

## บทที่ 2

# ทฤษฎีที่เกี่ยวข้อง

**การพยากรณ์อนุกรมเวลา (Time Series Forecasting)** เป็นวิธีการทางสถิติที่ใช้วิเคราะห์หาตัวแบบอธิบายลักษณะความสัมพันธ์ระหว่างค่าสังเกตที่เก็บตามลำดับเวลาของข้อมูลในอดีตและใช้ตัวแบบนั้นในการพยากรณ์ค่าสังเกตในอนาคต ข้อมูลอนุกรมเวลาเป็นข้อมูลที่มีการเก็บรวบรวมที่มีระยะเวลาห่างเท่าๆกันและต่อเนื่องกัน ดังนั้นข้อมูลอนุกรมเวลาจึงแสดงการเปลี่ยนแปลงตามคาบเวลาโดยอาจจะเป็นปี เดือน สัปดาห์ วัน หรือชั่วโมง

ในการวิเคราะห์ข้อมูลอนุกรมเวลาสามารถแยกความผันแปรของข้อมูลออกเป็น 4 องค์ประกอบ ดังนี้

- 1) แนวโน้ม (Trend) เป็นการเปลี่ยนแปลงของข้อมูลในระยะยาว
- 2) ความผันแปรตามฤดูกาล (Seasonal Variation) เป็นการเปลี่ยนแปลงของข้อมูลที่เกิดขึ้นเนื่องจากอิทธิพลของฤดูกาล ซึ่งเกิดขึ้นซ้ำๆกันในช่วงเวลาเดียวกันของแต่ละปี
- 3) ความผันแปรตามวัฏจักร (Cyclical Variation) เป็นการเปลี่ยนแปลงของข้อมูลที่เกิดขึ้นซ้ำๆกันในระยะยาวมากกว่า 1 ปี
- 4) ความผันแปรที่ไม่แน่นอน (Irregular Variation) เป็นการเปลี่ยนแปลงของข้อมูลที่ไม่ใช่รูปแบบแน่นอน ดังนั้นจึงไม่สามารถคาดคะเนหรือพยากรณ์ความผันแปรที่ไม่แน่นอนโดยใช้ข้อมูลจากอดีตได้

ข้อมูลอนุกรมเวลาแต่ละชุดอาจได้รับอิทธิพลของปัจจัยที่เป็นส่วนประกอบของอนุกรมเวลาทั้ง 4 องค์ประกอบหรือบางปัจจัยเท่านั้น ในการวิเคราะห์จึงควรแยกวิเคราะห์ที่ละปัจจัย

เทคนิคการพยากรณ์มีหลายวิธี ในที่นี้จะกล่าวถึงเฉพาะวิธีที่สนใจศึกษา คือ วิธีบ็อกซ์-เจนกินส์ (Box-Jenkins' Method) และวิธีปรับให้เรียบเอกซ์โพเนนเชียล (Exponential Smoothing) ซึ่งมีรายละเอียดดังนี้

### 2.1 วิธีบ็อกซ์-เจนกินส์ (Box-Jenkins' Method)

ข้อมูลที่จะนำมาใช้ในการวิเคราะห์อนุกรมเวลาจำเป็นต้องไม่มีสหสัมพันธ์กัน George E.P.Box และ Gwilym M. Jenkins ได้เสนอวิธีหาตัวแบบพยากรณ์ (วิธีบ็อกซ์-เจนกินส์) โดยพิจารณาสหสัมพันธ์ระหว่าง  $Y$  ที่คาบเวลา  $t$  ( $Y_t$ ) กับคาบเวลาที่ผ่านมา ( $Y_{t-1}, Y_{t-2}, \dots$ ) ซึ่งจะได้ตัวแบบซึ่งแสดงความสัมพันธ์ระหว่าง  $Y_t$  กับ  $Y_{t-1}, Y_{t-2}, \dots$  ในอนาคต ตัวแบบจากวิธีบ็อกซ์-เจนกินส์ โดยทั่วไปจึงใช้พยากรณ์ข้อมูลในช่วงเวลาข้างหน้าที่เป็นระยะสั้น หรือ ปานกลาง ทั้งนี้เพราะตัวแบบโดยทั่วไปจะให้ความสำคัญกับข้อมูลในอดีตระยะใกล้มากกว่าข้อมูลในอดีตที่ช่วงเวลาซึ่งห่างไกลออกไปมาก ๆ

ข้อมูลอนุกรมเวลาที่สามารถนำมาวิเคราะห์ด้วยวิธีบ็อกซ์-เจนกินส์ได้ อาจเป็นข้อมูลที่เป็นเลขจำนวนเต็ม หรือมีทศนิยมก็ได้ อาจมีค่าเป็นบวก หรือเป็นลบได้แต่จะต้องเป็นข้อมูลที่จัดเก็บโดยมีช่วงห่างของเวลาในระยะมีเท่ากัน นอกจากนี้ยังใช้ได้กับข้อมูลที่มีแนวโน้มการผันแปรตามวัฏจักร หรือการผันแปรตามฤดูกาล ซึ่งข้อมูลอนุกรมเวลาชุดหนึ่ง ๆ อาจมีองค์ประกอบมากกว่าหนึ่งองค์ประกอบได้ ในการหาตัวแบบพยากรณ์ด้วยวิธีบ็อกซ์-เจนกินส์ จะใช้จำนวนข้อมูลค่อนข้างมาก ซึ่งควรมีอย่างน้อย 50 ค่า อย่างไรก็ตามในบางกรณีก็พบว่าการใช้ข้อมูลจำนวนน้อยกว่า 50 ค่าไม่มากนักก็สามารถใช้ได้ ในกรณีที่ข้อมูลมีองค์ประกอบฤดูกาลควรใช้ข้อมูลจำนวนมากกว่า 50 เพราะถ้ามีจำนวนข้อมูลน้อยก็อาจจะไม่เห็นอิทธิพลของฤดูกาล นอกจากนี้วิธีบ็อกซ์-เจนกินส์ใช้กับข้อมูลที่อยู่ในสถานะนิ่งหรือคงที่ (Stationary) การทดสอบสถานะนิ่งหรือสถานะคงที่ของอนุกรมเวลาสามารถใช้การทดสอบโค-รีโลแกรม (Correlogram Test) และการทดสอบยูนิทรูท (Unit Root Test) ในที่นี้จะกล่าวเฉพาะการทดสอบยูนิทรูท โดยมีรายละเอียดดังนี้

จากตัวแบบอนุกรมเวลา  $Y_t = \rho Y_{t-1} + \mu_t$  โดย  $\mu_t$  เป็นค่าความคลาดเคลื่อนเชิงสุ่ม ซึ่งหาก  $|\rho| < 1$  แสดงว่าข้อมูลมีสถานะคงที่ และหาก  $\rho = 1$  แสดงว่าข้อมูลมีสถานะไม่คงที่ ดังนั้นในการทดสอบว่าข้อมูลอนุกรมเวลามีสถานะคงที่หรือไม่ จะตั้งสมมติฐานหลัก  $H_0 : \rho = 1$  ซึ่งหากยอมรับสมมติฐานหลักจะได้ผลสรุปว่าข้อมูลไม่มีสถานะคงที่ แต่หากปฏิเสธสมมติฐานหลักจะสรุปว่าข้อมูลอยู่ในสถานะคงที่ หากพิจารณาจากการเปลี่ยนแปลงของข้อมูลจากคาบเวลาหนึ่งไปอีกคาบเวลาหนึ่งได้เช่นกัน ซึ่งสามารถเขียนเป็นตัวแบบ  $Y_t - Y_{t-1} = \Delta Y_t = (\rho - 1)Y_{t-1} + \mu_t$  ถ้าให้  $(1 - \rho) = \theta$  จะได้  $\rho = 1 + \theta$  โดย  $\Delta Y_t$  เป็นผลต่างอันดับที่ 1 ดังนั้นสามารถเขียนตัวแบบของผลต่างอันดับที่ 1 ดังนี้  $Y_t = (1 + \theta)Y_{t-1} + \mu_t$  ในการทดสอบสมมติฐานว่าค่าผลต่างอันดับที่ 1 มีสถานะคงที่หรือไม่ จะตั้งสมมติฐานหลัก  $H_0 : \theta = 0$  ซึ่งหาก  $\theta = 0$  จะได้  $\rho = 1$  ซึ่งจะสรุปว่าค่าผลต่างอันดับที่ 1 ไม่มีสถานะคงที่ สำหรับในกรณีที่ข้อมูลอนุกรมเวลามีแนวโน้มและความผันแปรตามฤดูกาลรวมอยู่ด้วย  $\Delta Y_t = \alpha + \beta t + \theta Y_{t-1} + \mu_t$  ในการทดสอบว่าข้อมูลอยู่ในสถานะคงที่หรือไม่ก็สามารถตั้งสมมติฐานเพื่อการทดสอบในรูปแบบเดียวกัน

แนวคิดของการพัฒนาตัวแบบบ็อกซ์-เจนกินส์ มาจากการศึกษาวิเคราะห์กระบวนการเชิงเส้นหรือตัวกรองเชิงเส้น

$$Y_t = \mu + a_t + \psi_1 a_{t-1} + \psi_2 a_{t-2} + \dots \quad \dots \dots \dots (2.1)$$

โดย  $\mu$  เป็นค่าเฉลี่ยของ  $Y_t$  เมื่ออนุกรมเวลาอยู่ในสถานะคงที่หรือสถานะนิ่ง ค่าพารามิเตอร์  $\psi_1, \psi_2, \psi_3, \dots$  เป็นน้ำหนักที่ให้กับตัวแปรสุ่ม  $a_{t-1}, a_{t-2}, a_{t-3}, \dots$

ในการกำหนดตัวแบบเชิงเส้นจำเป็นต้องให้มีพารามิเตอร์จำนวนจำกัดและเพียงพอที่จะอธิบายอนุกรมเวลาได้

**ฟังก์ชันสหสัมพันธ์ในตัวเอง (Autocorrelation Function : ACF)** เป็นมาตรวัดความสัมพันธ์ของข้อมูลที่เกิดขึ้นในเวลาต่างๆ ค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างตัวแปร  $Y_t$

และ  $Y_{t+k}$  ในอนุกรมเวลาที่อยู่ห่างกัน  $k$  ช่วงเวลา เขียนแทนด้วย  $\rho_k$  โดยมี  $r_k$  เป็นค่าประมาณ

$$\text{ซึ่งคำนวณจากสูตร } r_k = \frac{\sum_{t=1}^{n-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2}, \quad k = 1, 2, 3, \dots \quad \text{โดย } \bar{Y} = \frac{\sum_{t=1}^n Y_t}{n}$$

การทดสอบความสัมพันธ์ในตัวเองของประชากร มีขั้นตอนการทดสอบดังนี้

- (1) ตั้งสมมติฐานในการทดสอบ  $H_0 : \rho_k = 0$  ;  $H_1 : \rho_k \neq 0$
- (2) ตัวสถิติที่ใช้ทดสอบ คือ  $r_k$
- (3) เกณฑ์ที่ใช้ในการปฏิเสธ  $H_0$  จากการใช้ระดับนัยสำคัญ 0.05 ในกรณีที่

ขนาดตัวอย่าง ( $n$ ) มีค่ามาก คือ  $|r_k| > \frac{t_{\alpha/2}; df}{n}$  ซึ่งสามารถอธิบายได้ว่าค่าสหสัมพันธ์ในตัวเองของประชากรที่อยู่ห่างกัน  $k$  ช่วงเวลามีค่าแตกต่างจากศูนย์

### ฟังก์ชันสหสัมพันธ์ในตัวเองบางส่วน (Partial Autocorrelation Function : PACF)

เป็นค่าสหสัมพันธ์ในตัวเองระหว่างตัวแปร  $Y_t$  และ  $Y_{t+k}$  ในอนุกรมเวลาที่อยู่ห่างกัน  $k$  ช่วงเวลาที่ขจัดอิทธิพลของตัวแปรที่อยู่ระหว่างตัวแปรทั้งสองได้แก่  $Y_{t+1}, Y_{t+2}, Y_{t+3}, \dots, Y_{t+k-1}$  ออกไป โดยเขียนแทนด้วยสัญลักษณ์  $r_{k,k}$  ซึ่งสามารถประมาณด้วยค่าสัมประสิทธิ์สหสัมพันธ์ในตัวเองบางส่วนจากตัวอย่างที่อยู่ห่างกัน  $k$  ช่วงเวลา (Sample Partial Autocorrelation of Lag  $k$ ) เขียนแทนด้วยสัญลักษณ์  $r_{k,k}$  ซึ่งคำนวณได้จากสูตร

$$r_{k,k} = \begin{cases} r_1, & k=1 \\ \frac{r_k - \sum_{j=1}^{k-1} r_{k-1,j} r_{k-j}}{1 - \sum_{j=1}^{k-1} r_{k-1,j} r_j}, & k=2,3,\dots \end{cases} \quad \text{โดยที่ } r_{kj} = r_{k-1,j} - r_{kk} r_{k-1,k-j} \quad j=1,2,3,\dots,k-1$$

การทดสอบความสัมพันธ์ในตัวเองบางส่วนของประชากร มีขั้นตอนการทดสอบดังนี้

- (1) ตั้งสมมติฐานในการทดสอบ  $H_0 : \phi_{k,k} = 0$  ;  $H_1 : \phi_{k,k} \neq 0$
- (2) ตัวสถิติที่ใช้ทดสอบ คือ  $r_{k,k}$
- (3) เกณฑ์ที่ใช้ในการปฏิเสธ  $H_0$  จากการใช้ระดับนัยสำคัญ 0.05 ในกรณีที่

ขนาดตัวอย่าง ( $n$ ) มีค่ามาก คือ  $|r_{k,k}| > \frac{t_{\alpha/2}; df}{n}$  ซึ่งสามารถอธิบายได้ว่าค่าสหสัมพันธ์ในตัวเองของประชากรที่อยู่ห่างกัน  $k$  ช่วงเวลามีค่าแตกต่างจากศูนย์

### 2.1.1 ตัวแบบสถานะนิ่ง (Stationary Models)

- ตัวแบบอัตถดถอย (Autoregressive Models : AR)

ภายใต้สถานะนิ่งหรือสถานะคงที่ อนุกรมเวลาจะเคลื่อนไหวยุบค่าคงที่ค่าหนึ่งให้เป็น  $\mu$  ซึ่งเป็นค่าเฉลี่ยของ  $Y_t$  เมื่ออนุกรมเวลาอยู่ในสถานะนิ่ง ดังนั้นจึงได้ “ตัวแบบอัตถดถอยอันดับ  $p$ ” หรือ “กระบวนการถดถอยอันดับ  $p$ ” (autoregressive process of order  $p$ ) เขียนแทนด้วยสัญลักษณ์  $AR(p)$  ซึ่งมีตัวแบบทั่วไปดังนี้

$$Y_t - \mu = \phi_1(Y_{t-1} - \mu) + \phi_2(Y_{t-2} - \mu) + \dots + \phi_p(Y_{t-p} - \mu) + a_t$$

หรือ

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t$$

หรือ

$$Y_t = c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + a_t \quad \dots \dots \dots (2.2)$$

โดยให้  $Z_t = Y_t - \mu$ ,  $Z_{t-1} = Y_{t-1} - \mu, \dots$  และ  $c = \mu(1 - \phi_1 - \phi_2 - \dots - \phi_p)$  และ

$\phi_1, \phi_2, \phi_3, \dots, \phi_p, \mu$  เป็นพารามิเตอร์ที่ต้องประมาณค่าโดยอาศัยข้อมูลอนุกรมเวลา

จากตัวแบบ  $AR(p)$  สามารถเขียนแทนด้วยตัวแบบสั้นๆ ได้ดังนี้

$$\phi_p(B)Z_t = a_t \quad \dots \dots \dots (2.3)$$

โดย  $\phi_p(B) = (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)$

และ  $BZ_t = Z_{t-1}$ ,  $B^2 Z_t = Z_{t-2}, \dots, B^p Z_t = Z_{t-p}$ ;  $Z_t = Y_t - \mu$  เรียก  $B$  ว่า “ตัวถอยหลังเวลา”

(backward - shift operator)

- ตัวแบบค่าเฉลี่ยเคลื่อนที่ (Moving Average Models : MA)

จากตัวแบบเชิงเส้น (2.1) สามารถพัฒนาเป็น “ตัวแบบค่าเฉลี่ยเคลื่อนที่อันดับ  $q$ ” หรือ “กระบวนการค่าเฉลี่ยเคลื่อนที่อันดับ  $q$ ” (moving average process of order  $q$ ) เขียนแทนด้วยสัญลักษณ์  $MA(q)$  ซึ่งมีตัวแบบทั่วไปดังนี้

$$Y_t = \mu + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad \dots \dots \dots (2.4)$$

หรือ

$$Z_t = \theta_q(B)a_t \quad \dots \dots \dots (2.5)$$

โดย  $Z_t = Y_t - \mu$ ;  $\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$

ตัวแบบบอซ-เจนกินส์ ยังมีเงื่อนไขที่สอดคล้องอีกเงื่อนไขหนึ่งนอกเหนือจากเงื่อนไขคงที่หรือหนึ่ง คือเงื่อนไข “ผกผันได้” (invertibility) ซึ่งพบว่าตัวแบบ  $AR(p)$ ,  $0 < p < \infty$  มีคุณสมบัติผกผันได้เสมอ แต่อาจไม่มี ในขณะที่ตัวแบบ  $MA(q)$ ,  $0 < q < \infty$  มีคุณสมบัติคงที่เสมอแต่อาจจะผกผันไม่ได้ ดังนั้นจึงจำเป็นต้องตรวจสอบคุณสมบัติหนึ่งในตัวแบบ  $AR$  และตรวจสอบคุณสมบัติผกผันได้ในตัวแบบ  $MA$

- ตัวแบบผสมอัตถดถอย-ค่าเฉลี่ยเคลื่อนที่ (Autoregressive Moving : ARMA)

ในบางกรณีการใช้ตัวแบบหรือกระบวนการผสมระหว่างตัวแบบ  $AR$  และ  $MA$  จะเป็นตัวแบบที่ประหยัดแทนการใช้ตัวแบบ  $AR$  อันดับสูงๆ ตัวแบบเดียว หรือใช้ตัวแบบ  $MA$  อันดับสูงๆ ตัวแบบเดียว ตัวแบบผสมระหว่าง  $AR(p)$  และ  $MA(q)$  เขียนแทนด้วยสัญลักษณ์  $ARMA(p, q)$  โดยมีรูปแบบสมการดังนี้

$$Y_t = \mu + \phi_1(Y_{t-1} - \mu) + \phi_2(Y_{t-2} - \mu) + \dots + \phi_p(Y_{t-p} - \mu) + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad \dots\dots\dots(2.6)$$

หรือ  $\phi_p(B)Z_t = \theta_q(B)a_t \quad \dots\dots\dots(2.7)$

### 2.1.2 ตัวแบบที่ไม่อยู่ในสถานะคงที่ (Nonstationary Models)

ในกรณีที่ข้อมูลอนุกรมเวลาหรือกระบวนการ  $Y_t$  ไม่อยู่ในสถานะคงที่ในค่าเฉลี่ยและ/หรือ ความแปรปรวน จำเป็นต้องแปลงข้อมูลให้อยู่ในสถานะนิ่งก่อนจึงกำหนดตัวแบบพยากรณ์

1) ในกรณีที่ข้อมูลอนุกรมเวลาไม่นิ่งหรือไม่คงที่ในค่าเฉลี่ย ให้พิจารณาจากค่าผลต่างของ ข้อมูลในคาบเวลาที่ติดกัน ในบางกรณีต้องการค่าผลต่างมากกว่าสองครั้งจึงจะทำให้ข้อมูลอยู่ใน สถานะนิ่ง ซึ่งการหาค่าผลต่างหลายครั้งจะทำให้การพยากรณ์มีความคลาดเคลื่อนสูง

- ในการหาค่าผลต่างครั้งที่หนึ่งจะได้ข้อมูล  $W_t = (1-B)Y_t = Y_t - Y_{t-1}$ ,  $t = 2, 3, 4, \dots, n$

- ในการหาค่าผลต่างครั้งที่สองจะได้ข้อมูลชุดใหม่ดังนี้

$$X_t = (1-B)W_t = (1-B)^2 Y_t = (1-2B+B^2)Y_t = Y_t - 2Y_{t-1} + Y_{t-2}, t = 3, 4, 5, \dots, n$$

- ในการหาค่าผลต่างครั้งที่  $d$  (หาผลต่าง  $d$  ครั้ง) จะได้ข้อมูลชุดใหม่ดังนี้

$W_t = (1-B)^d Y_t$ ,  $t = d+1, d+2, d+3, \dots, n$  โดย  $B$  คือตัวดำเนินการถอยหลัง

(backshift operator) ของตัวแปร  $X_t$  ใดๆ ซึ่งมีนิยามดังนี้  $B^k X_t = X_{t-k}$ ,  $k = 0, 1, 2, \dots$

และสำหรับค่าคงที่ใดๆจะไม่มีผลจาก  $B$  ซึ่ง  $B^k C = C$ ,  $k = 0, 1, 2, \dots$

2) ในกรณีที่ข้อมูลอนุกรมเวลาไม่นิ่งหรือไม่คงที่ในความแปรปรวน หรือมีการเคลื่อนไหว เป็นเส้นโค้ง

วิธีการแปลงข้อมูลที่ใช้เมื่อความแปรปรวนมีค่าผันแปรตามค่าเฉลี่ย (ความแปรปรวนมีค่า มากขึ้นเมื่ออนุกรมมีแนวโน้มเพิ่มขึ้น หรือมีค่าเฉลี่ยเพิ่มขึ้น) คือการหาค่า  $\ln$  ของอนุกรม  $Y_t$  ดังนั้นจึงได้ข้อมูลชุดใหม่  $X_t = \ln Y_t$ ,  $Y_t > 0$ ,  $t = 1, 2, 3, \dots, n$  ในกรณีที่ใช้วิธีนี้ไม่ได้ผลอาจใช้วิธี ทหารากที่สองของอนุกรม  $Y_t$  ซึ่งจะได้ข้อมูลชุดใหม่  $X_t = \sqrt{Y_t}$ ,  $Y_t > 0$ ,  $t = 1, 2, 3, \dots, n$

ในกรณีที่อนุกรมเวลาไม่คงที่ทั้งในค่าเฉลี่ยและความแปรปรวน จะต้องแปลงข้อมูลให้หนึ่งใน ค่าค่าเฉลี่ยและความแปรปรวน ซึ่งโดยทั่วไปจะแปลงข้อมูลให้หนึ่งในความแปรปรวนก่อนแต่ หากค่าผลต่างมีค่าเป็นลบก็จำเป็นต้องหาค่ารากที่สองของข้อมูลก่อนจึงหาค่าผลต่างของข้อมูล ตัวแบบ ARIMA  $(p, d, q)$  ของข้อมูลที่หาค่าผลต่าง  $d$  ครั้ง มีรูปแบบทั่วไปดังนี้

$$\phi_p(B)(1-B)^d Y_t = \delta + \theta_q(B)a_t \quad \dots\dots\dots(2.8)$$

หรือ  $\phi_p(B)W_t = \delta + \theta_q(B)a_t \quad \dots\dots\dots(2.9)$

โดย  $W_t = (1-B)^d Y_t$  ซึ่ง  $Y_t$  เป็นอนุกรมเวลาที่ถูกลบค่าความแปรปรวนคงที่แล้ว

และ  $\delta$  เป็นค่าคงที่ในตัวแบบ ซึ่งโดยปกติในทางปฏิบัติจะให้  $\delta = 0$  ถ้าค่าเฉลี่ยของอนุกรม  $W_t$  มีค่าไม่แตกต่างจากศูนย์อย่างมีนัยสำคัญ

### 2.1.3 ตัวแบบ ARIMA เมื่อมีองค์ประกอบฤดูกาล

ในการวิเคราะห์ข้อมูลอนุกรมเวลาโดยใช้ ตัวแบบ ARIMA เมื่อมีองค์ประกอบฤดูกาล สามารถเขียนแทนด้วยสัญลักษณ์ SARIMA  $(p,d,q)(P,D,Q)_s$  หรือ ARIMA  $(p,d,q)(P,D,Q)_s$  มีสมการดังนี้

$$\text{SARIMA } (p,d,q)(P,D,Q)_s : \phi_p(B)\Phi_p(B^s)(1-B)^d(1-B^s)^D Y_t = \delta + \theta_q(B)\Theta_Q(B^s)a_t$$

$$\text{โดย } \Phi_p(B^s) = (1 - \Phi_1 B^s - \Phi_2 B^{2s} - \dots - \Phi_p B^{ps})$$

$$\Theta_Q(B^s) = (1 - \Theta_1 B^s - \Theta_2 B^{2s} - \dots - \Theta_Q B^{Qs})$$

ในที่นี้ขอยกตัวอย่างการเขียนรูปแบบของสมการที่ได้จากการวิเคราะห์โดยใช้ตัวแบบ SARIMA  $(p,d,q)(P,D,Q)_s$  ใน 2 ตัวแบบ คือ ตัวแบบ SARIMA  $(0,1,0)(0,1,1)_4$  และตัวแบบ SARIMA  $(0,1,1)(1,1,0)_{12}$  โดยมีรายละเอียดดังนี้

$$\text{ตัวแบบ SARIMA } (0,1,0)(0,1,1)_4 : (1-B)(1-B^4)Y_t = \delta + (1 - \Theta_4 B^4)Y_t$$

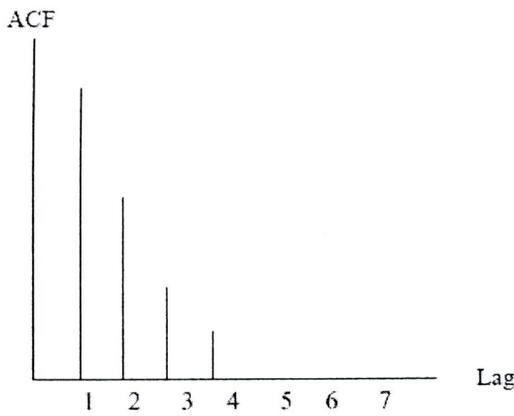
$$\text{หรือ } W_t = \delta + a_t - \Theta_4 a_{t-4}, W_t = (1-B)(1-B^4)Y_t$$

$$\text{ตัวแบบ SARIMA } (0,1,1)(1,1,0)_{12} : (1 - \Phi_{12} B^{12})(1-B)(1-B^{12})Y_t = \delta + (1 - \Theta_1 B)a_t$$

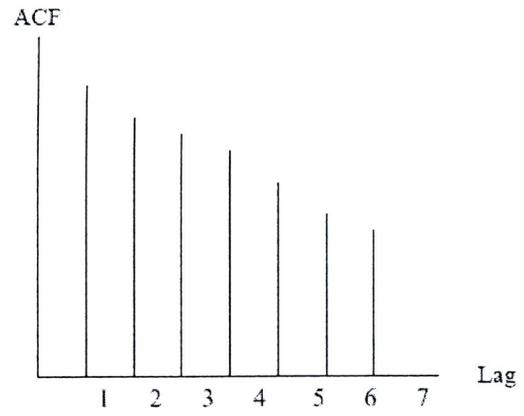
$$\text{หรือ } W_t = \delta + \Phi_{12} W_{t-12} + a_t - \Theta_1 a_{t-1}, W_t = (1-B)(1-B^{12})Y_t$$

การกำหนดอันดับ  $(p,d,q)$  และ  $(P,D,Q)_s$  ในตัวแบบ SARIMA  $(p,d,q)(P,D,Q)_s$  จะพิจารณาแยกกันแต่ใช้หลักเกณฑ์ในการพิจารณาเหมือนกัน ซึ่งกระบวนการ AR และ MA ต่างมีรูปแบบโครงสร้างเฉพาะสำหรับอันดับ  $p$  และ  $q$  ของฟังก์ชันอัตสหสัมพันธ์ ACF (Autocorrelation Function :  $\rho_k$ ) และโครงสร้างของฟังก์ชันอัตสหสัมพันธ์ย่อย PACF (Partial Autocorrelation Function :  $\phi_{k,k}$ ) ในการกำหนดค่า  $p$ ,  $q$ ,  $P$  และ  $Q$  จะต้องประมาณค่า  $\rho_k$  และ  $\phi_{k,k}$  โดยใช้ข้อมูลอนุกรมเวลาของตัวอย่าง ดังนั้นจึงใช้ค่าประมาณของ  $\rho_k$  และ  $\phi_{k,k}$  ซึ่งเขียนแทนด้วยสัญลักษณ์  $r_k$  และ  $r_{k,k}$  ซึ่งเป็นฟังก์ชันอัตสหสัมพันธ์ตัวอย่าง (Sample Autocorrelation Function : SACF) และฟังก์ชันอัตสหสัมพันธ์ย่อยของตัวอย่าง (Sample Partial Autocorrelation Function : SPACF) ตามลำดับ

จากการเปรียบเทียบลักษณะของฟังก์ชันสหสัมพันธ์ในตัวเอง (ACF) และฟังก์ชันสหสัมพันธ์ในตัวเองบางส่วนในตัวเอง (PACF) ของค่าสังเกตกับลักษณะของ ACF และ PACF ตามทฤษฎีของตัวแบบ ARIMA อันดับต่างๆ ซึ่งเสนอโดย บอกซ์-เจนกินส์ (1976) ซึ่งในการกำหนดอันดับของ  $p$  และ  $q$  พิจารณาจาก ACF และ PACF ประกอบกัน ถ้าเป็นตัวแบบ AR อันดับ  $p$  (AR(p)) กราฟของ ACF จะมีลักษณะลดลงเข้าสู่ศูนย์อย่างรวดเร็ว ในขณะที่ กราฟของ PACF ที่ห่างกันเกิน  $p$  ช่วงจะมีลักษณะลดลงเข้าสู่ศูนย์อย่างรวดเร็ว



รูปที่ 2.1 กราฟ ACF ของข้อมูลที่คงที่ (stationary)



รูปที่ 2.2 กราฟ ACF ของข้อมูลที่ไม่คงที่ (non-stationary)

ถ้าเป็นตัวแบบ MA (Moving Average) อันดับ  $q$  ((MA ( $q$ )) สหสัมพันธ์ในตัวเองที่ห่างกันเกิน  $q$  ช่วงเวลาจะมีลักษณะลดลงเข้าสู่ศูนย์อย่างรวดเร็วและสหสัมพันธ์ในตัวเองบางส่วนจะมีลักษณะลดลงเข้าสู่ศูนย์อย่างรวดเร็ว

ถ้าเป็นตัวแบบผสมระหว่าง AR และ MA (Mixed Autoregressive Moving Average : ARMA ( $p, q$ )) สหสัมพันธ์ในตัวเองที่ห่างกันเกิน  $q$  ช่วงเวลา และสหสัมพันธ์ในตัวเองบางส่วนที่ห่างกันเกิน  $p$  ช่วงเวลา จะมีลักษณะลดลงเข้าสู่ศูนย์อย่างรวดเร็ว

ถ้าทั้งสหสัมพันธ์ในตัวเองและสหสัมพันธ์ในตัวเองบางส่วนมีค่าเท่ากับศูนย์ทุกช่วงห่าง จะได้แบบจำลองที่เรียกว่า White Noise โดยมีตัวแบบ  $Y_t = \theta_0 + \varepsilon_t$  ;  $\varepsilon_t \sim \text{IN}(0, \sigma_\varepsilon^2)$

ถ้าทั้งสหสัมพันธ์ในตัวเองบางส่วนจากข้อมูลอนุกรมเวลาที่ได้จากการแปลงให้เป็นอนุกรมเวลา คงที่โดยการหาผลต่าง มีค่าเท่ากับศูนย์จะได้ตัวแบบที่เรียกว่า Random Walk โดย

$$Y_t = Y_{t-1} + \theta_0 + \varepsilon_t ; \varepsilon_t \sim \text{IN}(0, \sigma_\varepsilon^2)$$

ในการเลือกตัวแบบ ARIMA จำเป็นต้องทราบลักษณะการผันแปรของค่า  $\rho_k$  และ  $\phi_{k,k}$  ทางทฤษฎี ซึ่งมีรายละเอียดดังนี้

กระบวนการ	ACF	PACF
AR(1)	ค่า $\rho_k$ ลดลงอย่างรวดเร็วขณะที่ $k > 1$	ค่า $\phi_{k,k}$ จะมีค่าสูงที่ $k = 1$ และมีค่าเท่ากับศูนย์เมื่อ $k > 1$
AR(2)	ค่า $\rho_k$ ลดลงอย่างรวดเร็วขณะที่ $k > 1$	ค่า $\phi_{k,k}$ จะมีค่าสูงที่ $k = 1, 2$ และมีค่าเท่ากับศูนย์เมื่อ $k > 2$
MA(1)	ค่า $\rho_k$ มีค่าสูงที่ $k = 1$ และเท่ากับศูนย์เมื่อ $k > 1$	ค่า $\phi_{k,k}$ ลดลงอย่างรวดเร็วขณะที่ $k > 1$
ARMA(1,1)	ค่า $\rho_k$ ลดลงอย่างรวดเร็วหลัง lag $k=1$	ค่า $\phi_{k,k}$ ลดลงอย่างรวดเร็วหลัง lag $k=1$

สำหรับกระบวนการ AR , MA และ ARMA ที่อันดับอื่นๆ มีวิธีพิจารณาในทำนองเดียวกัน ในองค์ประกอบที่เป็นฤดูกาลที่มีคาบฤดูกาล  $s$  นั้น การกำหนดอันดับ  $P$  และ  $Q$  มีวิธีพิจารณาทำนองเดียวกับองค์ประกอบที่ไม่มีฤดูกาล โดยพิจารณาโครงสร้างของการผันแปรของค่าอัตโนมัติสัมพันธ์  $r_k$  และ  $r_{k,k}$  ที่ lag ฤดูกาล  $s, 2s, 3s, \dots$  เปรียบเทียบกับโครงสร้างของ  $\rho_k$  และ  $\phi_{k,k}$  ทางทฤษฎี ซึ่งมีลักษณะการผันแปรที่เหมือนกับกรณีที่ไม่มีองค์ประกอบฤดูกาล

**การประมาณค่าพารามิเตอร์ (Estimation)** หลังจากได้กำหนดแบบจำลองในขั้นตอนที่ 1 แล้วจะประมาณค่าพารามิเตอร์ของแบบจำลองโดยวิธีกำลังสองน้อยที่สุด (Least-Squares Method) โดยโปรแกรมสำเร็จรูปจะกำหนดค่าประมาณเบื้องต้น (initial estimates) เพื่อประมวลผลจนได้ค่าประมาณสุดท้าย โปรแกรมสำเร็จรูปจะคำนวณแบบย่อนซ้ำ (iterative) จนกว่าจะให้ค่าผลรวมของค่าประมาณความคลาดเคลื่อนกำลังสอง ( $\sum_{i=1}^n \hat{\epsilon}_i^2$ ) มีค่าน้อยที่สุด โดย  $\hat{\epsilon}_i$  เป็นค่าประมาณความคลาดเคลื่อน  $\epsilon_i$  จากนั้นนำตัวแบบที่ได้ไปตรวจสอบความเหมาะสม

**การวินิจฉัยตัวแบบ ARIMA** หลังจากการประมาณค่าพารามิเตอร์ของตัวแบบแล้วจำเป็น ต้องตรวจสอบว่าตัวแบบมีความเหมาะสมหรือไม่ ซึ่งหากตัวแบบไม่เหมาะสมจำเป็นต้องกลับไปปรับปรุงตัวแบบ ประมาณค่าพารามิเตอร์และตรวจสอบความเหมาะสมของตัวแบบอีกครั้ง โดย จะทำการกระวนซ้ำๆกันไปจนกระทั่งได้ตัวแบบที่เหมาะสม ในการวินิจฉัยตัวแบบจะตรวจสอบคุณสมบัติเชิงสถิติของค่าความคลาดเคลื่อนสุ่ม  $\{a_i\}$  และทดสอบว่าค่าความคลาดเคลื่อนสุ่มมีอิสระสัมพันธ์กันหรือไม่ เป็นการตรวจสอบที่สำคัญมากที่สุดในการวินิจฉัยความเหมาะสมในเชิงสถิติ โดยคำนวณค่า SACF ของค่าตกค้าง (residuals)  $\hat{\epsilon}_i = y_i - \hat{y}_i$  (เป็นค่าประมาณของ  $a_i$ ) ที่ lag  $k$  จากนั้นจึงทดสอบว่าค่าความคลาดเคลื่อนสุ่มมีอิสระสัมพันธ์กันหรือไม่ ที่แต่ละ lag  $k=1, 2, 3, \dots, m$  และทดสอบว่าค่าความคลาดเคลื่อนสุ่มไม่มีอิสระสัมพันธ์กันใน  $k$  lag แรก โดยใช้ตัวสถิติทดสอบ Box-Pierce หรือ ตัวสถิติทดสอบ Ljung-Box นอกจากนี้อาจตรวจสอบด้วยการเขียนกราฟของค่าตกค้างกับเวลา ซึ่งหากพบว่าค่าตกค้างกระจายเป็นแนวในลักษณะฆานรอบค่าศูนย์ อาจกล่าวได้ว่าค่าเฉลี่ยของความคลาดเคลื่อนมีค่าเท่ากับศูนย์ และมีค่าความแปรปรวนคงที่ แต่หากการกระจายของค่าตกค้างมีรูปแบบต่างไปจากแนวฆานแสดงว่าค่าความแปรปรวนยังไม่คงที่ ควรพิจารณาปรับปรุงแก้ไขตัวแบบโดยอาจจะใช้วิธีแปลงข้อมูล

การตรวจสอบความเหมาะสมของตัวแบบ (Diagnostic Checking) เป็นการตรวจสอบว่าแบบจำลองที่เลือกเหมาะสมกับข้อมูลอนุกรมเวลาหรือไม่โดยมีขั้นตอนการวิเคราะห์ดังนี้

1) ทดสอบค่าประมาณพารามิเตอร์ในแบบจำลองตามขั้นตอนดังต่อไปนี้

(1) ตั้งสมมติฐานเพื่อการทดสอบ

$$H_0: \text{พารามิเตอร์} = 0 ; H_1: \text{พารามิเตอร์} \neq 0$$

(2) ตัวสถิติทดสอบ  $t = \left( \frac{\text{ค่าประมาณพารามิเตอร์}}{\text{ค่าส่วนเบี่ยงเบนมาตรฐานของตัวประมาณ}} \right)$

ค่าส่วนเบี่ยงเบนมาตรฐานของตัวประมาณ

(3) เกณฑ์ที่ใช้ในการปฏิเสธ  $H_0$  จากการใช้ระดับนัยสำคัญ 0.05 ในกรณีที่ขนาดตัวอย่าง ( $n$ ) มีค่ามาก คือ  $|r_{k,k}| > \frac{t_{\alpha/2; df}}{n}$

(4) สรุปผลการทดสอบ ซึ่งหากปฏิเสธสมมติฐานว่างสามารถสรุปได้ว่าพารามิเตอร์มีค่าไม่เท่ากับศูนย์ ควรรวมพารามิเตอร์ตัวนั้นในแบบจำลอง

2) พิจารณาค่าประมาณความคลาดเคลื่อนที่คำนวณได้จากสมการพยากรณ์

(1) พิจารณากราฟความสัมพันธ์ระหว่างความคลาดเคลื่อนกับเวลา หากค่าประมาณความคลาดเคลื่อนมีการกระจายไม่คงที่ แต่มีค่าเปลี่ยนแปลงตามเวลาแสดงว่าค่าความคลาดเคลื่อนมีความแปรปรวนไม่คงที่และข้อมูลอนุกรมเวลาที่มีความแปรปรวนไม่คงที่

(2) เปรียบเทียบกับกราฟ ACF และ PACF ทางทฤษฎีของค่าประมาณความคลาดเคลื่อน ถ้าแบบจำลองมีลักษณะเป็น White Noise แสดงว่าแบบจำลองที่ได้เป็นแบบจำลองที่เหมาะสม

(3) การทดสอบสหสัมพันธ์ในตนเองของค่าประมาณความคลาด

เคลื่อน Box และ Pierce ได้เสนอตัวสถิติทดสอบ  $Q = n \sum_{k=1}^K r_k^2(\hat{\epsilon})$

โดย  $n$  = จำนวนข้อมูลของค่าความคลาดเคลื่อนของค่าสังเกตอนุกรมเวลาหลังจากปรับให้เป็นอนุกรมเวลาคงที่แล้ว  $K$  = จำนวนสหสัมพันธ์ในตัวเองของค่าประมาณความคลาดเคลื่อนที่ใช้ในการคำนวณค่า  $Q$  และ  $r_k(\hat{\epsilon})$  = ฟังก์ชันสหสัมพันธ์ในตัวเองของค่าประมาณความคลาดเคลื่อน โดยตัวสถิตินี้ที่มีการแจกแจงไคสแควร์มีค่าองศาอิสระ (degree of freedom) เท่ากับจำนวนสหสัมพันธ์ในตัวเองจากตัวอย่าง (sample autocorrelation) ของค่าความคลาดเคลื่อน  $K$  ตัวที่ใช้ในการทดสอบลบจำนวนพารามิเตอร์ ( $m$ ) ในแบบจำลองที่ประมาณค่า

(4) การทดสอบว่าค่าความคลาดเคลื่อนเป็นอิสระต่อกันหรือไม่ มีขั้นตอนการทดสอบดังนี้

- ตั้งสมมติฐานในการทดสอบ

$$H_0 : \rho_k = 0 \quad \text{ทุก ๆ ค่า } k \leq K$$

$$H_1 : \rho_k \neq 0 \quad \text{อย่างน้อย 1 ค่าที่ } k \leq K$$

- ตัวสถิติทดสอบ  $t = n \sum_{k=1}^K r_k^2(\hat{\epsilon})$

- เกณฑ์ที่ใช้ในการปฏิเสธ  $H_0$  จากการใช้ระดับนัยสำคัญ 0.05 คือ  $Q > \chi_{\alpha, k-m}^2$



- หากผลการทดสอบปฏิบัติเหมาะสมมาตรฐานหลักแสดงว่าความคลาดเคลื่อนยังสหสัมพันธ์กันจึงต้องปรับปรุงแบบจำลองใหม่ แต่หากผลการทดสอบยอมรับสมมติฐานว่างแสดงว่าแบบจำลองที่ได้เป็นแบบจำลองที่เหมาะสม

## 2.2 วิธีปรับให้เรียบเอกซ์โพเนนเชียล (Exponential Smoothing)

เป็นวิธีที่ใช้ในการปรับข้อมูลให้เรียบและใช้ประมาณอนุกรมเวลาโดยไม่จำเป็นต้องประมาณค่าพารามิเตอร์ ในการประมาณจะเป็นการแทนค่าซ้ำขั้นตอนเดิม ซึ่งค่าพยากรณ์จะถูกปรับค่าเมื่อมีค่าสังเกตใหม่ โดยมีการกำหนดค่าปรับให้เรียบ  $\alpha$  (Smoothing Factor) ซึ่งทำให้ค่าเฉลี่ยของความคลาดเคลื่อนกำลังสอง (Average Square Residual) ของการประมาณโดยใช้ค่าสังเกตก่อนหน้าคาบเวลา  $t$  หนึ่งคาบ มีค่าน้อยที่สุด แบ่งเป็น 3 วิธี ดังนี้

(1) วิธีปรับให้เรียบเอกซ์โพเนนเชียลอย่างง่าย (Simple Exponential Smoothing) วิธีนี้เหมาะสำหรับข้อมูลที่ไม่มีแนวโน้มและไม่มีอิทธิพลของฤดูกาล ซึ่งข้อมูลมีลักษณะการเคลื่อนไหวที่ค่อนข้างคงที่ ซึ่งมีสมการดังนี้

$$F_{t+1} = \alpha Y_t + (1 - \alpha)F_t \quad \dots\dots\dots(2.10)$$

โดย  $Y_t$  เป็นข้อมูล ณ คาบเวลา  $t$

$F_{t+1}$  เป็นค่าพยากรณ์ที่ต้องการทราบล่วงหน้า ณ คาบเวลา  $t+1$

$\alpha$  เป็นค่าคงที่ซึ่งใช้ในการปรับค่าพยากรณ์



วิธีปรับให้เรียบเอกซ์โพเนนเชียลอย่างง่ายเป็นกระบวนการสำหรับการทบทวนการพยากรณ์อย่างต่อเนื่อง ค่าคงที่ซึ่งใช้ในการปรับค่าพยากรณ์ (Smoothing constant) ใช้ในการให้น้ำหนักแก่ปัจจัย ค่าที่แท้จริงของ  $\alpha$  จะกำหนดค่าสังเกตในปัจจุบันซึ่งจะมีอิทธิพลในการพยากรณ์อนาคต ถ้าค่า  $\alpha$  เข้าใกล้ 1 การพยากรณ์ใหม่จะรวมกันปรับเปลี่ยน สำหรับความผิดพลาดที่เกิดจากการพยากรณ์ที่ผ่านมา ในทางตรงกันข้าม ถ้าค่า  $\alpha$  เข้าไปใกล้ศูนย์ ค่าพยากรณ์ใหม่จะคล้ายคลึงกับค่าพยากรณ์เก่า

### (2) วิธีปรับให้เรียบแบบโฮลท์ (Holt's linear method)

Holt (1957) ได้ปรับปรุงวิธีปรับให้เรียบเอกซ์โพเนนเชียลอย่างง่าย ให้เป็นวิธีปรับให้เรียบในเชิงเส้นตรง (Linear Smoothing Method) สำหรับการพยากรณ์ข้อมูลที่มีลักษณะเป็นแนวโน้มเชิงเส้น (trend) ซึ่งเป็นเทคนิคที่ให้ความสำคัญกับข้อมูลล่าสุดมากที่สุด ดังนั้นจึงมีค่าคงที่ที่ทำให้เรียบ 2 ค่าคือ  $\alpha$  และ  $\beta$  จึงอาจเรียกว่า วิธีปรับให้เรียบเอกซ์โพเนนเชียลกำลังสอง (Double Exponential Smoothing Method) ซึ่งมีสมการดังนี้

$$L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad \dots\dots\dots(2.11)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad \dots\dots\dots(2.12)$$

$$F_{t+m} = L_t + b_t m \quad \dots\dots\dots(2.13)$$

โดย  $Y_t$  เป็นข้อมูล ณ คาบเวลา  $t$

$F_{t+1}$  เป็นค่าพยากรณ์ที่ต้องการทราบล่วงหน้า ณ คาบเวลา  $t+1$

$\alpha$  เป็นค่าคงที่ซึ่งใช้ในการปรับค่าพยากรณ์

$\beta$  เป็นค่าที่ทำให้เรียบระหว่างค่าแนวโน้มจริงกับค่าประมาณของแนวโน้ม  
ค่า  $\alpha$  และ  $\beta$  จะมีค่าอยู่ระหว่าง 0-1 ในกรณีที่  $\alpha = \beta$  จะเรียกว่า "Brown's Double Exponential Smoothing"

$L$  เป็นค่าประมาณ level ของอนุกรมที่เวลา  $t$

$b$  เป็นค่าประมาณความชันของอนุกรมที่เวลา  $t$

$m$  เป็นจำนวนของคาบที่ต้องการพยากรณ์ล่วงหน้า

ซึ่งเทคนิคของโฮลท์ จะปรับระดับความลาดชันโดยตรงด้วยการใช้ค่าปรับคงที่ (smoothing constant) ของแต่ละช่วงเวลาต่างกัน ค่าปรับคงที่เหล่านี้จะประมาณการระดับ และความลาดชันตลอดเวลาเมื่อมีค่าสังเกตใหม่ ดังนั้นจุดเด่นของวิธีนี้คือ มีความคล่องตัวในการเลือกอัตราระดับและแนวโน้ม

(3) วิธีปรับให้เรียบแบบโฮลท์วินเตอร์ (Holt-Winters'trend and seasonality method) ได้ถูกพัฒนาขึ้นจากวิธี Holt's linear method โดย Winters (1960) เป็นวิธีที่เหมาะสมกับข้อมูลที่มีแนวโน้ม (trend) และอิทธิพลของฤดูกาล (seasonality) เข้ามาเกี่ยวข้อง จึงเหมาะสมกับระยะสั้นและระยะปานกลางดังนี้

$$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1-\alpha)[L_{t-1} + b_{t-1}] \quad \dots\dots\dots(2.14)$$

$$b_t = \beta(L_t - L_{t-1}) + (1-\beta)b_{t-1} \quad \dots\dots\dots(2.15)$$

$$S_t = \gamma \frac{Y_t}{L_t} + (1-\gamma)S_{t-s} \quad \dots\dots\dots(2.16)$$

$$\hat{Y}_{t+m} = (L_t + b_t m)S_{t-s+m} \quad \dots\dots\dots(2.17)$$

โดย  $\gamma$  เป็นค่าประมาณของฤดูกาลจริงกับค่าประมาณแนวโน้ม จะมีค่าอยู่ระหว่าง 0 - 1

$L$  เป็นค่าประมาณ level ของอนุกรม ที่เวลา  $t$

$b$  เป็นค่าประมาณของความชันของอนุกรม ที่เวลา  $t$

$S$  ส่วนประกอบของฤดูกาล

$s$  คาบเวลาของฤดูกาล

$Y_t$  เป็นค่าสังเกตใหม่หรือค่าที่แท้จริงในช่วงเวลา  $t$

$\beta$  เป็นค่าปรับคงที่สำหรับการประมาณแนวโน้ม ( $0 \leq \beta \leq 1$ )

การปรับอนุกรมให้เรียบในช่วงเวลาปัจจุบัน (Update) ด้วย  $L_t$  จะทำให้  $L_t$  ที่ได้แตกต่างจากค่า  $L_t$  ในแบบจำลองของโฮลท์ นอกจากนั้น การที่ค่า  $Y_t/S_{t-s}$  เป็นปรับฤดูกาลออกจากข้อมูล  $Y_t$  หลังจากการปรับประมาณการแนวโน้ม ( $b_t$ ) และการประมาณฤดูกาล ( $S_t$ )

แล้ว จึงทำการพยากรณ์หาค่า  $\hat{Y}_{t+m}$  โดยช่วงเวลาในอดีต คือ  $t+m$  จะต้องคูณด้วย  $S_{t-s+m}$  หรือ ดัชนีฤดูกาล (seasonal index) เพื่อนำไปปรับการพยากรณ์ที่มีฤดูกาล สำหรับแบบจำลองของ Winters จะใช้ค่า  $\alpha, \beta$  และ  $\gamma$  เป็นค่าคงที่ในการปรับเรียบ เพื่อลดค่าความคลาดเคลื่อนจากการพยากรณ์ให้ต่ำที่สุด มีขั้นตอนดังนี้

#### ขั้นตอนแรก

การคำนวณเริ่มจากการปรับให้ค่าประมาณลำดับที่หนึ่งที่ได้ปรับเรียบแล้ว ให้มีค่าเท่ากับค่าสังเกตลำดับที่หนึ่ง ( $L_t = Y_t$ ) ซึ่งจะประมาณการได้ว่าแนวโน้มจะเป็นศูนย์ ( $b=0$ ) และ ดัชนีฤดูกาลเท่ากับหนึ่ง ( $S_t = 1.0$ )

#### ขั้นตอนที่สอง

นำค่าเฉลี่ยของฤดูกาลลำดับที่หนึ่งหรือค่าสังเกต  $s$  ครั้ง (ช่วงความยาวของฤดูกาล) เพื่อใช้เป็นค่าปรับเรียบขั้นต้น เส้นแนวโน้มจะประมาณการความลาดชัน (slope) ที่เหมาะสมกับค่าสังเกต (observation) ดัชนีฤดูกาลคือ  $S_t = \frac{Y_t}{L_s}$

การวิเคราะห์อนุกรมเวลาในกรณีที่ตัวแปรหนึ่งตัว วิธีปรับให้เรียบเอกซ์โพเนนเชียลอย่างง่ายเป็นวิธีที่ใช้กับข้อมูลอนุกรมเวลาที่ไม่ได้มีแนวโน้มและไม่มีฤดูกาล มีลักษณะการเปลี่ยนแปลงช้าๆ หรือมีลักษณะค่อนข้างคงที่ ส่วนวิธีปรับให้เรียบเอกซ์โพเนนเชียลกำลังสองเหมาะที่จะใช้กับอนุกรมเวลาที่มีแนวโน้ม ไม่มีฤดูกาล ซึ่งแนวโน้มอาจมีลักษณะความชันไม่คงที่ วิธีการ์ตเนอร์และวิธีแมคเคนซีเหมาะที่จะใช้กับข้อมูลอนุกรมเวลาที่มีแนวโน้มซึ่งมีลักษณะไม่เพิ่มในอัตราคงที่ตลอดมีความหน่วงในช่วงปลายไม่มีฤดูกาล ส่วนวิธีโฮลท์วินเตอร์เหมาะที่จะใช้กับอนุกรมเวลาที่มีฤดูกาลและมี/ไม่มีแนวโน้ม

### 2.3 เกณฑ์การพิจารณาตัวแบบพยากรณ์ที่เหมาะสม

ในการพิจารณาแบบจำลองที่เหมาะสมในการพยากรณ์นั้น อาจพิจารณาจากความแตกต่างระหว่างค่าที่แท้จริงกับค่าพยากรณ์ซึ่งเรียกว่าค่าความคลาดเคลื่อน (residuals) สามารถเขียนเป็นสมการได้ดังนี้  $\hat{\epsilon}_t = Y_t - \hat{Y}_t$  โดย  $\hat{\epsilon}_t$  = ความคลาดเคลื่อนจากการพยากรณ์ ในช่วงเวลา  $t$   $Y_t$  = ค่าของข้อมูลในช่วงเวลา  $t$  และ  $\hat{Y}_t$  = ค่าที่พยากรณ์ในช่วงเวลา  $t$

- 1) ค่าความคลาดเคลื่อนที่แท้จริงเฉลี่ย (Mean Absolute Deviation :MAD)

$$MAD = \frac{1}{n} \sum_{i=1}^n |Y_t - \hat{Y}_t|$$

ใช้วัดความแม่นยำของค่าพยากรณ์โดยการเฉลี่ยค่าความผิดพลาดของ

ค่าพยากรณ์ซึ่งจะมีประโยชน์มากสำหรับการวิเคราะห์ที่ต้องการวัดความผิดพลาดในหน่วยเดียวกันกับข้อมูลอนุกรมเวลาเดิม

- 2) ค่ารากที่สองของความคลาดเคลื่อนเฉลี่ยกำลังสอง (Root Mean Square

Error : RMSE)  $RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_t - \hat{Y}_t)^2}$

3) ค่าเฉลี่ยของเปอร์เซ็นต์ความคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Percent

Error : MAPE) 
$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right|$$

ในการเลือกตัวแบบพยากรณ์ที่เหมาะสมจะเลือกตัวแบบที่ให้ค่าความคลาดเคลื่อนมีค่าน้อยที่สุด