

### บทที่ 3

#### ระเบียบวิธีวิจัย

ในการศึกษาการวิเคราะห์ความผันผวนและพยากรณ์มูลค่าหน่วยลงทุนกองทุนหุ้นระยะยาวโดยใช้แบบจำลอง ARIMA-GARCH ใช้แนวคิดและทฤษฎีเกี่ยวกับการวิเคราะห์หอนุกรมเวลา การทดสอบความนิ่งของข้อมูล (stationary) โดยการทดสอบ Unit Root และสร้างแบบจำลองที่ดีที่สุดเพื่อประมาณค่าความผันผวนและพยากรณ์มูลค่าหน่วยลงทุนในอนาคต แบบจำลองที่ใช้คือแบบจำลอง ARIMA (Autoregressive Intergrated Movingaverage) แบบจำลอง Autoregressive Conditional Heteroscadasticity (ARCH) แบบจำลอง Gernalized Conditional Heteroscadasticity (GARCH) และวิธีการพยากรณ์

#### 3.1 การวิเคราะห์หอนุกรมเวลา (Time Series Analysis)

หอนุกรมเวลา คือ เซตของข้อมูลเชิงปริมาณที่มีการจัดเก็บในช่วงเวลาที่ติดต่อกัน ส่วนข้อมูลหอนุกรมเวลา (Time Series Data) คือ ชุดของข้อมูลที่มีการเก็บรวบรวมตามระยะเวลาที่ติดต่อกันอย่างเป็นระบบโดยทั่วไปข้อมูลหอนุกรมเวลาประกอบด้วยองค์ประกอบ 4 ส่วน คือ แนวโน้ม (Trend: T), ฤดูกาล (Seasonal: S), วัฏจักร (Cycle: C) และเหตุการณ์ที่ผิดปกติหรือเหตุการณ์ความไม่แน่นอน (Irregular: I) สำหรับรูปแบบของหอนุกรมเวลาโดยทั่วไปนี้มีอยู่ 2 รูปแบบคือ

ก) รูปแบบบวก  $Y = T + S + C + I$  (1)

ข) รูปแบบคูณ  $Y = T \times S \times C \times I$  (2)

โดยที่ Y	คือ	หอนุกรมเวลา
T	คือ	อิทธิพลของแนวโน้ม
S	คือ	อิทธิพลของฤดูกาล
C	คือ	อิทธิพลของวัฏจักร
I	คือ	อิทธิพลของความไม่แน่นอน

การวิเคราะห์หอนุกรมเวลาเป็นวิธีที่ใช้ในการวิเคราะห์ข้อมูลหรือค่าสังเกตที่มีการเปลี่ยนแปลงไปตามลำดับเวลาที่เกิดขึ้น หรือการเปลี่ยนแปลงของตัวแปรในช่วงเวลาที่ผ่านไป ลักษณะของการเปลี่ยนแปลงอาจมีหรือไม่มีรูปแบบก็ได้ แต่ถ้าหอนุกรมเวลาแสดงให้เห็นรูปแบบการเปลี่ยนแปลงในช่วงเวลาที่ผ่านมานในอดีตก็จะทำให้สามารถคาดการณ์ได้ว่าในอนาคตลักษณะ

การเปลี่ยนแปลงควรอยู่ในรูปแบบใด และสามารถพยากรณ์การเปลี่ยนแปลงข้อมูลในอนาคตได้ การวิเคราะห์ข้อมูลอนุกรมเวลานี้ จะขึ้นอยู่กับ การเปลี่ยนแปลงของเวลาในอดีตเป็นพื้นฐาน (ศิริลักษณ์ เล็กสมบูรณ์ 2531)

นำข้อมูลมูลค่าทรัพย์สินสุทธิต (NAV) ซึ่งเป็นข้อมูลทุติยภูมิ (Secondary data) มาวิเคราะห์ ข้อมูลอนุกรมเวลา (time series data) ได้สมการในการทดสอบดังนี้

$$Nav_t = \rho Nav_{t-1} + \varepsilon_t \quad (3)$$

กำหนดให้

$Nav_t$  คือ ตัวแปรที่เราทำการศึกษาได้แก่ มูลค่าทรัพย์สินสุทธิหรือมูลค่าหน่วยลงทุน

$t$  คือ แนวโน้มเวลา

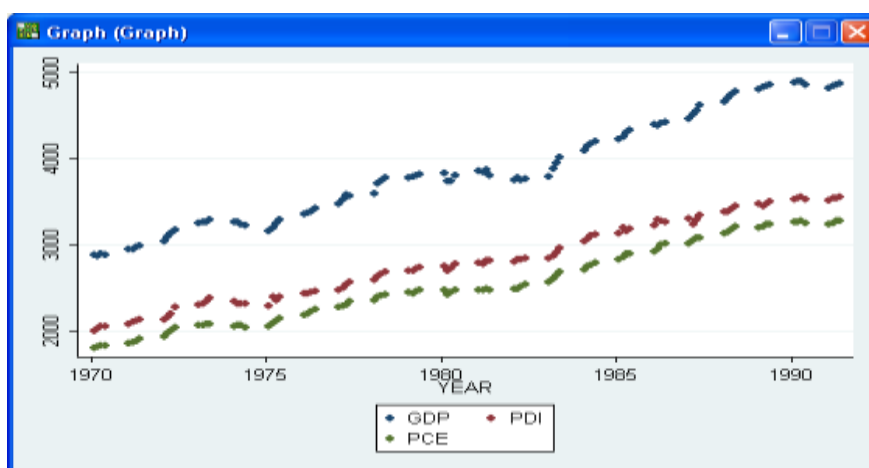
$\varepsilon_t$  คือ ตัวแปรสุ่มโดยมีการแจกแจงแบบปกติที่เป็นอิสระต่อกันและเหมือนกัน

นำข้อมูลอนุกรมเวลามาทดสอบ Stationary แบ่งได้เป็น 3 วิธีหลัก ๆ คือ

- 1) การทดสอบโดยใช้กราฟ
- 2) การทดสอบ โดยใช้ Correlogram test
- 3) การทดสอบ โดยใช้ Unit Root test


### 3.1.1 การทดสอบโดยใช้กราฟ

การทดสอบโดยใช้กราฟ ข้อมูลที่ไม่เสถียรจะมีรูปแบบ ดังนี้



ภาพที่ 3.1 ตัวอย่างข้อมูลที่ไม่เสถียรภาพ

การทดสอบโดยใช้กราฟข้อมูลที่มีเสถียรภาพจะกระจายอยู่รอบ ๆ ค่าเฉลี่ย



ภาพที่ 3.2 ตัวอย่างข้อมูลที่มีเสถียรภาพ

### 3.1.2 การทดสอบโดยใช้ Correlogram test (Correlogram and Q-statistics)

การพิจารณา Correlogram and Q-statistics มีเงื่อนไขในการพิจารณาว่ากราฟ Correlogram ของ Autocorrelation ของตัวแปรที่กำลังพิจารณาจะต้องไม่มีลักษณะการลดลงแบบ Exponential และค่า Q-statistics ที่คำนวณได้มีค่ามากกว่าค่าวิกฤติของ Chi-square ณ ระดับนัยสำคัญ

## 3.2 การทดสอบความนิ่งของข้อมูล (Stationary) และการทดสอบ Unit Root

การทดสอบอนุกรมเวลา เป็นสิ่งที่ควรกระทำก่อนที่จะนำข้อมูลข้อมูลอนุกรมเวลามาใช้ในการวิเคราะห์ โดยเฉพาะเงื่อนไขความนิ่งของอนุกรมเวลา (Stationary) ซึ่งเป็นเงื่อนไขที่สำคัญในการนำข้อมูลอนุกรมเวลามาใช้ ดังนั้นถ้าหากอนุกรมเวลาที่นำมาใช้ไม่คงที่จะต้องทำให้อนุกรมเวลาดังกล่าวคงที่ก่อน โดยการหาผลต่างของอนุกรมเวลา การคงที่ของอนุกรมเวลา หมายถึง อนุกรมเวลาที่อยู่ในสถานะสมดุลเชิงสถิติ (Statistical equilibrium) ซึ่งก็คือ การที่คุณสมบัติทางสถิติของอนุกรมเวลาไม่เปลี่ยนแปลงตามกาลเวลา

การทดสอบ Unit Root เป็นการทดสอบว่าข้อมูลที่นำมาศึกษามีนิ่งหรือไม่ สามารถทำได้โดยการทดสอบ 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

เมื่อสมมติให้ตัวแปร  $X_t$  เป็นอนุกรมเวลาที่คงที่ (Stationary) ดังนั้น ตัวแปร  $X_t$  จะมีคุณสมบัติดังนี้

$$\text{Mean: } E(X_t) = \mu \quad (4)$$

$$\text{Variance: } \text{Var}(X_t) = E(X_t - \mu)^2 = \sigma^2 \quad (5)$$

$$\text{Covariance: } E[(X_t - \mu)(X_{t+k} - \mu)] = \gamma_k \quad (6)$$

ส่วนข้อมูลที่มีลักษณะไม่นิ่ง (Non-Stationary) หมายถึง ข้อมูลอนุกรมเวลาที่มีค่าเฉลี่ย (Mean) และความแปรปรวน (Variance) ไม่เท่ากันตลอดระยะเวลาที่ศึกษา

เมื่อสมมติให้ตัวแปร  $X_t$  เป็นอนุกรมเวลาที่ไม่คงที่ (Nonstationary) ดังนั้น ตัวแปร  $X_t$  จะมีคุณสมบัติดังนี้

$$\text{Mean: } E(X_t) = t\mu \quad (7)$$

$$\text{Variance: } \text{Var}(X_t) = E(X_t - \mu)^2 = t\sigma^2 \quad (8)$$

$$\text{Covariance: } E[(X_t - \mu)(X_{t+k} - \mu)] = t\gamma_k \quad (9)$$

### 3.2.1 วิธีการทดสอบ DF (Dickey – Fuller Test)

มีสมการที่ต้องทดสอบอยู่ 3 สมการ (At Level) คือ

$$\Delta X_t = \gamma X_{t-1} + \varepsilon_t \quad (\text{random walk process}) \quad (10)$$

$$\Delta X_t = \alpha + \gamma X_{t-1} + \varepsilon_t \quad (\text{random walk with drift}) \quad (11)$$

$$\Delta X_t = \alpha + \beta_t + \gamma X_{t-1} + \varepsilon_t \quad (\text{random walk with drift และ} \\ \text{มี linear Time and trend}) \quad (12)$$

สมมติฐานที่ทดสอบ

$$H_0 : \gamma = 0$$

$$H_1 : \gamma \neq 0$$

ถ้ายอมรับ  $H_0$  แสดงว่า  $X_t$  มีลักษณะไม่นิ่ง (Nonstationary) มีการเปลี่ยนแปลงเมื่อเวลาเปลี่ยนแปลงและถ้าปฏิเสธ  $H_0$  แสดงว่าข้อมูลนั้นมีลักษณะนิ่ง (Stationary)

สมการที่ใช้ทดสอบตามวิธี DF

$$\Delta Nav_{t-1} = \theta \Delta Nav_{t-1} + \varepsilon_t \quad (13)$$

$$\Delta Nav_{t-1} = \alpha + \theta \Delta Nav_{t-1} + \varepsilon_t \quad (14)$$

$$\Delta Nav_{t-1} = \alpha + \beta_t + \theta \Delta Nav_{t-1} + \varepsilon_t \quad (15)$$

### 3.2.2 วิธีการทดสอบ ADF (Augmented Dickey–Fuller Test)

การทดสอบ ADF (Augmented Dickey–Fuller Test) พัฒนามาจากวิธี Dickey – Fuller Test เพื่อแก้ปัญหา Serial Correlation หรือแก้ปัญหา Autocorrelation ซึ่งค่าสถิติที่ได้จะขาดความถูกต้องดังนั้น จึงได้มีการนำเสนอให้ปรับสมการของวิธีการ Dickey-Fuller ใหม่ โดยใส่ตัวแปรล่า (Lag) ของ X ในลำดับที่สูงขึ้น แล้วเรียกวิธีการนี้ว่า Augmented Dickey–Fuller Test ในการตรวจสอบว่าข้อมูลนั้นมีลักษณะนิ่งหรือไม่ โดยการเปรียบเทียบค่าสถิติ  $t$  ที่คำนวณได้กับค่าวิกฤตในตาราง ADF (อัครพงษ์ อันทอง, 2550)

มีสมการที่ต้องทดสอบอยู่ 3 สมการ (At Level) คือ

$$\Delta X_t = \gamma X_{t-1} + \sum_{i=1}^p \phi_i \Delta X_{t-1} + \varepsilon_t \quad (\text{random walk process}) \quad (16)$$

$$\Delta X_t = \alpha + \gamma X_{t-1} + \sum_{i=1}^p \phi_i \Delta X_{t-1} + \varepsilon_t \quad (\text{random walk with drift}) \quad (17)$$

$$\Delta X_t = \alpha + \beta_t + \gamma X_{t-1} + \sum_{i=1}^p \phi_i \Delta X_{t-1} + \varepsilon_t \quad (\text{random walk with linear and trend}) \quad (18)$$

สมมติฐานที่ทดสอบ

$$H_0 : \gamma = 0$$

$$H_1 : \gamma \neq 0$$

ถ้ายอมรับ  $H_0$  แสดงว่า  $X_t$  ข้อมูลมีลักษณะไม่นิ่ง (Nonstationary) และถ้าปฏิเสธ  $H_0$  แสดงว่าข้อมูลนั้นมีลักษณะนิ่ง (Stationary) ข้อมูลที่มีลักษณะนิ่ง (Stationary) หมายถึง ข้อมูลอนุกรมเวลาที่มีค่าเฉลี่ย (Mean) และความแปรปรวน (Variance) เท่ากันตลอดระยะเวลาที่ศึกษา ส่วนข้อมูลที่มีลักษณะไม่นิ่ง (Non-Stationary) หมายถึงข้อมูลอนุกรมที่มีค่าเฉลี่ย (Mean) และความแปรปรวน (Variance) ไม่เท่ากันตลอดระยะเวลาที่ศึกษา

สมการที่ใช้ในการทดสอบตามวิธี ADF

$$\Delta Nav_{t-1} = \theta Nav_{t-1} + \sum_{j=1}^p \lambda_j \Delta Nav_{t-1} + \varepsilon_t \quad (19)$$

$$\Delta Nav_{t-1} = \alpha + \theta Nav_{t-1} + \sum_{j=1}^p \lambda_j \Delta Nav_{t-1} + \varepsilon_t \quad (20)$$

$$\Delta Nav_{t-1} = \alpha + \beta_t + \theta Nav_{t-1} + \sum_{j=1}^p \lambda_j \Delta Nav_{t-1} + \varepsilon_t \quad (21)$$

### 3.3 การเลือกแบบจำลองจากการทดสอบ Unit Root โดยการทดสอบสัมประสิทธิ์ของการถดถอย (Deterministic Regressors)

เป็นการทดสอบว่า แบบจำลองใดเป็นแบบจำลองที่เหมาะสมที่สุดระหว่างกรณีของแบบจำลองที่ไม่มีค่าคงที่และแนวโน้มเวลา (None) แบบจำลองที่มีค่าคงที่ (Intercept) และแบบจำลองที่มีทั้งค่าคงที่และแนวโน้มเวลา (Trend and Intercept) โดยการทดสอบการมีนัยสำคัญทางสถิติของสัมประสิทธิ์ของตัวถดถอย (ค่าคงที่หรือค่าแนวโน้มเวลา) โดยขั้นตอนการทดสอบดังนี้

**ขั้นตอนที่ 1** เริ่มการทดสอบจากแบบจำลองกรณีที่มีทั้งค่าคงที่และแนวโน้มเวลาตามสมการ

$$\Delta X_t = a_0 + \beta + \gamma X_{t-1} + a_2 + \sum \beta_i \Delta X_{t-1} + \varepsilon_t \quad (22)$$

ทำการทดสอบสมมติฐานว่าง  $H_0: \gamma = 0$  โดยใช้  $\tau$  statistic ถ้าเกิดการปฏิเสธสมมติฐานว่าง แสดงว่า ข้อมูล  $X_t$  มีลักษณะนิ่งแล้ว และเลือกใช้แบบจำลองที่มีทั้งค่าคงที่และแนวโน้มเวลา

**ขั้นตอนที่ 2** ถ้าเกิดการยอมรับสมมติฐานว่างในขั้นตอนที่ 1 แสดงว่าในแบบจำลองดังกล่าวมีตัวถดถอยที่ไม่จำเป็นอยู่ในสมการ ซึ่งอาจทำให้อำนาจการทดสอบของสมการลดลง ดังนั้น จึงต้องมีการทดสอบนัยสำคัญทางสถิติของค่าแนวโน้ม ( $a_2$ ) ที่อยู่ในสมการ โดยการทดสอบสมมติฐานว่า  $H_0: a_2 = \gamma = 0$  โดยใช้  $\phi$  statistic ถ้าค่าสัมประสิทธิ์ของค่าแนวโน้มไม่มีนัยสำคัญทางสถิติให้ข้ามไปขั้นตอนที่ 3 อย่างไรก็ตาม ถ้าค่าสัมประสิทธิ์ของค่าแนวโน้มมีนัยสำคัญทางสถิติให้ทำการทดสอบความไม่นิ่งของข้อมูลอีกครั้ง โดยใช้ การแจกแจงแบบปกติมาตรฐาน (standardized normal distribution) ถ้าเกิดการปฏิเสธสมมติฐานว่างแสดงว่า ข้อมูล  $X_t$  มีลักษณะนิ่งแล้วจะเลือกใช้แบบจำลองที่มีทั้งค่าคงที่และแนวโน้มเวลา แต่ถ้าเกิดการยอมรับสมมติฐานว่าง แสดงว่าข้อมูล  $X_t$  มีลักษณะไม่นิ่ง

**ขั้นตอนที่ 3** ทำการประเมินค่าแบบจำลอง ที่ปราศจากค่าแนวโน้มเวลา และทดสอบ unit root โดยใช้  $\tau_{\mu}$  statistic ถ้าเกิดการปฏิเสธสมมติฐานว่างแสดงว่าข้อมูล  $X_t$  มีลักษณะนิ่งแล้วและเลือกใช้แบบจำลองที่ปราศจากค่าแนวโน้มเวลา แต่ถ้าเกิดการยอมรับสมมติฐานว่างให้ทำการทดสอบความไม่นิ่งของข้อมูลอีกครั้งโดยใช้ การแจกแจงแบบปกติมาตรฐาน (standardized normal distribution) ถ้าเกิดการปฏิเสธสมมติฐานว่างแสดงว่า ข้อมูล  $X_t$  มีลักษณะนิ่งแล้วและเลือกใช้แบบจำลองที่มีทั้งค่าคงที่และแนวโน้มเวลา แต่ถ้าเกิดการยอมรับสมมติฐานว่างแสดงว่า ข้อมูล  $X_t$  มีลักษณะไม่นิ่ง

**ขั้นตอนที่ 4** ทำการประมาณค่าแบบจำลองที่ปราศจากค่าแนวโน้มเวลา และค่าคงที่ และทดสอบ Unit root โดยใช้  $\tau$  statistic ถ้าเกิดการปฏิเสธสมมติฐานว่าง แสดงว่าข้อมูล  $X_t$  มีลักษณะนิ่งแล้วและเลือกใช้แบบจำลองที่ปราศจากค่าแนวโน้มเวลาและค่าคงที่ แต่ถ้าเกิดการยอมรับสมมติฐานว่าง แสดงว่าข้อมูล  $X_t$  มีลักษณะไม่นิ่ง

ทั้งนี้ การวิเคราะห์ข้อมูลที่เป็นอนุกรมเวลา ส่วนมากจะพบปัญหาความไม่นิ่งของข้อมูล เนื่องจากข้อมูลนั้นมาจากกระบวนการเชิงสุ่ม (random process) เมื่อนำข้อมูลอนุกรมเวลาไปใช้โดยไม่ได้ทำการตรวจสอบว่าข้อมูลมีลักษณะนิ่งนั้น ค่าสถิติที่เกิดขึ้นจะมีการแจกแจงไม่มาตรฐาน (standard distributions) ทำให้นำไปสู่การลงความเห็นที่ผิดพลาดและความสัมพันธ์ที่ไม่แท้จริง (spurious regression) กล่าวคือ R มีค่าสูงมากและได้ค่าสถิติ t-test มีนัยสำคัญหรือสูงเกินกว่าความเป็นจริง ซึ่งสามารถแก้ไขได้ด้วยการทำให้ข้อมูลมีความนิ่งเสียก่อน โดยอาจใช้วิธีการหาผลต่าง (Difference) ของข้อมูล การแปลงให้อยู่ในรูป Logarithm หรือการทดสอบหาความสัมพันธ์ของตัวแปรในระยะยาว (Cointegration) เป็นต้น

### 3.4 การเลือกแบบจำลองที่ดีที่สุด โดยการตรวจสอบรูปแบบ (Diagnostic Checking)

หลังจากการสร้างสมการพร้อมทั้งประมาณค่าพารามิเตอร์แล้ว สิ่งสำคัญที่จะต้องทำคือ การตรวจสอบรูปแบบว่าสมการที่ได้มามีความเหมาะสมหรือไม่ และรูปแบบใดของสมการที่ดีที่สุด

#### 3.4.1 เกณฑ์ในการเลือกแบบจำลองที่ดีที่สุด (Information Criteria)

ในการหารูปแบบของแบบจำลอง เมื่อได้รูปแบบของแบบจำลองที่เหมาะสมหลายรูปแบบต้องมีแนวทางในการเลือกรูปแบบของแบบจำลองที่ดีที่สุด โดยพิจารณาจากค่า Akaike Information Criterion (AIC) และ Schwartz Criterion (SC) รูปแบบของแบบจำลองที่ให้ค่า AIC และ SC น้อยที่สุดจะเป็นรูปแบบที่ดีที่สุด สามารถคำนวณได้ดังนี้

$$\text{Akaike Information Criterion (AIC)} = -2l/\eta + 2\kappa/\eta \quad (23)$$

$$\text{Schwartz Criterion (SC)} = -2l/\eta + \kappa \log \eta/\eta \quad (24)$$

โดยที่  $\kappa$  เป็นจำนวนของพารามิเตอร์ที่ทำการประมาณค่า

$\eta$  เป็นจำนวนของค่าสังเกต

$l$  เป็นค่าของ log likelihood function ที่ใช้พารามิเตอร์ที่ถูกประมาณค่า  $k$  ตัว

### 3.4.2 แบบจำลอง ARIMA (Autoregressive Intergrated Movingaverage)

แบบจำลองตัวแบบ ARIMA (p, d, q) มีส่วนประกอบที่สำคัญ 3 ส่วน ได้แก่ Auto Regressive AR : (p), Intergrated (I) และ Moving Average MA : (q) สำหรับ AR (p) เป็นรูปแบบที่แสดงว่าค่าสังเกต  $y_t$  ขึ้นอยู่กับค่าของ  $y_{t-1}, \dots, y_{t-p}$  หรือค่าสังเกตที่เกิดขึ้นก่อนหน้า p ค่า ส่วนรูปแบบ MA (q) เป็นรูปแบบที่แสดงค่าสังเกต  $y_t$  ขึ้นอยู่กับค่าความคลาดเคลื่อน  $\varepsilon_{t-1}, \dots, \varepsilon_{t-q}$  หรือความคลาดเคลื่อนที่อยู่ก่อนหน้า q ค่า ส่วน Integrated (I) เป็นการหาผลต่าง (Difference) ของอนุกรมเวลา เหตุผลสำคัญที่ต้องหาผลต่างของอนุกรมเวลา เนื่องจากแบบจำลอง ARIMA จะต้องใช้ในการวิเคราะห์ข้อมูลอนุกรมเวลาที่มีคุณสมบัติคงที่ (Stationary) เท่านั้น ในกรณีที่ข้อมูลอนุกรมเวลาที่ใช้ในการวิเคราะห์สมบัติไม่คงที่ (Nonstationary) จะต้องทำการแปลงข้อมูลอนุกรมเวลาดังกล่าวให้มีคุณสมบัติคงที่ก่อน โดยการหาผลต่างของข้อมูลอนุกรมเวลา หรือการหาค่า Natural logarithm ของอนุกรมเวลาก่อนที่จะนำข้อมูลไปใช้สร้างแบบจำลอง ARIMA

$$\phi(B) \nabla^d y_t = \delta + \theta(B) \varepsilon_t \quad (25)$$

โดยที่

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p \quad (26)$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \quad (27)$$

$y_t$  = ค่าสังเกตในอนุกรมเวลา ณ เวลา t

B = Backward shift operation โดยที่  $B_m = \nabla y_{t-m}$

d = จำนวนครั้งของการหาผลต่างเพื่อให้อนุกรมเวลาที่มีคุณสมบัติคงที่ (stationary)

p = อันดับของออโตรีเกรสซีฟ (Autoregressive Order)

q = อันดับของค่าเฉลี่ยเคลื่อนที่ (Moving Average)

$\delta$  = ค่าคงที่ (Constant Term)

$\phi_1, \dots, \phi_p$  = พารามิเตอร์ของ ออโตรีเกรสซีฟ (Autoregressive parameter)

$\theta_1, \dots, \theta_q$  = พารามิเตอร์ของ ค่าเฉลี่ยเคลื่อนที่ (Moving-Average parameter)

$\varepsilon_t$  = กระบวนการ white noise ซึ่งก็คือ ค่าความคลาดเคลื่อน ณ เวลา t ภายใต้อ

สมมติว่าความคลาดที่คนละเวลาเป็นตัวแปรสุ่มที่เป็นอิสระต่อกัน โดยมีการแจกแจงแบบปกติที่มีค่าเฉลี่ยเป็นศูนย์ และความแปรปรวนคงที่ [ $\varepsilon_t \sim N(0, \sigma^2)$ ]



จากสมการข้างต้นอาจเขียนได้ใหม่เป็น

$$\nabla^d y_t = \delta_+ \phi \nabla^d y_{t-1} + \phi \nabla^d y_{t-2} + \dots + \phi \nabla^d y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_q \varepsilon_{t-q} \quad (28)$$

จากรูปแบบทั่วไปตามสมการข้างต้นนำไปใช้ในการกำหนดรูปแบบที่เหมาะสมและประมาณค่าต่อไป ซึ่งอนุกรมเวลาที่จะนำมาวิเคราะห์ ด้วยวิธีของ Box and Jenkins นี้ ต้องมีเงื่อนไขบางประการเกี่ยวกับค่าพารามิเตอร์ในตัวแบบเพื่อให้อนุกรมเวลามีคุณสมบัติคงที่ (Stationary) และคุณสมบัติผกผัน (Invertibility) สำหรับคุณสมบัติคงที่ (Stationary) เป็นคุณสมบัติของรูปแบบ AR (p) ซึ่งเป็นคุณสมบัติที่ทำให้  $E(y_t)$  และ  $V(y_t)$  คงที่ และ  $\text{Cov}(y_t, \dots, y_{t-k})$  มีค่าคงที่ ขึ้นกับว่า Lag k อย่างเดียว ส่วนคุณสมบัติผกผัน (Invertible) เป็นคุณสมบัติของรูปแบบ MA (q) ซึ่งเป็นคุณสมบัติที่ทำให้ค่าคลาดเคลื่อนของการพยากรณ์  $\varepsilon_t$  ในเทอมของ  $y_t, y_{t-1}$  มีค่าคงที่ (ทรงศิริ แต่สมบัติ, 2539) มีขั้นตอนของวิธีการ Box and Jenkins

**ขั้นตอนที่ 1** กำหนดรูปแบบ (Identification) เพื่อหารูปแบบที่คาดว่าเหมาะสมให้กับอนุกรมเวลา โดยใช้วิธีพิจารณาเปรียบเทียบจาก Correlogram ของค่า  $r_k$  และ  $r_{kk}$  ของอนุกรมเวลา

**ขั้นตอนที่ 2** การประมาณค่าสัมประสิทธิ์ (Estimation) ในรูปแบบ โดยทั่วไปใช้วิธีการประมาณค่าสัมประสิทธิ์ด้วยวิธีกำลังสองน้อยที่สุดแบบธรรมดา (Ordinary Least Square Method: OLS)

**ขั้นตอนที่ 3** การตรวจสอบรูปแบบ (Diagnostic checking) เมื่อกำหนดรูปแบบและประมาณค่าพารามิเตอร์ในรูปแบบแล้ว ต้องตรวจสอบอีกครั้งว่ารูปแบบที่กำหนดมีความเหมาะสมจริงหรือไม่ โดยการพิจารณาค่าสหสัมพันธ์ในตัวเองของค่าความคลาดเคลื่อน (ดูจากกราฟ Correlogram) การทดสอบค่าพารามิเตอร์ในรูปแบบ โดยการพิจารณาจากค่าสถิติ t (t-statistic) และการทดสอบความเหมาะสมของรูปแบบโดยการทดสอบของ Box and Pierce หรือการทดสอบของ Box and Ljung [Q-statistic]

**ขั้นตอนที่ 4** การพยากรณ์ (Forecasting) นำสมการพยากรณ์ที่สร้างจากรูปแบบการพยากรณ์ที่กำหนดและผ่านการตรวจสอบรูปแบบ มาพยากรณ์ค่าในอนาคต โดยสามารถทำได้ทั้งการพยากรณ์แบบจุด (Point forecast) และการพยากรณ์แบบช่วง (Interval Forecast) การพยากรณ์โดยวิธี Box and Jenkins จะให้ค่าพยากรณ์ไปข้างหน้าที่ดีในช่วงสั้นๆ และต้องมีอนุกรมเวลาที่ยาวพอสมควร (อักรพงศ์ อันทอง, 2550)

### 3.4.3 แบบจำลอง Autoregressive Conditional Heteroscedasticity (ARCH)

ในการวิเคราะห์อนุกรมเวลาส่วนใหญ่แล้วจะมีการกำหนด stochastic variable ให้มีความแปรปรวนคงที่ (homoscedastic) ซึ่งในการประยุกต์ใช้กับบางข้อมูลนั้นค่าความแปรปรวนของค่าความคลาดเคลื่อน(error term) จะไม่ใช่ฟังก์ชันของตัวแปรอิสระแต่มีค่าเปลี่ยนแปลงไปตามช่วงเวลาขึ้นอยู่กับขนาดของความคลาดเคลื่อนที่เกิดขึ้นในอดีต และในบางงานศึกษา เช่น แบบจำลองของเงินเพื่อ อัตราดอกเบี้ยหรือผลตอบแทนจากตลาดหลักทรัพย์ ในบางคาบเวลาจะมีค่าความผันผวน(volatility) สูง (และความคลาดเคลื่อนที่มีขนาดใหญ่) ตามด้วยคาบเวลาที่มีค่าความผันผวน(volatility) ต่ำ (และมีค่าความคลาดเคลื่อนที่มีขนาดเล็ก) สรุปได้ว่าค่าความแปรปรวนของค่าความคลาดเคลื่อนจากการถดถอยจะขึ้นอยู่กับค่าความผันผวน(volatility) ของความคลาดเคลื่อนในอดีตที่ผ่านมา (สธนพล วิเชียรรัตนพันธ์, 2547; อ้างถึงใน ทรงศักดิ์ ศรีบุญจิตต์, 2547)

ความเป็นไปได้ในการหาค่าเฉลี่ยและความแปรปรวนของอนุกรมเวลาไปพร้อมกันนั้น ในขั้นตอนการพยากรณ์อย่างมีเงื่อนไขจะมีความแม่นยำเหนือกว่าการพยากรณ์อย่างไม่มีเงื่อนไข ซึ่งจากแบบจำลอง Autoregressive Moving Average (ARMA) ซึ่งแสดงได้ดังนี้

$$X_t = a_0 + a_1 X_{t-1} + \varepsilon_t \quad (29)$$

และการพยากรณ์อย่างมีเงื่อนไขของ  $X_{t-1}$  ดังนี้คือ

$$E_t X_{t-1} = a_0 + a_1 X_t \quad (30)$$

และค่าเฉลี่ยแบบมีเงื่อนไขในการพยากรณ์  $X_{t-1}$  ค่าความคลาดเคลื่อนของความแปรปรวนอย่างมีเงื่อนไขที่พยากรณ์ได้ดังนี้คือ

$$E_t [(X_{t-1} - a_0 - a_1 X_t)^2] = E_t \varepsilon_{t-1}^2 = \sigma^2 \quad (31)$$

ถ้าเปลี่ยนไปใช้การพยากรณ์อย่างมีเงื่อนไขแล้ว ผลที่จะใช้เป็นค่าเฉลี่ยในช่วง Long-Run ของลำดับ  $\{X_t\}$  ซึ่งเท่ากับ  $\frac{a_0}{(1-a_1)}$  จะได้ค่าความคลาดเคลื่อนของการพยากรณ์อย่างไม่มีเงื่อนไขดังนี้

$$E_t \left\{ \left( X_{t-1} - \frac{a_0}{(1-a_1)} \right)^2 \right\} = E \left[ (\varepsilon_{t-1} + a_1 \varepsilon_{t-1} + a_1^2 \varepsilon_{t-2} + a_1^3 \varepsilon_{t-3} + \dots)^2 \right] \quad (32)$$

เนื่องจาก  $\frac{1}{(1-a_1)^2} > 1$  เพราะฉะนั้นความแปรปรวน(variance) จากการพยากรณ์แบบไม่มีเงื่อนไข (unconditional variance) จึงมีค่าสูงกว่าความแปรปรวนของ  $\{\varepsilon_t\}$  ไม่เป็นค่าคงที่จะสามารถประมาณค่าแนวโน้มของการเปลี่ยนแปลงความแปรปรวนโดยใช้ ARMA Model โดยให้  $\varepsilon_t$  แทนส่วนที่เหลือที่ได้จากการประมาณจากสมการ ดังนั้น ค่าความแปรปรวนแบบมีเงื่อนไขของ  $X_{t-1}$  จะได้ดังนี้

$$\text{Var}(X_{t+1} | X_t) = E[(X_{t+1} - a_0 - a_1 X_t)^2] = E_t \varepsilon_{t+1}^2 \quad (33)$$

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

$$\hat{\varepsilon}_t^2 = \alpha_0 + \alpha_1 \hat{\varepsilon}_{t-1}^2 + \dots + \alpha_q \hat{\varepsilon}_{t-q}^2 + V_t \quad (34)$$

เมื่อ  $V_t =$  white noise process

ถ้าค่าของ  $\alpha_1, \alpha_2, \dots, \alpha_q$  มีค่าเท่ากับศูนย์ ความแปรปรวนที่ประมาณค่ามาได้ (estimated variance) จะมีค่าคงที่หรือคงตัว (constant variance)  $\alpha_0$  อีกนัยหนึ่ง คือ ค่าความแปรปรวนอย่างมีเงื่อนไขของ  $X_t$  จะมีการเปลี่ยนแปลงสอดคล้องกับในสมการ (34) และค่าพยากรณ์สามารถเขียนได้ดังนี้

$$E_t \hat{\varepsilon}_t^2 = \alpha_0 + \alpha_1 \hat{\varepsilon}_{t-1}^2 + \dots + \alpha_q \hat{\varepsilon}_{t-1-q}^2 \quad (35)$$

จากเหตุผลที่กล่าวมา สมการ(34) เรียกว่า Autoregressive Conditional Heteroscedastic (ARCH) Model และสมการ(35) เป็น ARCH(q) โดยค่า  $E_t \hat{\varepsilon}_t^2$  หรือ  $\sigma_{t-1}^2$  จะประกอบด้วย 2 องค์ประกอบ คือ ค่าคงที่และความผันผวน(volatility) ในคาบเวลาที่ผ่านมา ซึ่งเขียนได้เป็นส่วนเหลือกำลังสองของคาบเวลาในอดีต (ARCH term) ส่วนค่าสัมประสิทธิ์ ( $\alpha_1, \alpha_2, \dots, \alpha_q$ ) สามารถหาค่าได้โดยวิธี Maximum likelihood

### 3.4.4 แบบจำลอง Generalized Autoregressive Conditional Heteroscedasticity

#### (GARCH)

แบบจำลอง ARCH ของ Engle ได้มีการพัฒนาต่อโดย Bollerslev ในปี 1986 ด้วยการให้ความแปรปรวนแบบมีเงื่อนไข (conditional variance) มีลักษณะเป็น ARMA process โดยที่ error process มีลักษณะดังนี้

$$\varepsilon_t = V_t \varepsilon_t \quad (36)$$

โดยที่ความแปรปรวนของ  $V_t = \sigma_t^2 = 1$  และ

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^p \beta_i \sigma_{t-i}^2 \quad (37)$$

เมื่อ  $\{V_t\}$  คือ White noise process ที่เป็นค่าอิสระจากเหตุการณ์ในอดีต  $\{\varepsilon_{t-1}\}$  ค่าเฉลี่ยแบบมีเงื่อนไขของ  $\varepsilon_t$  จะเท่ากับศูนย์ ประเด็นสำคัญในการหาความแปรปรวนแบบมีเงื่อนไขของ  $\varepsilon_t$  ถูกกำหนดโดย

$$E_{t-1} \varepsilon_t^2 = \sigma_t^2 = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^p \beta_i \sigma_{t-i}^2 \quad (38)$$

ดังนั้น ความแปรปรวนแบบมีเงื่อนไขของ  $\varepsilon_t$  ถูกกำหนดโดย  $\sigma_t^2$  ในสมการ (16) แบบจำลองนี้จึงเรียกว่า Generalized Autoregressive Conditional Heteroscedasticity (GARCH) หรือ GARCH (p, q) นั้นใช้กระบวนการ Autoregressive และ Moving Average ในการหาความแปรปรวนที่มีลักษณะ Heteroscedastic Variance จะเห็นว่าถ้า  $p=0$  และ  $q=1$  เป็น GARCH (0,1) หรือคือ ARCH(1) นั่นเอง โดยสรุปว่าถ้า  $\beta_1$  ทั้งหมดมีค่าเป็นศูนย์แบบจำลอง GARCH (p, q) จะเทียบเท่ากับแบบจำลอง ARCH (q) คุณสมบัติที่สำคัญของแบบจำลอง GARCH คือค่าความแปรปรวนอย่างมีเงื่อนไขของ disturbances ของค่า  $X_t$  สร้างขึ้นมาจากกระบวนการ ARMA จึงสามารถคาดได้ว่าส่วนเหลือจากการทำ ARMA จะแสดงถึงรูปแบบคุณลักษณะเดียวกันเช่น ถ้าการประมาณค่า  $\{X_t\}$  ด้วยกระบวนการทำ ARMA ค่า Autocorrelation Function (ACF) ซึ่งเป็นสหสัมพันธ์ระหว่างตัวแปรสุ่มที่หน่วยเวลาห่างกันของกระบวนการเดียวกันและ Partial Autocorrelation Function (PACF) ของส่วนที่เหลือ (residuals) ควรจะบ่งถึงกระบวนการ White noise และ ACF ของกำลังสองของส่วนที่เหลือ (squared residuals) นำมาช่วยในการระบุถึงลำดับ (order) ของกระบวนการ GARCH (สธนพล วิเชียรรัตนพันธ์, 2547; อ่างถึงใน ทรงศักดิ์ ศรีบุญจิตต์, 2547)

### 3.4.5 แบบจำลอง Exponential GARCH (EGARCH)

แบบจำลอง GARCH ต่าง ๆ นอกจากใช้ได้อย่างประสบผลสำเร็จ แต่ก็มีข้อเสียอยู่สองประการในการประยุกต์ใช้กับการตั้งหรือคำนวณค่าทรัพย์สินประเภททุน ประการแรก คือ ในกระบวนการ GARCH แบบสมมาตรนั้น ถ้ามีความผิดปกติ หรือ shock เกิดขึ้นๆไม่ว่าในทางบวกหรือทางลบ แต่อยู่ในระดับหรือขนาดเดียวกัน ซึ่งให้ระดับความไม่แน่นอนที่เท่ากันแล้ว ค่าความแปรปรวนอย่างมีเงื่อนไขก็จะเพิ่มขึ้นในทางบวกหรือทางลบ แต่อยู่ในระดับหรือขนาดเดียวกัน ซึ่งให้ระดับความไม่แน่นอนที่เท่ากันแล้ว ค่าความแปรปรวนอย่างมีเงื่อนไขก็จะเพิ่มขึ้นในทางบวกหรือทางลบอย่างมากจนน่าตกใจ (Engle and Bollerslev, 1986) อย่างไรก็ตาม Black (1976) ได้พบความสัมพันธ์ที่เป็นลบหรือตรงกันข้ามกันระหว่างผลตอบแทนในปัจจุบันกับความไม่แน่นอนที่เกิดจากความอ่อนไหว (Volatility) ในอนาคต เช่น ความไม่แน่นอนมักจะสูงเมื่อมีข่าวร้าย และจะลดลงเมื่อมีข่าวดี (Nelson, Daniel B, 1991) ลักษณะความไม่สมมาตรของความแปรปรวนแบบมีเงื่อนไขนี้ ผู้เขียนงานวิชาการหลายคนเรียกว่า leverage effect คือ อิทธิพลจากค่ายกกำลัง ซึ่งแบบจำลอง GARCH แบบเส้นตรงไม่สามารถกำหนดความไม่แน่นอนที่อ่อนไหวในอนาคต กล่าวอีกนัยหนึ่งคือ เฉพาะขนาดของค่าความคลาดเคลื่อนจากประมาณการถดถอยโดยมีการทอดระยะเวลา (Lagged Residuals) เท่านั้นที่มีส่วนกำหนดค่าความแปรปรวนอย่างมีเงื่อนไข แต่ความเป็นบวกหรือลบของค่าความคลาดเคลื่อนไม่มีส่วนเกี่ยวข้อง (Nelson, Daniel B, 1991) ซึ่งข้อจำกัดนี้เป็นจุดสำคัญประการแรกที่ทำให้มีการพัฒนาแบบจำลอง EGARCH

Nelson (1991) นำเสนอแบบจำลอง EGARCH หรือ Exponential ARCH Model ที่มีค่ายกกำลังสูง(Exponential) เพื่อแก้ไขข้อจำกัดที่ปรากฏในแบบจำลอง GARCH (1,1) ให้ความแปรปรวนอย่างมีเงื่อนไข (นนทพร จำปาวาน, 2550)

สมการความแปรปรวน

$$\ln(\sigma_t^2) = \omega + \beta \ln(\sigma_{t-1}^2) + \gamma \frac{\varepsilon_{t-1}}{\sqrt{\sigma_{t-1}^2}} + \alpha \left[ \frac{|\varepsilon_{t-1}|}{\sqrt{\sigma_{t-1}^2}} - \sqrt{\frac{2}{\pi}} \right] \quad (40)$$

### 3.4.6 แบบจำลอง GARCH-in-Mean (GARCH-M)

จากแบบจำลอง GARCH (p,q) ในสมการที่ (38) ความแปรปรวนอย่างมีเงื่อนไขของข้อมูลอนุกรมเวลาขึ้นอยู่กับส่วนที่เหลือกำลังสองของกระบวนการนี้ (Bollerslev, 1986) Engle (1987) ขยายแนวคิดนี้โดยให้ค่าเฉลี่ยอย่างมีเงื่อนไขเป็นฟังก์ชันของความแปรปรวนอย่างมีเงื่อนไข โดยรู้จักกันในชื่อ GARCH-in-Mean หรือ GARCH-M (ภัทร์ ตั้งตระกูล, 2546)

สมการความแปรปรวน

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \beta \sigma_{t-1}^2 \quad (41)$$

อิทธิพลอย่างมีนัยสำคัญของความผันผวนในผลตอบแทนของหลักทรัพย์ถูกตรวจจับด้วยค่าสัมประสิทธิ์  $\sigma(\beta)$  ในสมการที่ (41) ซึ่งอธิบายแทนดัชนีของความสัมพันธ์ของการหลีกเลี่ยง ความเสี่ยง ค่าสัมประสิทธิ์  $\beta$  ที่เป็นบวกอย่างมีนัยสำคัญบอกลถึงผู้ลงทุนในหลักทรัพย์เมื่อเผชิญกับระดับความเสี่ยงที่สูงขึ้นก็ต้องการค่าชดเชยความเสี่ยงที่มากขึ้นตามไปด้วย

### 3.5 วิธีการพยากรณ์

ประโยชน์ของข้อมูลอนุกรมเวลาที่สำคัญ ก็คือการนำข้อมูลดังกล่าวมาใช้วิเคราะห์เพื่อพยากรณ์ค่าอนุกรมเวลาในอนาคตสามารถทำได้หลายวิธีเช่น การวิเคราะห์แนวโน้ม (Time trend) วิธีการปรับให้เรียบแบบเอ็กซ์โปเนนเชียล (Exponential smoothing), วิธีถดถอยเชิงพหุ (Multiple regression) และวิธีบ็อกซ์-เจนกินส์ (Box-jenkins)

#### 3.5.1 วิธีการวิเคราะห์แนวโน้ม (Time trend)

แบบจำลองที่ใช้การวิเคราะห์แนวโน้ม โดยทั่วไปมักจะใช้สมการแนวโน้มที่ประมาณค่าสัมประสิทธิ์ด้วยวิธีกำลังสองน้อยที่สุด (Ordinary Least Square: OLS) ซึ่งเป็นวิธีการที่ทำให้ผลรวมกำลังสองของผลต่างระหว่างค่าแนวโน้มกับข้อมูลที่ใช้มีค่าน้อยที่สุด (Least-square Error) วิธีการนี้เป็นวิธีการหนึ่งที่นิยมนำมาใช้ในการพยากรณ์แนวโน้ม เนื่องจากเป็นวิธีการที่ง่ายในการคำนวณ และสามารถสร้างสมการพยากรณ์ได้หลายรูปแบบทั้งที่เป็นเส้นตรงหรือไม่ใช่เส้นตรงก็ได้ หรือสามารถประยุกต์ใช้วัดอิทธิพลของฤดูกาลได้ด้วย สำหรับวิธีการประมาณค่าพารามิเตอร์ด้วยวิธีการกำลังสองน้อยที่สุด (OLS) สามารถทำได้ดังนี้

$$\hat{y} = \alpha + \beta t \quad (42)$$

โดยที่  $\hat{y}$  คือ ค่าพยากรณ์  $y$   
 $\alpha, \beta$  คือ ค่าพารามิเตอร์  
 $t$  คือ เวลา โดยที่  $t = 1, 2, \dots, n$

สมการข้างต้นเป็นสมการแนวโน้มเส้นตรง แต่ในบางกรณีเส้นสมการแนวโน้มอาจเป็นเส้นโค้งก็ได้ ดังนั้นการใช้สมการแนวโน้มเส้นตรงในการพยากรณ์อาจทำให้เกิดความคลาดเคลื่อน รูปแบบสมการแนวโน้มที่ไม่เป็นเส้นตรงที่มักจะพบอยู่เสมอ ได้แก่

- 1) แนวโน้มพหุนาม (Polynomial trend)

$$\hat{y} = \alpha_0 + \beta_1 t + \beta_2 t^2 + \beta_3 t^3 + \dots + \beta_n t^n \quad (43)$$

- 2) แนวโน้มพหุนามที่มักพบอยู่เสมอ ก็คือแนวโน้มพาราโบลา (Parabola trend) ดังนี้

$$\hat{y} = \alpha_0 + \beta_1 t + \beta_2 t^2 \quad (44)$$

- 3) แนวโน้มเอ็กซ์โปเนนเชียล (Exponential trend)

$$\hat{y} = \alpha_0 + \beta^t \quad (45)$$

- 4) แนวโน้มเอ็กซ์โปเนนเชียลลำดับที่สอง (Second exponential trend)

$$\hat{y} = \alpha_0 + \beta_1^t \beta_2^{t^2} \quad (46)$$

การเลือกรูปแบบของสมการแนวโน้มแบบใดนั้น ขึ้นอยู่กับลักษณะการกระจายของข้อมูลอนุกรมเวลา ดังนั้นก่อนการสร้างสมการพยากรณ์จะต้องทำการทดสอบหรือตรวจสอบว่าตัวแปรหรือข้อมูลที่ต้องการพยากรณ์นั้นมีลักษณะของการกระจาย และมีเส้นกราฟแนวโน้มประเภทใด แล้วเลือกรูปแบบของสมการพยากรณ์ให้สอดคล้องกับรูปแบบการกระจายและเส้นแนวโน้ม เพื่อให้สมการและค่าพยากรณ์ที่ได้จากการคำนวณมีความแม่นยำและคลาดเคลื่อนน้อยที่สุด

### 3.5.2 วิธีการปรับให้เรียบแบบเอ็กซ์โปเนนเชียล (Exponential smoothing)

วิธีการปรับให้เรียบแบบเอ็กซ์โปเนนเชียล (Exponential smoothing) เป็นวิธีพยากรณ์ที่เหมาะสมกับการพยากรณ์ในระยะสั้นและปานกลาง วิธีการนี้ให้ความสำคัญกับข้อมูลล่าสุด และความสำคัญของข้อมูลที่ห่างออกไปจะลดลง วิธีการ Exponential smoothing ที่นิยมในปัจจุบันมีอยู่ 3 วิธี ดังนี้

- 1) Single Exponential Smoothing (SES)

เป็นวิธีการทำให้เรียบอย่างง่าย โดยใช้การหาค่าเฉลี่ยแบบถ่วงน้ำหนัก และสมมติให้ค่าน้ำหนักหรือค่าความสำคัญของข้อมูล คือ  $\alpha$  (Alpha) วิธีการนี้มีเงื่อนไขว่า ข้อมูล

อนุกรมเวลาที่ใช้ในการวิเคราะห์จะต้องไม่มีแนวโน้ม (Trend) และอิทธิพลของฤดูกาล (Seasonality) หมายความว่า ข้อมูลอนุกรมเวลาที่นำมาใช้การวิเคราะห์ต้องมีลักษณะคงที่ สำหรับสมการที่ใช้ในการพยากรณ์สามารถแสดงได้ดังนี้

$$\hat{y}_t = \alpha y_t + (1 + \alpha) \hat{y}_{t-1} \quad (47)$$

หรือ

$$\hat{y}_t = \alpha \sum_{n=0}^{t-1} (1 + \alpha)^n y_{t-n} \quad (48)$$

โดยที่  $y_t$  = ข้อมูล ณ เวลาที่  $t$ ;  $t = 1, 2, \dots, n$   
 $\alpha$  = ค่าถ่วงน้ำหนักความสำคัญที่ให้แก่ข้อมูล ณ เวลาที่  $t$  ( $0 \leq \alpha \leq 1$ )  
 $\hat{y}_t$  = ค่าประมาณหรือพยากรณ์ของข้อมูล ณ เวลาที่  $t$   
 $\hat{y}_{t-1}$  = ค่าประมาณหรือค่าพยากรณ์ของข้อมูล ณ เวลา  $t-1$

## 2) Holt's Two-Parameter Method

วิธี Holt's Two-Parameter Method เป็นวิธีที่ Holt (1957) ได้ปรับปรุงวิธี Single Exponential Smoothing (SES) ขึ้นใหม่เพื่อให้สามารถใช้ข้อมูลอนุกรมเวลาที่มีแนวโน้ม (trend) ของเวลา เรียกวิธีการนี้ว่า "Holt's Two-Parameter Method" วิธีการนี้ให้ความสำคัญกับข้อมูลล่าสุดและแนวโน้มเวลา ดังนั้นจึงมีค่าคงที่ในการทำให้เรียบ 2 ค่า คือ  $\alpha$  (Alpha) และ  $\beta$  (Beta) โดยมีสมการที่ใช้ในการพยากรณ์ดังนี้

$$\hat{y}_{t+k} = a_t + b_k \quad ; \quad \hat{y}_{t+k} = \text{ค่าพยากรณ์ ณ เวลาที่ } t+k \quad (49)$$

ค่า  $a$  และ  $b$  คำนวณจาก

$$a_t = \alpha y_t + (1 + \alpha)(a_{t-1} + b_{t-1}) \quad (50)$$

$$b_t = \beta (a_t - a_{t-1}) + (1 - \beta)b_{t-1} \quad (51)$$

โดยที่

$\alpha$  = ค่าคงที่ที่ทำให้เรียบระหว่างข้อมูลกับพยากรณ์ ( $0 \leq \alpha \leq 1$ )

$\beta$  = ค่าคงที่ที่ทำให้เรียบระหว่างแนวโน้มจริงกับค่าประมาณของแนวโน้ม ( $0 \leq \beta \leq 1$ )



### 3) Holt-Winters-Trend and Seasonal (Three-Parameter)

วิธีนี้ถูกพัฒนาเพิ่มขึ้นจากวิธีการของ Holt โดย Winters (1960) ได้พัฒนาให้วิธีการนี้สามารถวิเคราะห์ข้อมูลอนุกรมเวลาที่มีทั้งแนวโน้ม (Trend) และฤดูกาล (Seasonality) วิธีการนี้ให้ความสำคัญกับข้อมูลล่าสุดแนวโน้มเวลาและฤดูกาล ดังนั้นจึงมีค่าคงที่ในการทำให้เรียบ 3 ค่า คือ  $\alpha$  (Alpha),  $\beta$  (Beta) และ  $\gamma$  (Gamma) โดยมีสมการที่ใช้ในการพยากรณ์ดังนี้

Holt-Wintes-Multiplicative

$$\hat{y}_{t+k} = (a + bk)c_{t+k} \quad ; \quad \hat{y}_{t+k} = \text{ค่าพยากรณ์ ณ เวลาที่ } t+k \quad (52)$$

ค่า  $a, b$  และ  $c$  คำนวณจาก

$$a_t = \alpha \frac{y_t}{c_{t-s}} + (1-\alpha)(a_{t-1} + b_{t-1}) \quad (53)$$

$$b_t = \beta (a_t - a_{t-1}) + (1-\beta)b_{t-1} \quad (54)$$

$$c_t = \gamma \frac{y_t}{a_t} + (1-\gamma) c_{t-1} \quad (55)$$

โดยที่  $\alpha$  = ค่าคงที่ที่ทำให้เรียบระหว่างข้อมูลกับพยากรณ์ ( $0 \leq \alpha \leq 1$ )

$\beta$  = ค่าคงที่ที่ทำให้เรียบระหว่างแนวโน้มจริงกับค่าประมาณของแนวโน้ม ( $0 \leq \beta \leq 1$ )

$\gamma$  = ค่าคงที่ที่ทำให้เรียบระหว่างฤดูกาลจริงกับค่าประมาณของฤดูกาล ( $0 \leq \gamma \leq 1$ )

Holt-Wintes-Additive

$$\hat{y}_{t+k} = (a + bk)c_{t+k} \quad ; \quad \hat{y}_{t+k} = \text{ค่าพยากรณ์ ณ เวลาที่ } t+k \quad (56)$$

ค่า  $a, b$  และ  $c$  คำนวณจาก

$$a_t = \alpha (y_{t-1} - c_{t-1}) + (1-\alpha)(a_{t-1} + b_{t-1}) \quad (57)$$

$$b_t = \beta (a_t - a_{t-1}) + (1-\beta)b_{t-1} \quad (58)$$

$$c_t = \gamma (y_t - a_{t-1}) - \gamma c_{t-1} \quad (59)$$

โดยที่  $\alpha$  = ค่าคงที่ที่ทำให้เรียบระหว่างข้อมูลกับพยากรณ์ ( $0 \leq \alpha \leq 1$ )

$\beta$  = ค่าคงที่ที่ทำให้เรียบระหว่างแนวโน้มจริงกับค่าประมาณของแนวโน้ม ( $0 \leq \beta \leq 1$ )

$\gamma$  = ค่าคงที่ที่ทำให้เรียบระหว่างฤดูกาลจริงกับค่าประมาณของฤดูกาล ( $0 \leq \gamma \leq 1$ )

### 3.6 การประเมินค่าการพยากรณ์

การศึกษาค้นคว้าครั้งนี้ใช้ค่าสถิติ RMSE (Root Mean Squared Error) และ MAPE (Mean Absolute Percentage Error) ในการประเมินค่าการพยากรณ์ เพื่อทดสอบความแม่นยำของผลการพยากรณ์

#### Root Mean Squared Error (RMSE)

$$\text{RMSE} = \sqrt{\sum_{t=T+1}^{T+h} (\hat{Y}_t - Y_t)^2 / h} \quad (60)$$

#### Mean Absolute Percentage Error (MAPE)

$$\text{MAPE} = 100 \sum_{t=T+1}^{T+h} \left| \frac{\hat{Y}_t - Y_t}{Y_t} \right| / h \quad (61)$$