประสิทธิ์ $h_t^{1/2}$ (δ_1) ในสมการ (4.25) ซึ่งอธิบายแทนค่าที่ของความสัมพันธ์ของการหลีกเลี่ยงความเสี่ยง ค่าสัมประสิทธิ์ δ_1 ที่เป็นบวกอย่างมีนัยสำคัญของถึงผู้ลงทุนในหลักทรัพย์เมื่อเพรียบเทียบระดับความเสี่ยงที่สูงขึ้นกับต้องการค่าคาดคะเนความเสี่ยงที่มากขึ้นตามไปด้วย

4.7 การตรวจสอบรูปแบบ (Diagnostic Checking)

การสร้างสมการพร้อมทั้งประเมินค่าพารามิเตอร์แล้วนั้น จะต้องทำการตรวจสอบรูปแบบว่าสมการพยากรณ์ที่ได้มา มีความเหมาะสมหรือไม่ และรูปแบบใดของสมการที่ดีที่สุด โดยใช้การทดสอบค่าทางๆ ดังนี้

4.7.1 การทดสอบ Ljung-Box Q-Statistics

การทดสอบ Ljung-Box Q-Statistics เป็นการทดสอบว่าสหสัมพันธ์ในตัวของในส่วนเหลือทุกช่วงเวลาที่ห่างกัน k มีความเป็นอิสระกันหรือไม่ โดยมีสมมติฐานดังนี้

$$H_0: \hat{\rho}_1(a_t) = \hat{\rho}_2(a_t) = \dots = \hat{\rho}_k(a_t) = 0$$

และ $H_1: \hat{\rho}_1(a_t) \neq \hat{\rho}_2(a_t) \neq \dots \neq \hat{\rho}_k(a_t) \neq 0$

คำนวณตามสมการที่ (4.28) คือ

$$Q_{LB} = T(T+2) \sum_{j=1}^k \frac{r_j^2}{T-j} \quad (4.28)$$

เมื่อ r_j คือ สหสัมพันธ์ในตัวของลำดับที่ j โดยที่ $j = 1, \dots, k$

T คือ จำนวนของค่าสังเกต

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

จะยอมรับสมมติฐานหลักเมื่อ $Q_{LB} \leq \chi^2_{\alpha, k-m}$ คือส่วนเหลือเป็นอิสระต่อ กันที่ความล่า k และถ้าปฏิเสธสมมติฐานหลักเมื่อ $Q_{LB} > \chi^2_{\alpha, k-m}$ คือ เกิดสหสัมพันธ์ในตัวของอย่างน้อยหนึ่งค่าในส่วนเหลือที่ไม่เท่ากับศูนย์

4.7.2 เกณฑ์การเลือกรูปแบบของแบบจำลองที่ดีที่สุด (Information Criteria)

ในการหารูปแบบของแบบจำลอง เมื่อ ได้รูปแบบของแบบจำลองที่เหมาะสมที่สุด โดยการพิจารณาค่า Akaike Information Criterion (AIC) และ Schwartz Criterion (SC) รูปแบบที่ให้ค่า AIC และ SC น้อยที่สุด จะเป็นรูปแบบที่ดีที่สุด โดย Akaike Information Criterion (AIC) คำนวณตามสมการที่ (4.29) และ Schwartz Criterion (SC) คำนวณตามสมการที่ (4.30)

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

$$\text{Schwarz Criterion (SC)} \quad -2\ell/\eta + k \log \eta / \eta \quad (4.30)$$

โดยที่ k เป็นจำนวนของพารามิเตอร์ที่ทำการประมาณค่า

η เป็นจำนวนของค่าสังเกต

ℓ เป็นค่าของ log likelihood function ที่ใช้พารามิเตอร์ที่ถูกประมาณค่า k ด้วย