

บทที่ 2




ระเบียบวิธีการทางสถิติที่ใช้ในการวิจัย

ค่าของข้อมูลที่เกิดขึ้นในระยะเวลาต่าง ๆ กัน ซึ่งได้รับการจัดเรียงลำดับโดย
 9 คำนี้ถึงเวลาแห่งการเกิดขึ้นหรือปรากฏนั้นเป็นเกณฑ์ โดยจุดบอกเวลาจะอยู่ห่างจากกัน
 แต่ละคู่เป็นระยะเท่า ๆ กัน เช่น ยอดขายสินค้าเป็นรายเดือน ข้อมูลนี้เรียกว่าข้อมูล
 อนุกรมเวลา (Time Series) ซึ่งแบ่งออกได้เป็น 3 ประเภท คือ


1. อนุกรมเวลาคงที่ (Stationary Time Series) ข้อมูลจะเคลื่อนไหวไป
 รอบ ๆ ค่าเฉลี่ย (Mean) และการเคลื่อนไหวจะเป็นไปในลักษณะคงที่ พอกำหนดเพิ่มขึ้น
 ค่าที่ตามมาจะลดลงดังรูปที่ 2.1

2. อนุกรมเวลาไม่คงที่ (Non Stationary Time Series) ข้อมูลจะ
 เคลื่อนไหวไม่แน่นอน และจะไม่สามารถหาค่าเฉลี่ยที่เป็นศูนย์กลางได้ดังรูปที่ 2.2

3. อนุกรมเวลาฤดูกาล (Seasonal Time Series) ข้อมูลจะมีการเคลื่อนไหว
 ขึ้นลงตามระยะเวลาเป็นช่วงที่แน่นอน และลักษณะการเคลื่อนไหวในระยะเวลานึงจะคล้าย
 หรือเหมือนกันกับช่วงเวลาอื่น ๆ ซ้ำ ๆ กัน ดังรูปที่ 2.3



รูปที่ 2.1 ลักษณะของอนุกรมเวลาคงที่



รูปที่ 2.2 ลักษณะของอนุกรมเวลาไม่คงที่



รูปที่ 2.3 ลักษณะของอนุกรมเวลาฤดูกาล

ในการวิเคราะห์อนุกรมเวลา (Time Series Analysis) แบ่งเป็น 2 ส่วนใหญ่ คือ การวิเคราะห์หารูปแบบ (Models) ที่เหมาะสมกับข้อมูลในอดีต เพื่อนำมาใช้คาดคะเนค่าในอนาคต (Forecast - Values) อันเป็นจุดประสงค์แรกและสำคัญในการวิเคราะห์ทางสถิติ ในการวิจัยนี้จะได้นำวิธีการของบ็อกซ์และเจนกินส์ และวิธีการของ Classical Time Series มาใช้ ในส่วนแรกนี้จะกล่าวถึงขั้นตอนในการวิเคราะห์โดยวิธีการของ บ็อกซ์และเจนกินส์

ขั้นตอนการวิเคราะห์ส่วนที่ 1 เป็นการเลือกรูปแบบที่เหมาะสม

ขั้นที่ 1 การกำหนดรูปแบบ (Model Identification)

ขั้นที่ 2 การประมาณค่าพารามิเตอร์ (Parameter Estimation)

ขั้นที่ 3 การทดสอบความเหมาะสมของรูปแบบ (Model Diagnostic Checking)

ส่วนที่ 2 จะเป็นการนำรูปแบบที่เหมาะสมนั้นมาหาค่าค่าคงที่เมื่อนอนาคต่อไป

2.1 การกำหนดรูปแบบ

เป็นวิธีการขั้นแรกในการวิเคราะห์ รูปแบบที่จะนำมาพิจารณาว่ามีความเหมาะสมกับอนุกรมเวลาแต่ละชุดนั้นมีเป็นจำนวนมากแบ่งเป็น 3 ประเภทใหญ่ ๆ คือ Autoregressive Models, Moving Average Models และ Autoregressive - Moving Average Models ใช้สัญลักษณ์แทนรูปแบบ คือ ARIMA

อนุกรมเวลาคงที่

Autoregressive Model อันดับที่ P ใช้สัญลักษณ์ AR (P)

$$\dot{Y}_t = \phi_1 \dot{Y}_{t-1} + \phi_2 \dot{Y}_{t-2} + \dots + \phi_p \dot{Y}_{t-p} + e_t$$

โดยที่ $\dot{Y}_t = Y_t - \mu$

Moving Average Model อันดับที่ q ใช้สัญลักษณ์ MA (q)

$$\dot{Y}_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q}$$

Autoregressive - Moving Average Model อันดับที่ p และ q

ใช้สัญลักษณ์ ARMA (p,q)

$$\dot{Y}_t - \phi_1 \dot{Y}_{t-1} - \dots - \phi_p \dot{Y}_{t-p} = e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q}$$

ถ้าเป็นอนุกรมเวลาไม่คงที่ จะต้องทำให้เป็นอนุกรมเวลาคงที่โดยการหาผลต่าง

(Differencing) ดังนี้

ผลต่างครั้งที่ 1 : $D^1 Y_t = DY_t = Y_t - Y_{t-1}$

$$\begin{aligned} \text{ผลต่างครั้งที่ 2} : \quad D^2 Y_t &= D(DY_t) = D(Y_t - Y_{t-1}) = DY_t - DY_{t-1} \\ &= Y_t - 2Y_{t-1} + Y_{t-2} \end{aligned}$$

$$\text{ผลต่างครั้งที่ 3} : \quad D^3 Y_t = D(D^2 Y_t) = Y_t - 3Y_{t-1} + 3Y_{t-2} - Y_{t-3}$$

$$\begin{aligned} \text{ผลต่างครั้งที่ } d : \quad D^d Y_t &= \binom{d}{0} Y_t - \binom{d}{1} Y_{t-1} + \binom{d}{2} Y_{t-2} - \dots \\ &\quad + \binom{d}{d} Y_{t-d} \end{aligned}$$

เมื่อได้ผลต่างแต่ละครั้งตั้งแต่ครั้งที่ 1, 2, ..., d จะต้องพิจารณาว่าอนุกรมนั้นเป็นชนิดคงที่หรือยัง ถ้าเป็นก็จะหยุดเพียงนั้น รูปแบบสำหรับอนุกรมเวลาไม่คงที่ก็จะเป็นลักษณะเดียวกับอนุกรมเวลาคงที่แล้วใช้สัญลักษณ์ W_t แทน \dot{Y}_t โดย $W_t = Y_t - Y_{t-1}$ สัญลักษณ์แทนรูปแบบ คือ ARIMA (p, d, q)

ในการวิจัยนี้จะนำรูปแบบมาใช้พิจารณาเพียงระดับที่ $p = 2$, $q = 2$ ส่วน d นั้นในทางปฏิบัติจริง ๆ คงจะไม่เกินครั้งที่ 2 อนุกรมเวลาไม่คงที่จะเป็นชนิดคงที่ได้ ลักษณะของรูปแบบจะเป็นดังนี้

2.1.1 ARIMA (1,0,0) หรือ AR (1)

$$\text{รูปแบบคือ } \dot{Y}_t = \phi_1 \dot{Y}_{t-1} + e_t \quad \text{โดยที่ } \dot{Y}_t = Y_t - \mu, \quad |\phi_1| < 1$$

$$t = 1, 2, \dots, N$$

เมื่อ Y_t คือข้อมูลอนุกรมเวลาที่ต้องการศึกษา ณ เวลา t
 μ, ϕ_1 เป็นพารามิเตอร์ของรูปแบบ
 e_t คือค่าความคลาดเคลื่อนของความสัมพันธ์ระหว่างข้อมูล Y_t และ Y_{t-1}
 หรือเรียกว่า "Shock"

2.1.2 ARIMA (2,0,0) หรือ AR (2)

รูปแบบคือ $\hat{Y}_t = \phi_1 \hat{Y}_{t-1} + \phi_2 \hat{Y}_{t-2} + e_t$ โดยที่ $\phi_2 + \phi_1 < 1$
 $\phi_2 - \phi_1 < 1$
 $-1 < \phi_2 < 1$

2.1.3 ARIMA (0,0,1) หรือ MA (1)

รูปแบบคือ $\hat{Y}_t = e_t - \theta_1 e_{t-1}$ โดยที่ $|\theta_1| < 1$

เมื่อ θ_1 คือค่าพารามิเตอร์แสดง proportion ของ e_{t-1} ที่มีต่อ \hat{Y}_t

e_t คือ current shock

e_{t-1} คือ previous shock

2.1.4 ARIMA (0,0,2) หรือ MA (2)

รูปแบบคือ $\hat{Y}_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2}$ โดยที่ $\theta_2 + \theta_1 < 1$
 $\theta_2 - \theta_1 < 1$
 $-1 < \theta_2 < 1$

2.1.5 ARIMA (1,0,1) หรือ ARMA (1,1)

รูปแบบคือ $\hat{Y}_t - \phi_1 \hat{Y}_{t-1} = e_t - \theta_1 e_{t-1}$ โดยที่ $|\phi_1| < 1, |\theta_1| < 1$

2.1.6 ARIMA (1,1,0) หรือ ARI (1,1)

รูปแบบคือ $w_t = \phi_1 w_{t-1} - e_t$ โดยที่ $w_t = Y_t - Y_{t-1}, |\phi_1| < 1$

2.1.7 ARIMA (2,1,0) หรือ ARI (2,1)

รูปแบบคือ $W_t = \phi_1 W_{t-1} + \phi_2 W_{t-2} - e_t$ โดยที่ $\phi_2 + \phi_1 < 1$
 $\phi_2 - \phi_1 < 1$
 $-1 < \phi_2 < 1$

2.1.8 ARIMA (0,1,1) หรือ IMA (1,1)

รูปแบบคือ $W_t = e_t - \theta_1 e_{t-1}$ โดยที่ $|\theta_1| < 1$

2.1.9 ARIMA (0,1,2) หรือ IMA (1,2)

รูปแบบคือ $W_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2}$ โดยที่ $\theta_2 + \theta_1 < 1$
 $\theta_2 - \theta_1 < 1$
 $-1 < \theta_2 < 1$

2.1.10 ARIMA (1,1,1)

รูปแบบคือ $W_t - \phi_1 W_{t-1} = e_t - \theta_1 e_{t-1}$ โดยที่ $|\phi_1| < 1, |\theta_1| < 1$

2.1.11 ARIMA (0,1,0) หรือ Random Walk Process

รูปแบบคือ $Y_t - Y_{t-1} = e_t$

ทั้งนี้แต่ละรูปแบบอยู่ภายใต้ข้อสมมติดังนี้

1. $E(e_t) = 0$, Variance $(e_t) = \sigma_e^2$ ทุกค่าของ t
2. $E(e_t e_{t'}) = 0$ สำหรับ $t \neq t'$
3. $E(e_t Y_{t'}) = 0$ สำหรับ $t' < t$

ค่าสถิติที่จะคำนวณเพื่อใช้ในการเลือกรูปแบบก็คือ ค่าสัมประสิทธิ์ออโตคอร์เรเลชันของ ตัวอย่าง (Sample Autocorrelation coefficient - r_k) มีสูตรดังนี้

$$2.1.12 \quad r_k = \frac{\frac{1}{N-k} \sum_{t=1}^{N-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\frac{1}{N} \sum_{t=1}^N (Y_t - \bar{Y})^2}$$

$$= \frac{\sum_{t=1}^{N-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})}{\sum_{t=1}^N (Y_t - \bar{Y})^2}$$

โดยที่ Y_t คือข้อมูลอนุกรมเวลา Y_1, Y_2, \dots, Y_N

$$\bar{Y} = \frac{1}{N} \sum_{t=1}^N Y_t$$

และ $k = 1, 2, \dots, K$ (นิยมให้ $K < N/4$)






ในการวิเคราะห์การถดถอย (Regression Analysis)

ของตัวอย่าง (Sample Correlation coefficient) เพื่อดูความสัมพันธ์ของข้อมูล อย่างน้อย 2 ชุดขึ้นไป เช่น ข้อมูล X กับข้อมูล Y แต่สำหรับ r_k ดังสมการ 2.1.12 จะเป็นการแสดงความสัมพันธ์เชิงเส้นตรงของข้อมูลแต่ละคู่ภายในอนุกรมเวลาชุดเดียวกัน คือ ระหว่าง Y_t กับ Y_{t+k} โดย $t = 1, 2, \dots, N-k$ เมื่อ $k = 1, 2, \dots, K$ ซึ่งในการคำนวณค่า r_k นี้จะสะดวกเร็วและถูกต้องโดยใช้เครื่องคอมพิวเตอร์ จากค่า r_k นี้นำไปพิจารณาว่า อนุกรมเวลานั้น ๆ เป็นอนุกรมเวลาคงที่หรือไม่ โดยถ้าอนุกรมเวลาคงที่ค่า r_k จะเปลี่ยนแปลงอย่างรวดเร็วเมื่อ $k = 1, 2, \dots, K$ หากค่า r_k มีการเปลี่ยนแปลงที่ละน้อย แสดงว่าเป็นอนุกรมเวลาไม่คงที่ ต้องทำให้เป็นอนุกรมเวลาคงที่โดยการหาผลต่าง

(ดังกล่าวข้างต้น) แล้วคำนวณหาค่า r_k และพิจารณาเช่นเดียวกัน ทำจนกว่าจะได้เป็นอนุกรมเวลาคงที่ นำค่า r_k นี้ไปสร้างกราฟโดยให้ $k ; k = 1, 2, \dots, K$ เป็นแกนแนวนอน ให้ค่า r_k เป็นแกนตั้ง เพื่อนำไปเปรียบเทียบกับกราฟของค่าสัมประสิทธิ์ออโตคอร์เรเลชัน (Theoretical Autocorrelation Coefficient; ρ_k) ทั้ง 5 แบบ ดังรูปที่ 2.4 ว่าสอดคล้องกับแบบใด ซึ่งอาจจะสอดคล้องมากกว่า 1 แบบก็ได้ แสดงว่ารูปแบบที่จะเลือกใช้ได้มีมากกว่า 1 รูปแบบ แต่อย่างไรก็ตามจะต้องคำนึงถึงความสะดวกของรูปแบบนั้นด้วย ถ้ามีความเหมาะสมพอ ๆ กัน ก็ควรจะเลือกใช้รูปแบบที่มีจำนวนพารามิเตอร์น้อยที่สุดเพื่อสะดวกและถูกต้องในการคำนวณต่อไป

004591

ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย



แสดงลักษณะ fnc. ของ $\rho_k; (k \geq 0)$ ของอนุกรมเวลาคงที่

สัมประสิทธิ์ออโตคอร์เรเลชัน (Theoretical Autocorrelation Coefficient)

สัญลักษณ์ คือ ρ_k นี้ในทางปฏิบัติไม่สามารถคำนวณหาค่าได้มีสูตรดังนี้

$$2.1.13 \quad \rho_k = \frac{\text{Cov}(Y_t, Y_{t+k})}{\sqrt{\text{Var}(Y_t) \text{Var}(Y_{t+k})}} = \frac{\gamma_k}{\sqrt{\gamma_0^2}} = \frac{\gamma_k}{\gamma_0} \quad \text{ทุก ๆ ค่าของ } t$$

ฉะนั้นจะได้ใช้ค่า r_k เป็นค่าประมาณของ ρ_k $\left. \vphantom{\rho_k} \right) = \hat{\rho}_k$

เมื่อพิจารณา r_k เปรียบเทียบกับ ρ_k ในรูปที่ 2.4 เมื่อ $k = 1, 2, \dots, K$ เลือกรูปแบบที่เหมาะสมในขั้นต้นได้ จากรูปแบบนี้เราสามารถหาค่าประมาณเบื้องต้นของ พารามิเตอร์ (Initial Parameters Estimation) ทั้งนี้โดยอาศัยความสัมพันธ์ระหว่าง ρ_k กับพารามิเตอร์ของแต่ละรูปแบบนั้น ๆ หรือเปิดตาราง A, B, C, D ซึ่งแสดงค่า ρ_k กับค่าพารามิเตอร์ของรูปแบบ MA(1), AR(2), MA(2) และ ARMA(1,1) ตามลำดับ ทั้งนี้จะใช้ค่า r_k แทนค่า ρ_k จากสมการ 2.1.13 ใช้หาค่าความสัมพันธ์ระหว่าง ρ_k และพารามิเตอร์ของแต่ละรูปแบบในอนุกรมเวลาคงที่ได้ดังนี้

$$\text{AR}(1) : \dot{Y}_t = \phi_1 \dot{Y}_{t-1} + e_t \quad \text{โดยที่ } \dot{Y}_t = Y_t - \mu, \quad |\phi_1| < 1$$

$$\begin{aligned} \gamma_0 &= E[\dot{Y}_t \dot{Y}_t] = E[\phi_1 \dot{Y}_{t-1} + e_t]^2 \\ &= E[\phi_1^2 \dot{Y}_{t-1}^2 + 2\phi_1 \dot{Y}_{t-1} e_t + e_t^2] \\ &= \phi_1^2 E[\dot{Y}_{t-1}^2] + 2\phi_1 E[\dot{Y}_{t-1} e_t] + E[e_t^2] \\ &= \phi_1^2 \gamma_0 + \sigma_e^2 \quad \text{โดยที่ } E[\dot{Y}_{t-1} e_t] = 0 \quad \text{จาก} \end{aligned}$$

สมมติฐานข้อที่ 3

² Part V : Collection of Tables and Charts หน้า 517 - 520

Box, G.E., P. and G.M. Jenkins, Time Series Analysis Forecasting and Control

$$\gamma_0(1-\phi_1^2) = \sigma_e^2$$

$$\gamma_0 = \sigma_e^2 / (1 - \phi_1^2)$$

$$\gamma_k = \gamma_{-k} = E[\dot{y}_t \dot{y}_{t-k}] \quad ; k \geq 1$$

$$= E[(\phi_1 \dot{y}_{t-1} + e_t) \dot{y}_{t-k}]$$

$$= E[\phi_1 \dot{y}_{t-1} \dot{y}_{t-k} + \dot{y}_{t-k} e_t]$$

$$= \phi_1 E[\dot{y}_{t-1} \dot{y}_{t-k}] + E[\dot{y}_{t-k} e_t]$$

$$\text{ถ้า } k=1; \gamma_1 = \gamma_{-1} = \phi_1 E[\dot{y}_{t-1} \dot{y}_{t-1}] + E[\dot{y}_{t-1} e_t]$$

$$= \phi_1 \gamma_0$$

$$= \phi_1 \sigma_e^2 / (1 - \phi_1^2)$$

$$k=2; \gamma_2 = \gamma_{-2} = \phi_1 E[\dot{y}_{t-1} \dot{y}_{t-2}] + E[\dot{y}_{t-2} e_t]$$

$$= \phi_1 E[\phi_1 \dot{y}_{t-2} + e_{t-1}] \dot{y}_{t-2}$$

$$= \phi_1 E[\phi_1 \dot{y}_{t-2} \dot{y}_{t-2}] + \phi_1 E[\dot{y}_{t-2} e_{t-1}]$$

$$= \phi_1^2 \gamma_0$$

$$\text{นั่นคือ } \gamma_k = \gamma_{-k} = \phi_1^k \gamma_0 \quad ; k \geq 1$$

$$\text{และ } \rho_k = \rho_{-k} = \frac{\gamma_k}{\gamma_0} = \phi_1^k \quad ; k \geq 1$$

ในทำนองเดียวกันจะได้ว่า

$$\text{AR (2) : } \rho_1 = \frac{\phi_1}{1-\phi_2}, \quad \rho_2 = \phi_2 + \frac{\phi_1^2}{1-\phi_2}$$

$$\text{และ } \rho_k = \phi_1 \rho_{k-1} + \phi_2 \rho_{k-2} \quad \text{เมื่อ } k \geq 3$$

$$\text{MA (1) : } \rho_1 = \frac{-e_1}{1 + e_1^2}$$

$$\text{และ } \rho_k = 0 \quad \text{เมื่อ } k > 1$$

$$\text{MA (2) : } \rho_1 = \frac{-e_1(1 - e_2)}{1 + e_1^2 + e_2^2}, \quad \rho_2 = \frac{-e_2}{1 + e_1^2 + e_2^2}$$

$$\text{และ } \rho_k = 0 \quad \text{เมื่อ } k > 2$$

$$\text{ARMA (1,1) : } \rho_k = \frac{(\phi_1 - e_1)(1 - \phi_1 e_1) \phi_1^{k-1}}{1 - 2\phi_1 e_1 + e_1^2} \quad \text{เมื่อ } k \geq 1$$

แทนค่า ρ_k ด้วยค่า r_k ลงในรูปแบบที่เหมาะสม คำนวณหาค่าประมาณเบื้องต้นของพารามิเตอร์ จะได้รูปแบบตามต้องการ ซึ่งจะได้นำไปหาค่าประมาณพารามิเตอร์ที่แน่นอนในขั้นที่ 2 ต่อไป

2.2 การประมาณค่าพารามิเตอร์

จากขั้นที่ 1 ในข้อ 2.1 จะได้รูปแบบที่เหมาะสมและค่าประมาณเบื้องต้นของพารามิเตอร์ ในขั้นนี้จะเป็นการหาค่าประมาณของพารามิเตอร์ที่ดีที่สุด ซึ่งในอนุกรมเวลา คือ ค่าประมาณกำลังสองน้อยที่สุด (Least Square Estimates) คำนวณโดยให้ได้ผลบวกกำลังสองของส่วนเบี่ยงเบนน้อยที่สุด (Minimize the Sum of Square Deviations) เพื่อจะได้รูปแบบที่เหมาะสมยิ่งขึ้น สำหรับใช้หาค่าคาดหมาย (Fitted Values)

จากรูปแบบทั่วไป ARIMA (p,d,q) ประกอบด้วยพารามิเตอร์จำนวน p+q+1 ตัว

คือ $\phi = (\phi_1, \phi_2, \dots, \phi_p)$, $\theta = (\theta_1, \theta_2, \dots, \theta_q)$ และ μ

นั่นคือ $S_N(\mu, \phi, \theta) = \sum_{t=1}^N [Y_t - E(Y_t | \text{previous Y's})]^2$

หรือ $\sum_{t=1}^N [w_t - E(w_t | \text{previous w's})]^2$

โดยที่ y_t คือ ข้อมูล ณ เวลา t ที่นำมาวิเคราะห์

$$E[y_t | \text{previous Y's}] = \hat{y}_t \text{ คือ ค่าคาดหมายของ } y_t \text{ ในเวลาที่ } t$$

จะเลือกค่าพารามิเตอร์ที่ให้ค่า $S(\mu, \phi, \theta)$ น้อยที่สุด เพราะถ้า $S(\mu, \phi, \theta)$ น้อยที่สุดแสดงว่า \hat{y}_t มีส่วนเบี่ยงเบนจาก y_t น้อยที่สุดในทุก ๆ เวลาที่ t การคำนวณหา $S(\mu, \phi, \theta)$ ที่น้อยที่สุดนี้ จะคำนวณโดยใช้เครื่องคอมพิวเตอร์ $S(\mu, \phi, \theta)$ แต่ละรูปแบบคือ

$$\text{AR (1)} : y_t - \mu = \phi_1(y_{t-1} - \mu) + e_t$$

$$y_t = \mu + \phi_1(y_{t-1} - \mu) + e_t$$

$$E[y_t | \text{previous Y's}] = E[y_t | y_{t-1}] = \mu + \phi_1(y_{t-1} - \mu) + E(e_t)$$

$$= \mu + \phi_1(y_{t-1} - \mu)$$

$$\text{จากสมมติฐานข้อ 1 } E(e_t) = 0$$

$$\therefore S(\mu, \phi_1) = \sum_{t=1}^N [y_t - \mu - \phi_1(y_{t-1} - \mu)]^2$$

$$= \sum_{t=2}^N [y_t - \mu - \phi_1(y_{t-1} - \mu)]^2$$

ทั้งนี้เพราะว่าเมื่อเริ่ม $t=1$ นั้น $y_{t-1} = y_0$ ซึ่งไม่มีค่าจริง

คำนวณหา $S(\mu, \phi_1)$ โดยแทนค่า $y_t, y_{t-1}, \mu, \phi_1$

$$\text{AR (2)} : S(\mu, \phi_1, \phi_2) = \sum_{t=3}^N [y_t - \mu - \phi_1(y_{t-1} - \mu) - \phi_2(y_{t-2} - \mu)]^2$$

$$\text{MA (1)} : S(\mu, \theta_1) = \sum_{t=2}^N [y_t - \mu + \theta_1 e_{t-1}]^2$$

$$\text{หรือ} = \sum_{t=2}^N e_t^2$$

$$\text{MA (2)} : S(\mu, \theta_1, \theta_2) = \sum_{t=3}^N [Y_t - \mu + \theta_1 e_{t-1} + \theta_2 e_{t-2}]^2$$

$$\text{หรือ} = \sum_{t=3}^N e_t^2$$

$$\text{ARMA (1,1)} : S(\mu, \phi_1, \theta_1) = \sum_{t=2}^N [Y_t - \mu - \phi_1(Y_{t-1} - \mu) + \theta_1 e_{t-1}]^2$$

$$\text{ARI (1,1)} : W_t = \phi_1 W_{t-1} + e_t$$

โดยที่ $W_t = Y_t - Y_{t-1}$ และ $t = 2, 3, \dots, N$

$$E[W_t | \text{previous } W\text{'s}] = E[W_t | W_{t-1}] = \phi_1 W_{t-1} + E(e_t)$$

$$= \phi_1 W_{t-1}$$

โดยข้อสมมติ $E(e_t) = 0$

$$S(\mu, \phi_1) = \sum_{t=2}^N [W_t - \phi_1 W_{t-1}]^2$$

$$\text{ARI (2,1)} : S(\mu, \phi_1, \phi_2) = \sum_{t=3}^N [W_t - \phi_1 W_{t-1} - \phi_2 W_{t-2}]^2$$

$$\text{IMA (1,1)} : S(\mu, \theta_1) = \sum_{t=2}^N [W_t + \theta_1 e_{t-1}]^2$$

$$\text{IMA (2,1)} : S(\mu, \theta_1, \theta_2) = \sum_{t=3}^N [W_t + \theta_1 e_{t-1} + \theta_2 e_{t-2}]^2$$

$$\text{ARIMA (1,1,1)} : S(\mu, \phi_1, \theta_1) = \sum_{t=2}^N [W_t - \phi_1 W_{t-1} + \theta_1 e_{t-1}]^2$$

เมื่อคำนวณได้ค่า $S(\mu, \phi, \theta)$ ที่น้อยที่สุดของอนุกรมเวลาแต่ละชุดแล้ว นำค่าพารามิเตอร์หรือค่าประมาณกำลังสองน้อยที่สุด $(\hat{\mu}, \hat{\phi}, \hat{\theta})$ ที่ได้นั้นไปแทนลงในรูปแบบนั้น ๆ ก็จะได้รูปแบบที่เหมาะสม (Fitted Model) ในขั้นต้น และจากรูปแบบนี้ก็นำไปหาค่าคาดหมายของ $Y_t; t=1, 2, \dots, N$ (Fitted values หรือ Estimated of Y_t) ใช้สัญลักษณ์ \hat{Y}_t การพิจารณาว่ารูปแบบเหมาะสมหรือไม่ อย่างคร่าว ๆ ในขั้นนี้ก็โดยการสร้างกราฟ



เปรียบเทียบระหว่าง Y_t (Observed Values) และ \hat{Y}_t (Fitted Values) ค่าทั้งสอง อยู่ในแถวที่ t ช่วงเวลา t ; $t=1,2,\dots,N$ เป็นแกนนอนจะได้นำค่าผลต่างระหว่าง Y_t และ \hat{Y}_t นี้ไปใช้ในการทดสอบความเหมาะสมของรูปแบบอย่างละเอียดต่อไปในขั้นที่ 3

2.3 การทดสอบความเหมาะสมของรูปแบบ

ในขั้นนี้จะเป็นการทดสอบว่ารูปแบบที่เลือกนั้นมีความถูกต้อง และเหมาะสมกับ ข้อมูลชุดนั้นหรือไม่ ถ้าหากว่าไม่จะต้องหาวิธีวิเคราะห์ว่า รูปแบบลักษณะไหนจึงจะนำมาใช้ได้ดีต่อไป ค่าสถิติที่จะใช้ในการทดสอบก็คือ ค่าความคลาดเคลื่อน (Residuals) สัญญลักษณ์ คือ \hat{e}_t ซึ่งเป็นผลต่างระหว่างค่าข้อมูลจริงกับค่าคาดหมาย เท่ากับ $Y_t - \hat{Y}_t$ จะได้จากขั้นที่ 2 โดยที่รูปแบบที่เหมาะสมจะต้องมีคุณลักษณะดังนี้

2.3.1 \hat{e}_t จะต้องไม่มีสหสัมพันธ์ต่อกัน (Uncorrelated) ทุกค่า lag k

$$\text{คือ } r_k(\hat{e}) = 0$$

2.3.2 \hat{e}_t จะมีการกระจายแบบปกติ (Normal Distribution) ด้วย

$$\text{ค่าเฉลี่ย (Mean) } = 0 \quad \text{ค่าแปรปรวน (Variance) } = \sigma_e^2$$

ทั้งนี้จะต้องทดสอบว่า $E(e_t) = 0$

$$E(e_t e_{t'}) = 0 ; t \neq t' \quad \text{หรือ } r_k(\hat{e}) = 0$$

2.3.3 การทดสอบ $E(\hat{e}_t) = \bar{\hat{e}}_t = 0$ โดยการเปรียบเทียบค่ามัธยฐานเลขคณิต

(Arithmetic Mean) และค่าประมาณของส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) ของ Residual นั้น ๆ

$$\text{ค่ามัธยฐานเลขคณิตของ Residual : } \bar{\hat{e}}_t = \frac{1}{N-1} \sum_{t=2}^N \hat{e}_t$$

ค่าประมาณของส่วนเบี่ยงเบนมาตรฐานของ Residual : $\hat{\sigma}_e$

$$\hat{\sigma}_e^2 = \frac{\sum_{t=1}^N (y_t - \hat{y}_t)^2}{N - a} = \frac{\sum_{t=1}^N \hat{e}_t^2}{N - a}$$

โดยที่ N คือจำนวนของ Residuals

a คือจำนวนของพารามิเตอร์ในรูปแบบนั้น ๆ

ทั้งนี้ ถ้า $\hat{\sigma}_e < \hat{\sigma}_e / \sqrt{N}$ แล้วแสดงว่า $E(e_t) = 0$

2.2.4 การทดสอบว่า $E(e_t e_{t'}) = 0$ $t \neq t'$ โดยการหาค่าสัมประสิทธิ์

ออโตคอร์เรลชัน ของ Residual มีสูตรในการคำนวณดังนี้

$$r_k(\hat{e}) = \frac{\sum_{t=1}^{N-k} \hat{e}_t \hat{e}_{t+k}}{\sum_{t=1}^N \hat{e}_t^2}$$

โดยที่ N คือ จำนวนของ Residuals และ $k = 1, 2, \dots, K$ (ตามกฎของ Thumb ให้ $K \leq \sqrt{N}$) และจากทฤษฎีว่าด้วยการกระจายของออโตคอร์เรลชันของ Residual ในรูปแบบ ARIMA ของ Box และ Pierce คือ

$$2.2.4.1 \quad E[r_k(\hat{e})] = 0$$

2.2.4.2 $\text{Var}[r_k(\hat{e})]$ ของแต่ละรูปแบบคือ

$$\text{AR}(1) \text{ และ } \text{ARI}(1,1) : \text{Var}[r_1(\hat{e})] \approx \frac{\sigma_1^2}{N}$$

$$\text{Var}[r_2(\hat{e})] \approx \frac{1 - \sigma_1^2 + \sigma_1^4}{N}$$

$$\text{Var}[r_k(\hat{e})] \approx \frac{1}{N} \quad \text{โดยที่ } k \geq 3$$

$$\text{AR (2) และ ARI (2,1)} : \text{Var} [r_1(\hat{e})] \approx \frac{\phi_2^2}{N}$$

$$\text{Var} [r_2(\hat{e})] \approx \frac{\phi_2^2 + \phi_1^2(1 + \phi_2)^2}{N}$$

$$\text{Var} [r_k(\hat{e})] \approx \frac{1}{N} \quad \text{โดยที่ } k \geq 3$$

$$\text{MA (1) และ IMA (1,1)} : \text{Var} [r_1(\hat{e})] \approx \frac{\theta_1^2}{N}$$

$$\text{Var} [r_2(\hat{e})] \approx \frac{1 - \theta_1^2 + \theta_1^4}{N}$$

$$\text{Var} [r_k(\hat{e})] \approx \frac{1}{N} \quad \text{โดยที่ } k \geq 3$$

$$\text{MA (2) และ IMA (1,2)} : \text{Var} [r_1(\hat{e})] \approx \frac{\theta_2^2}{N}$$

$$\text{Var} [r_2(\hat{e})] \approx \frac{\theta_2^2 + \theta_1^2(1 + \theta_2)^2}{N}$$

$$\text{Var} [r_k(\hat{e})] \approx \frac{1}{N} \quad \text{โดยที่ } k \geq 3$$

$$\text{ARMA (1,1) และ ARIMA (1,1,1)} : \text{Var} [r_1(\hat{e})] \approx \frac{\theta_1^2}{N}$$

$$\text{Var} [r_2(\hat{e})] \approx \frac{1 - \theta_1^2 + \theta_1^4}{N}$$

$$\text{Var} [r_k(\hat{e})] \approx \frac{1}{N} \quad \text{โดยที่ } k \geq 3$$

ดำเนินการทดสอบสมมติฐาน $H_0 : r_k(\hat{e}) = 0$ โดยการเปรียบเทียบค่า $r_k(\hat{e})$ กับค่าประมาณเบี่ยงเบนมาตรฐานของ $r_k(\hat{e})$ คือ $\hat{\sigma}_{r_k(\hat{e})}$ ซึ่งเท่ากับ $+\sqrt{\widehat{\text{var}}[r_k(\hat{e})]}$

ทั้งนี้จะยอมรับสมมติฐาน $H_0 : r_k(\hat{e}) = 0$ ถ้า $|r_k(\hat{e})| \leq Z_{\alpha/2} \hat{\sigma}_{r_k(\hat{e})}$ ทุก ๆ ค่า k ณ ระดับนัยสำคัญ α


นั่นคือถ้าได้ว่า $r_k(\hat{e}) = 0$ ก็แสดงว่า \hat{e}_t ไม่มีสหสัมพันธ์ต่อกันหรือ $E[e_t e_t'] = 0$

จากการทดสอบในข้อ 2.2.3 และ 2.2.4 ถ้าเป็นไปตามกฎเกณฑ์ดังกล่าวแล้ว รูปแบบที่เลือกใช้สำหรับข้อมูลอนุกรมเวลานั้น จะมีความเหมาะสมเพียงพอที่จะใช้ในการหาค่าคาดคะเนของข้อมูลในอนาคตได้ดี

ยังมีการทดสอบว่ารูปแบบที่เลือกมานั้นมีความเหมาะสมหรือไม่อีกวิธีหนึ่ง คือ การทดสอบโดยใช้ไค - สแควร์ : $\chi^2 = \text{Test}$ ซึ่งโดยวิธีนี้ \hat{e}_t ไม่จำเป็นต้องมีการกระจายแบบปกติ คำนวณหา χ^2 ได้ดังนี้

$$\chi^2 = N \sum_{k=1}^K r_k^2(\hat{e}) ; \text{Degree of Freedom} = K - a$$

ถ้ารูปที่เลือกได้นั้นมีความเหมาะสมกับข้อมูลแล้ว χ^2 จากการคำนวณจะน้อยกว่า $\chi^2_{(1-\alpha)}$ จากตารางสถิติโดยมี degree of freedom = $K - a$



2.4 การคาดคะเนค่าในอนาคตของอนุกรมเวลา

จะเป็นวิธีการหาค่าคาดคะเนในอนาคต โดยใช้รูปแบบที่เหมาะสมจากวิธีการข้างต้น และจาก Observed data ของข้อมูลอนุกรมเวลานั้น ๆ ค่าคาดคะเนที่จะคำนวณหา คือ Y_{N+l} โดยที่ l เรียกว่า Lead Time ซึ่ง $l = 1, 2, \dots, q$ และ Y_N จะเป็นค่าสุดท้ายของอนุกรมเวลา ซึ่งการคาดคะเนนี้จะใช้ช่วงเวลา $t = N$ เป็นจุดเริ่มต้นของการคาดคะเน (Forecast Origin) จะใช้สัญลักษณ์แทนค่าคาดคะเน Y_{N+l} คือ $E_N(Y_{N+l})$ หรือ $\hat{Y}_N(l)$ โดยที่ N จะแสดงว่าเป็นจุดเริ่มต้นของการคาดคะเน และ l ค่าในวงเล็บจะแสดงถึงช่วงเวลาที่เท่าใดของค่าคาดคะเน

$E_N(Y_{N+l})$ หรือ $\hat{Y}_N(l)$ จะเป็นค่าคาดคะเนที่ดีที่สุดของ Y_{N+l} ก็ต่อเมื่อค่าคาดหมาย ณ เวลาที่ N ของผลต่างกำลังสองของ $\hat{Y}_N(l)$ กับ Y_{N+l} [Expected (mean) Square Error] มีค่าน้อยมาก : $E_N[\hat{Y}_N(l) - Y_{N+l}]^2$

วิธีการหาค่าคาดคะเนที่ดีที่สุดสำหรับรูปแบบ ARIMA โดยทั่ว ๆ ไปดังนี้

2.4.1 หาค่า $\hat{Y}_N(l)$ ได้จากรูปแบบที่เหมาะสมที่เลือกใช้นั้น ๆ โดยที่ N คือจุดเริ่มต้นของการคาดคะเน (Forecast Origin) และ l คือ ช่วงเวลาที่ต้องการคาดคะเน (Lead Time)

2.4.2 การคาดหมาย ณ จุดเริ่มต้นของการคาดคะเนที่ N สำหรับเทอมของ Y และค่าความคลาดเคลื่อน สรุปได้ดังนี้

$$E_N(Y_{N+j}) = \begin{cases} Y_N(j) & \text{เมื่อ } j > 0 \quad (\text{เป็นค่าคาดคะเน}) \\ Y_{N+j} & \text{เมื่อ } j \leq 0 \quad (\text{ค่าจากการสังเกต}) \end{cases}$$

$$E_N(e_{N+j}) = \begin{cases} 0 & \text{เมื่อ } j > 0 \quad (\text{เพราะว่าไม่ทราบค่า}) \\ e_{N+j} & \text{เมื่อ } j \leq 0 \quad (\text{เป็นความคลาดเคลื่อนของ } Y_{N+j} - \hat{Y}_{N+j} \text{ เมื่อ } j \leq 0 \text{ เรียกว่า Observed Error}) \end{cases}$$

2.4.3 ค่าพารามิเตอร์จะได้จากการประมาณกำลังสองน้อยที่สุด คือ $\hat{\mu}$, $\hat{\phi}_1$, $\hat{\phi}_2$ และใช้ \hat{e}_{N+j} ; $j \leq 0$ เป็นค่าประมาณของ e_{N+j} คำนวณหา $\hat{Y}_N(l)$

ฉะนั้นการหาค่าคาดคะเน $\hat{Y}_N(l)$; $l = 1, 2, \dots, q$ ของแต่ละรูปแบบหาได้ดังนี้

$$\text{AR (1)} \quad : \quad \hat{Y}_t = \phi_1 \hat{Y}_{t+1} + e_t$$

$$\text{โดยที่ } \hat{Y}_t = Y_{t-\mu} \quad \text{และให้ } t = N + l$$

$$Y_{N+l} = \mu + \phi_1 (Y_{N+l-1} - \mu) + e_{N+l}$$

โดยการใช้ค่าคาดคะเน ณ จุดเริ่มต้นของการคาดคะเนที่ N

$$\begin{aligned} E_N(Y_{N+l}) &= E_N[\mu + \phi_1 (Y_{N+l-1} - \mu) + e_{N+l}] \\ &= \hat{\mu} + \hat{\phi}_1 E_N(Y_{N+l-1} - \mu) + E_N(e_{N+l}) \\ &= \hat{\mu} + \hat{\phi}_1 E_N(Y_{N+l-1} - \mu) \end{aligned}$$

โดยที่ $E_N(e_{N+l}) = 0$; $l > 0$ จาก 2.4.2

$$\text{เมื่อ } l = 1 : \quad \hat{Y}_N(1) = E_N(Y_{N+1}) = \hat{\mu} + \hat{\phi}_1 (Y_N - \hat{\mu});$$

Y_N เป็น observed value

$$\text{และ } l \geq 2 : \quad \hat{Y}_N(l) = E_N(Y_{N+l}) = \hat{\mu} + \hat{\phi}_1 [\hat{Y}_N(l-1) - \hat{\mu}];$$

$\hat{Y}_N(l-1)$ เป็นค่าคาดคะเนก่อนหน้า $\hat{Y}_N(l)$

ในทำนองเดียวกับรูปแบบอื่น ๆ จะได้ดังนี้

$$\begin{aligned} \text{AR (2)} : \quad \hat{Y}_N(1) &= \hat{\mu} + \hat{\phi}_1 [Y_N - \hat{\mu}] + \hat{\phi}_2 [Y_{N-1} - \hat{\mu}] \\ \hat{Y}_N(2) &= \hat{\mu} + \hat{\phi}_1 [\hat{Y}_N(1) - \hat{\mu}] + \hat{\phi}_2 [Y_N - \hat{\mu}] \end{aligned}$$

$$\text{และ } \hat{Y}_N(l) = \hat{\mu} + \hat{\phi}_1 [\hat{Y}_N(l-1) - \hat{\mu}] + \hat{\phi}_2 [\hat{Y}_N(l-2) - \hat{\mu}] \quad \text{เมื่อ } l \geq 3$$

$$\text{MA (1) : } \hat{Y}_N(1) = \hat{\mu}$$

$$\text{และ } \hat{Y}_N(l) = \hat{\mu} - \hat{\theta}_1 \hat{e}_N \quad \text{เมื่อ } l \geq 2$$

$$\text{MA (2) : } \hat{Y}_N(1) = \hat{\mu} - \hat{\theta}_1 \hat{e}_N - \hat{\theta}_2 \hat{e}_{N-1}$$

$$\hat{Y}_N(2) = \hat{\mu} - \hat{\theta}_2 \hat{e}_N$$

$$\text{และ } \hat{Y}_N(l) = \hat{\mu} \quad \text{เมื่อ } l \geq 3$$

$$\text{ARMA (1,1) : } \hat{Y}_N(1) = \hat{\mu} + \hat{\phi}_1 (Y_N - \hat{\mu}) - \hat{\theta}_1 \hat{e}_N$$

$$\text{และ } \hat{Y}_N(l) = \hat{\mu} + \hat{\phi}_1 [\hat{Y}_N(l-1) - \hat{\mu}] \quad \text{เมื่อ } l \geq 2$$

$$\text{ARI (1,1) : } \hat{Y}_N(1) = Y_N + \hat{\phi}_1 [Y_N - Y_{N-1}]$$

$$\hat{Y}_N(2) = \hat{Y}_N(1) + \hat{\phi}_1 [\hat{Y}_N(1) - Y_N]$$

$$\text{และ } \hat{Y}_N(l) = \hat{Y}_N(l-1) + \hat{\phi}_1 [\hat{Y}_N(l-1) - \hat{Y}_N(l-2)] \quad \text{เมื่อ } l \geq 3$$

$$\text{ARI (2,1) : } \hat{Y}_N(1) = Y_N + \hat{\phi}_1 [Y_N - Y_{N-1}] + \hat{\phi}_2 [Y_{N-1} - Y_{N-2}]$$

$$\text{หรือ } = (1 + \hat{\phi}_1) Y_N - (\hat{\phi}_1 - \hat{\phi}_2) Y_{N-1} - \hat{\phi}_2 Y_{N-2}$$

$$\hat{Y}_N(2) = \hat{Y}_N(1) + \hat{\phi}_1 [\hat{Y}_N(1) - Y_N] + \hat{\phi}_2 [Y_N - Y_{N-1}]$$

$$\text{หรือ } = (1 + \hat{\phi}_1) \hat{Y}_N(1) - (\hat{\phi}_1 - \hat{\phi}_2) Y_N - \hat{\phi}_2 Y_{N-1}$$

$$\hat{Y}_N(3) = \hat{Y}_N(2) + \hat{\phi}_1 [\hat{Y}_N(2) - \hat{Y}_N(1)] + \hat{\phi}_2 [\hat{Y}_N(1) - Y_N]$$

$$\text{หรือ} = (1 + \hat{\phi}_1) \hat{Y}_N(2) - (\hat{\phi}_1 - \hat{\phi}_2) \hat{Y}_N(1) - \hat{\phi}_2 Y_N$$

และ

$$\hat{Y}_N(l) = \hat{Y}_N(l-1) + \hat{\phi}_1 [\hat{Y}_N(l-1) - \hat{Y}_N(l-2)] + \hat{\phi}_2 [\hat{Y}_N(l-2) - \hat{Y}_N(l-3)] \quad \text{เมื่อ } l \geq 4$$

$$\text{หรือ} = (1 + \hat{\phi}_1) \hat{Y}_N(l-1) - (\hat{\phi}_1 - \hat{\phi}_2) \hat{Y}_N(l-2) - \hat{\phi}_2 \hat{Y}_N(l-3)$$

IMA (1,1) :

$$\hat{Y}_N(1) = Y_N - \hat{\theta}_1 \hat{e}_N$$

และ

$$\hat{Y}_N(l) = \hat{Y}_N(l-1) \quad \text{เมื่อ } l \geq 2$$

IMA (1,2) :

$$\hat{Y}_N(1) = Y_N - \hat{\theta}_1 \hat{e}_N - \hat{\theta}_2 \hat{e}_{N-1}$$

$$\hat{Y}_N(2) = \hat{Y}_N(1) - \hat{\theta}_2 \hat{e}_N$$

และ

$$Y_N(l) = Y_N(l-1) \quad \text{เมื่อ } l \geq 3$$

ARIMA (1,1,1) :

$$\hat{Y}_N(1) = Y_N + \hat{\phi}_1 [Y_N - Y_{N-1}] - \hat{\theta}_1 \hat{e}_N$$

$$\text{หรือ} = (1 + \hat{\phi}_1) Y_N - \hat{\phi}_1 Y_{N-1} - \hat{\theta}_1 \hat{e}_N$$

$$\hat{Y}_N(2) = \hat{Y}_N(1) + \hat{\phi}_1 [\hat{Y}_N(1) - Y_N]$$

$$\text{หรือ} = (1 + \hat{\phi}_1) \hat{Y}_N(1) - \hat{\phi}_1 Y_N$$

และ

$$\hat{Y}_N(l) = \hat{Y}_N(l-1) + \hat{\phi}_1 [\hat{Y}_N(l-1) - \hat{Y}_N(l-2)] \quad \text{เมื่อ } l \geq 3$$

$$\text{หรือ} = (1 + \hat{\phi}_1) \hat{Y}_N(l-1) - \hat{\phi}_1 \hat{Y}_N(l-2)$$

2.5 ขอบเขตที่น่าจะเป็นของค่าคาดคะเน (Probability Limits)

เป็นการหาจุดสูงสุดและต่ำสุดของค่าคาดคะเนในอนาคตแต่ละตัว ซึ่งจะทำให้เราทราบขอบเขตของค่าคาดคะเนนั้น ๆ จากค่าคาดคะเนในอนาคตที่กล่าวมาแล้ว คือ $y_N(l)$; $l = 1, 2, \dots, q$ และถ้าเรามีค่าจากการสังเกต y_{N+l} ก็จะทำให้ค่าความคลาดเคลื่อนในอนาคตได้ (Forecast Error), $e_N(l)$ ซึ่งเท่ากับ $y_{N+l} - \hat{y}_N(l)$ แต่ทั้งนี้ค่า y_{N+l} เป็นค่าที่ยังไม่เกิดขึ้นจริง ฉะนั้น $e_N(l)$ จะเป็นตัวแปรเชิงสุ่ม (Random Variable) ในการหาค่าความแปรปรวนของ $e_N(l)$ จะหาจากรูปแบบ ARIMA ซึ่งโดยทั่วไปจะประกอบด้วยเทอมของความคลาดเคลื่อนในอดีต คือ e_t, e_{t-1}, \dots สามารถเขียนเป็นสมการได้ดังนี้

$$2.5.1 \quad y_t = e_t + \psi_1 e_{t-1} + \psi_2 e_{t-2} + \dots$$

โดยที่ ψ_1, ψ_2, \dots เป็นค่าสัมประสิทธิ์ ซึ่งเป็นฟังก์ชันของพารามิเตอร์ใน ARIMA ดังจะได้อธิบายต่อไป และถ้าเป็นอนุกรมเวลาที่ ข้างซ้ายของสมการก็จะเป็น

$$\hat{y}_t = y_t - \mu$$

ให้ $t = N + l$ จาก 2.5.1 จะได้

$$2.5.2 \quad y_{N+l} = e_{N+l} + \psi_1 e_{N+l-1} + \psi_2 e_{N+l-2} + \dots \\ + \psi_{l-1} e_{N+1} + \psi_l e_N + \dots$$

โดยที่ ณ ช่วงเวลาที่ N ; เทอมของ $e_N, e_{N-1}, e_{N-2}, \dots$ จะคือค่าความคลาดเคลื่อนจากการสังเกต (Observed Error) และเทอมของ $e_{N+l}, e_{N+l-1}, e_{N+l-2}, \dots$ เป็นค่าความคลาดเคลื่อนในอนาคต ซึ่งค่าคาดคะเนของเทอมเหล่านี้จะเป็นศูนย์

ค่าคาดคะเนของสมการ 2.5.2 ณ จุดเริ่มต้นของการคาดคะเนที่ N คือ

$$2.5.3 \hat{Y}_N(l) = E(Y_{N+l}) = \psi_l e_N + \psi_1 e_{N+l-1} \\ + \psi_2 e_{N+l-2} + \dots$$

นำเอาสมการ 2.5.2 ลบด้วยสมการ 2.5.3 จะได้ค่าความคลาดเคลื่อนในอนาคตเป็นดังนี้

$$e_N(l) = Y_{N+l} - \hat{Y}_N(l) = e_{N+l} + \psi_1 e_{N+l-1} \\ + \psi_2 e_{N+l-2} + \dots + \psi_{l-1} e_{N+1}$$

เพราะฉะนั้น $\text{Var}[e_N(l)] = (1 + \psi_1^2 + \psi_2^2 + \dots + \psi_{l-1}^2) \sigma_e^2$

ทั้งนี้ภายใต้ข้อสมมติที่ว่าความคลาดเคลื่อนเหล่านี้ไม่มีความสัมพันธ์กัน และค่าความแปรปรวนของความคลาดเคลื่อนในอนาคต (The Variance of the Forecast Error) นี้ จะนำไปใช้สร้างขอบเขตของค่าคาดคะเนได้ โดยถือว่าภายใต้ข้อสมมติที่ว่า Y_{N+l} มีการกระจายแบบปกติ แล้วค่าความแปรปรวนของ $\hat{Y}_N(l)$ จะเท่ากับค่าความแปรปรวนของค่าความคลาดเคลื่อนในอนาคต ฉะนั้นค่า Y_{N+l} ที่เกิดขึ้นจะอยู่ภายในขอบเขตนี้ ณ ระดับนัยสำคัญ α คือ

$$2.5.4 \hat{Y}_N(l) \pm Z_{\alpha/2} \sqrt{1 + \psi_1^2 + \psi_2^2 + \dots + \psi_{l-1}^2} \sigma_e$$

การหาค่าสัมประสิทธิ์ ψ ของแต่ละรูปแบบ

จากสมการ $Y_t = e_t + \psi_1 e_{t-1} + \psi_2 e_{t-2} + \dots$

สามารถหาค่า ψ_1, ψ_2, \dots ได้เมื่อให้ $t = 1, 2, \dots$ ซึ่งจะสอดคล้องกับสมการโพลีโนเมียลของ X ใน ARIMA ดังนี้

$$2.5.5 \quad (1 - \phi_1 x - \phi_2 x^2 - \dots - \phi_p x^p) (1 - x)^d (1 + \psi_1 x + \psi_2 x^2 + \dots) = (1 - \theta_1 x - \theta_2 x^2 - \dots - \theta_q x^q)$$

โดยที่ p และ q เป็นอันดับที่ในรูปแบบ AR และ MA ตามลำดับ และ d คือจำนวนครั้งที่ได้ทำการหาผลต่าง (Differencing) เพื่อให้อนุกรมเวลาไม่คงที่เป็นอนุกรมเวลาคงที่

จาก 2.5.5 นี้จะนำมาหาค่า ψ_1, ψ_2, \dots ได้โดยการแทนค่า p, q และ d ตามลักษณะของรูปแบบนั้น

AR (1) หรือ ARIMA (1,0,0)

นั่นคือ $p = 1, d = q = 0$

จาก 2.5.5 จะได้ว่า

$$(1 - \phi_1 x) (1 - x)^0 (1 + \psi_1 x + \psi_2 x^2 + \dots) = 1$$

$$(1 - \phi_1 x) (1 + \psi_1 x + \psi_2 x^2 + \dots) = 1$$

$$1 + (\psi_1 - \phi_1)x + (\psi_2 - \phi_1\psi_1)x^2 + (\psi_3 - \phi_1\psi_2)x^3 + \dots = 1$$

เปรียบเทียบสมการข้างซ้ายและขวาจะได้

$$\psi_1 - \phi_1 = 0 \quad \text{นั่นคือ} \quad \psi_1 = \phi_1$$

$$\psi_2 - \phi_1\psi_1 = 0 \quad \text{นั่นคือ} \quad \psi_2 = \phi_1\psi_1 = \phi_1^2$$

$$\psi_3 - \phi_1\psi_2 = 0 \quad \text{นั่นคือ} \quad \psi_3 = \phi_1\psi_2 = \phi_1^3$$

ฉะนั้นสามารถเขียนในรูปแบบทั่วไปได้ดังนี้ $\psi_j = \phi_1^j$ เมื่อ $j \geq 1$

ในทำนองเดียวกัน

AR (2) หรือ ARIMA (2,0,0) คือ $p = 2, d = q = 0$ จากสมการ 2.5.5 ผลจะ
 ดังนี้

$$\begin{aligned}\psi_1 &= \phi_1 \\ \psi_2 &= \phi_1^2 + \phi_2 \\ \psi_j &= \psi_{j-1}\phi_1 + \psi_{j-2}\phi_2 \quad \text{เมื่อ } j \geq 3\end{aligned}$$

MA (1) หรือ ARIMA (0,0,1) คือ $p = d = 0 ; q = 1$ จากสมการ 2.5.5 ผล
 จะได้ดังนี้

$$\begin{aligned}\psi_1 &= -\theta_1 \\ \psi_j &= 0 \quad \text{เมื่อ } j \geq 2\end{aligned}$$

MA (2) หรือ ARIMA (0,0,2) คือ $p = d = 0, q = 2$ จากสมการ 2.5.5 ผล
 จะได้ดังนี้

$$\begin{aligned}\psi_1 &= -\theta_1 \\ \psi_2 &= -\theta_2 \\ \psi_j &= 0 \quad \text{เมื่อ } j \geq 3\end{aligned}$$

ARMA (1,1) หรือ ARIMA (1,0,1) คือ $p = 1, d = 0, q = 1$ จากสมการ
 2.5.5

$$\begin{aligned}\psi_1 &= \phi_1 - \theta_1 \quad \text{เมื่อ } j = 1 \\ \psi_j &= \phi_1 \psi_{j-1} \quad \text{เมื่อ } j \geq 2\end{aligned}$$

ARI (1,1) หรือ ARIMA (1,1,0) คือ $p = 1, d = 1, q = 0$ จากสมการ 2.5.5
ผลจะได้ดังนี้

$$\psi_j = 1 + \phi_1 + \phi_1^2 + \dots + \phi_1^j \quad \text{เมื่อ } j \geq 1$$

ARI (2,1) หรือ ARIMA (2,1,0) คือ $p = 2, d = 1, q = 0$ จากสมการ 2.5.5
ผลจะได้ดังนี้

$$\begin{aligned} \psi_1 &= 1 + \phi_1 \\ \psi_2 &= (1 + \phi_1)^2 - (\phi_1 - \phi_2) \\ \psi_3 &= (1 + \phi_1)\psi_2 - (\phi_1 - \phi_2)\psi_1 - \phi_2 \\ \psi_j &= (1 + \phi_1)\psi_{j-1} - (\phi_1 - \phi_2)\psi_{j-2} - \phi_2\psi_{j-3} \end{aligned} \quad \text{เมื่อ } j \geq 4$$



IMA (1,1) หรือ ARIMA (0,1,1) คือ $p = 0, d = 1, q = 1$ จากสมการ
2.5.5 ผลจะได้ดังนี้

$$\psi_j = (1 - \theta_1) \quad \text{เมื่อ } j \geq 1$$

IMA (1,2) หรือ ARIMA (0,1,2) คือ $p = 0, d = 1, q = 2$ จากสมการ
2.5.5 ผลจะได้ดังนี้

$$\begin{aligned} \psi_1 &= 1 - \theta_1 \\ \psi_j &= 1 - \theta_1 - \theta_2 \end{aligned} \quad \text{เมื่อ } j \geq 2$$

ARIMA (1,1,1) คือ $p = d = q = 1$ จากสมการ 2.5.5 ผลจะได้ดังนี้

$$\begin{aligned}\psi_1 &= 1 + \phi_1 - \theta_1 \\ \psi_2 &= (1 + \phi_1)^2 - \theta_1(1 + \phi_1) - \phi_1 \\ \psi_j &= (1 + \phi_1)\psi_{j-1} - \phi_1\psi_{j-2} \quad \text{เมื่อ } j \geq 3\end{aligned}$$

ทั้งนี้โดยที่ ψ_0 ของทุก ๆ รูปแบบมีค่าเท่ากับ 1 และจะเห็นได้ว่าค่าสัมประสิทธิ์ ψ_j นี้ จะเป็นฟังก์ชันของพารามิเตอร์ ϕ และ/หรือ θ ซึ่งจาก 2.2.2 จะได้ค่าประมาณกำลังสองน้อยที่สุดของพารามิเตอร์เหล่านี้ $\hat{\phi}$, $\hat{\theta}$ นำมาหาค่า $\hat{\psi}_j$ ซึ่งจะได้ใช้เป็นค่าประมาณของ ψ_j และใช้ค่าเบี่ยงเบนมาตรฐานของความคลาดเคลื่อน $\hat{\sigma}_e$ เป็นค่าประมาณของ σ_e เพื่อหาค่าขอบเขตของ $\hat{Y}_N(l)$ ดังสมการ 2.5.4

ข้อสังเกต : สำหรับอนุกรมเวลาคงที่ ค่า ψ_j^2 จะหัดออกไปเมื่อ j มีค่ามาก ๆ และขอบเขตที่น่าจะเป็นนี้ จะมีลักษณะอยู่ในแนวนอนตลอด (Horizontal Bands)

สำหรับอนุกรมเวลาไม่คงที่ ค่า ψ_j^2 จะต้องนำมาคิดด้วยถึงแม้ j มีค่ามากขึ้น และขอบเขตที่น่าจะเป็น จะมีลักษณะขยายกว้างขึ้นเมื่อช่วงเวลาของการคาดคะเนเพิ่มขึ้น ซึ่งทำให้ความเชื่อในค่าคาดคะเนนั้น ๆ มีน้อยลง

2.6 การปรับปรุงค่าคาดคะเน (Updating Forecasts)

เป็นการปรับปรุงค่าคาดคะเนที่คำนวณได้แล้วให้ดียิ่งขึ้น ถ้าหากว่าได้ข้อมูลอนุกรมเวลาชุดนั้นเพิ่มขึ้นคือ Y_{N+1}, Y_{N+2}, \dots มีวิธีการคำนวณ 2 วิธีด้วยกัน คือ

วิธีการปรับปรุงค่าคาดคะเนโดยทั่ว ๆ ไป สำหรับทุกรูปแบบ ARIMA มีสูตรในการคำนวณดังนี้

$$\hat{Y}_{N+1}(l) = \hat{Y}_N(l+1) + \psi_l e_{N+1} ; \quad l = 1, 2, \dots$$

- โดยที่ $\hat{Y}_{N+1}(l)$ คือ ค่าประมาณของค่าคาดคะเนที่เวลา $N + l + 1$ จากจุดเริ่มต้นของการคาดคะเนที่ $N + 1$
- $\hat{Y}_N(l + 1)$ คือ ค่าปรับปรุงของค่าคาดคะเนที่เวลา $N + l + 1$ จากจุดเริ่มต้นของการคาดคะเนที่ N
- e_{N+1} คือ ค่าความคลาดเคลื่อนระหว่าง $Y_{N+l} - \hat{Y}_N(l)$ หรือเรียกว่า One-Step ahead forecast error ณ ช่วงเวลาที่ N
- γ_l คือ ค่าสัมประสิทธิ์ซึ่งเป็นฟังก์ชันของพารามิเตอร์ ดังสมการในข้อ 2.5

วิธีการนี้เป็นการปรับปรุงค่าคาดคะเนที่คำนวณได้เดิมให้ถูกต้องยิ่งขึ้น โดยอาศัยค่าความคลาดเคลื่อนระหว่างข้อมูลจริงที่ได้เพิ่มขึ้น กับค่าคาดคะเนตัวแรก คือ e_{N+1} คูณกับ γ_l จากรูปแบบที่เลือกใช้ซึ่งถ้าหากว่าค่า e_{N+1} เป็นค่าลบ ค่าคาดคะเนหลังการปรับปรุงก็จะลดลง แต่ถ้าหากว่าเป็นค่าบวก ค่าคาดคะเนหลังการปรับปรุงก็จะเพิ่มขึ้น และค่าคาดคะเนหลังการปรับปรุงเกือบเท่ากันตลอดทุกช่วงเวลา ฉะนั้นเมื่อได้ข้อมูลจริงเพิ่มขึ้นแต่ละครั้ง ก็ต้องนำมาปรับปรุงค่าคาดคะเนตามสูตรข้างต้น โดยเปลี่ยนจุดเริ่มต้นของการคาดคะเน

อีกวิธีหนึ่งทำได้โดยตรงจากรูปแบบที่เลือกใช้กับข้อมูลชุดนั้น ๆ และใช้หาค่าคาดคะเน ณ จุดเริ่มต้นของการคาดคะเนที่ N เมื่อได้ค่าข้อมูลจริงที่เกิดขึ้นในช่วงเวลาที่ $N+1$ แล้วก็นำค่าตัวเลขใหม่นี้มาปรับค่าคาดคะเนที่ได้คำนวณไว้ จะได้ค่าคาดคะเนชุดใหม่ ณ จุดเริ่มต้นของการคาดคะเนที่ $N+1$ สัญลักษณ์คือ $\hat{Y}_{N+1}(l)$ และในทำนองเดียวกันเมื่อได้ค่าข้อมูลจริงเพิ่มขึ้นแต่ละครั้ง ก็ควรนำมาใช้ปรับปรุงค่าคาดคะเนใหม่ที่จุดเริ่มต้นของการคาดคะเนนั้น ๆ

นอกจากนี้ในระยะต่อมาเมื่อข้อมูลจริงเกิดขึ้นหลาย ๆ ค่าหลังจากช่วงเวลา N แล้ว ควรจะได้นำมาวิเคราะห์ว่ารูปแบบที่นำมาใช้คาดคะเนค่าในอนาคตนั้น ยังมีความเหมาะสมอยู่หรือไม่ หรือไม่เช่นนั้นก็ควรจะได้หาค่าประมาณจากพารามิเตอร์ใหม่จากรูปแบบนั้น ๆ ซึ่งอาจมีการเปลี่ยนแปลงจากเดิมก็ได้ ทั้งนี้เพื่อให้ได้รูปแบบที่มีความถูกต้องสมบูรณ์ยิ่งขึ้น

2.7 ในส่วนต่อไปนี้จะเป็นการและขั้นตอนในการวิเคราะห์ข้อมูลอนุกรมเวลาโดยทั่วไปหรือที่เรียกว่า Classical Time Series Analysis ซึ่งส่วนประกอบในอนุกรมเวลานั้นแบ่งออกได้เป็น 4 ชนิดด้วยกันคือ

ก. แนวโน้มตามลำดับเวลา (Secular Trend ; T) หมายถึง ลักษณะการเคลื่อนไหวขึ้นหรือลงของเส้นที่ยาวต่อเนื่องกันไปในช่วงระยะเวลายาว โดยไม่มีการหักมุมที่ใดของเส้นนั้น

ข. การเปลี่ยนแปลงตามฤดูกาล (Seasonal Movements ; S) หมายถึง พฤติการณ์ที่เกิดขึ้นอย่างเดียวกันหรือคล้าย ๆ กัน ในช่วงระยะเวลาอันสั้น เช่น เป็นรายวัน รายสัปดาห์ หรือรายเดือน เป็นต้น ในช่วงเวลาที่เหมือนกันข้อมูลมีการเปลี่ยนแปลงคล้ายคลึงกัน

ค. การเปลี่ยนแปลงตามวัฏจักร (Cyclical Movements ; C) หมายถึง พฤติการณ์ที่เกิดขึ้นเป็นระยะเวลาหลาย ๆ ปีคล้าย ๆ กับแนวโน้ม แต่มีรูปร่างประกอบด้วยระยะเวลารุ่งเรืองถึงจุดสูงสุดจนถึงต่ำสุด

ง. การเปลี่ยนแปลงเนื่องจากเหตุการณ์ผิดปกติ (Irregular Movements ; I) เช่น การเคลื่อนไหวที่เกิดขึ้นจากภัยธรรมชาติ เป็นต้นว่า น้ำท่วม แผ่นดินไหว

ส่วนประกอบของอนุกรมเวลามี 2 ลักษณะ คือ ในเชิงบวก (Additive Models) และในเชิงคูณ (Multiplicative Models) ซึ่งส่วนใหญ่ข้อมูลทางเศรษฐกิจจะอยู่ในลักษณะผลคูณ ฉะนั้นในที่นี้จะใช้องค์ประกอบในเชิงผลคูณมีรูปแบบการดังนี้

$$Y_i = T_i \times S_i \times C_i \times I_i$$

เมื่อ Y_i คือ ตัวแปรตาม (Dependent variable) ที่เราต้องการศึกษาในช่วงระยะเวลา i ซึ่งเราคาดว่า จะขึ้นอยู่กับแนวโน้ม (T) การเปลี่ยนแปลงเนื่องจากฤดูกาล (S) การเปลี่ยนแปลงตามวัฏจักร (C) และการเปลี่ยนแปลง เนื่องจากเหตุการณ์ผิดปกติ (I)

ในรูปแบบเชิงผลคูณนี้มักจะพบค่าแนวโน้ม และการเปลี่ยนแปลงเนื่องจากฤดูกาลปรากฏอยู่เสมอ ดังนั้นจะนำวิธีการวิเคราะห์หาค่าแนวโน้ม ซึ่งเป็นการศึกษาหาความสัมพันธ์ระหว่างเวลากับข้อมูลที่สนใจศึกษา โดยมีเวลา (X) เป็นตัวแปรอิสระ (Independent Variable) และข้อมูลที่สนใจศึกษา (Y) เป็นตัวแปรตาม (Dependent Variable) และหาค่าดัชนีฤดูกาล (Seasonal Index) เพื่อนำทั้งสองส่วนประกอบนี้มาใช้หาค่าคาดคะเนต่อไป

2.7.1 การวิเคราะห์หาแนวโน้มของข้อมูล ข้อมูลที่จะนำมาศึกษาเพื่อหาแนวโน้มนั้น จะต้องเป็นอนุกรมเวลาในระยะเวลายาวพอสมควร ส่วนมากตั้งแต่ 10 ช่วงเวลาขึ้นไป อาจจะเป็นเดือนหรือปีก็ได้ การสร้างแนวโน้มนี้อาจจะเป็นรูปอะไรก็ได้ ซึ่งแบ่งได้อย่างกว้าง ๆ เป็น 2 ลักษณะ คือ แนวโน้มที่เป็นเส้นตรง (Linear Trend) และไม่เป็นเส้นตรง (Non - Linear Trend) ในการคำนวณหาเส้นแนวโน้มมีหลายวิธีด้วยกัน แต่วิธีที่นิยมใช้กันมากที่สุดและง่ายในการคำนวณ คือ วิธีกำลังสองน้อยที่สุด (Least Squares Method) โดยมีหลักเกณฑ์ที่พยายามทำให้ผลรวมของผลต่างระหว่างค่าที่ได้จากเส้นแนวโน้มกับค่าข้อมูลจริงยกกำลังสองแล้วได้ค่าน้อยที่สุด

รูปแบบทั่วไปของสมการแนวโน้ม คือ สมการโพลีโนเมียล มีรูปแบบดังนี้

$$Y = a_0 + a_1X + a_2X^2 + a_3X^3 + \dots + a_nX^n$$

โดยที่ Y เป็น ตัวแปรตาม

X เป็น ตัวแปรอิสระ

a_i เป็น ค่าคงที่หรือพารามิเตอร์ ; $i = 0, 1, 2, \dots, n$

เส้นกราฟที่ได้จากสมการโพลิโนเมียลแต่ละอันดับจะมีลักษณะแตกต่างกันไป คือ

อันดับที่ 1 จะเป็นรูปแบบของแนวโน้มเส้นตรง (Linear Trend)

$$Y_t = a_0 + a_1 X$$

อันดับที่ 2 จะเป็นรูปแบบของแนวโน้มเส้นโค้งเดียว (Parabola Trend)

$$Y_t = b_0 + b_1 X + b_2 X^2$$

อันดับที่ 3 จะเป็นรูปแบบของแนวโน้มสองโค้ง (Hyperbola Trend)

$$Y_t = c_0 + c_1 X + c_2 X^2 + c_3 X^3$$

การคำนวณหาแนวโน้มโดยสมการโพลิโนเมียล มักนิยมและเหมาะสมกับข้อมูลโดยทั่วไปเพียงอันดับสามเท่านั้น เพราะยิ่งกำลังสูงมากขึ้น การคำนวณก็จะยุ่งยากมากขึ้นตามไปด้วย และจากทั้งสามรูปแบบนี้จะหาค่าประมาณของพารามิเตอร์ด้วยวิธีการของ Least Squares และคำนวณจากสมการปกติ (Normal Equations) ซึ่งหามาได้จากการ Differentiate ผลรวมของผลต่างกำลังสองของข้อมูลทั้งหมดเทียบกับตัวคงที่ในรูปแบบนั้น ๆ

นอกจากสามรูปแบบที่กล่าวมาแล้ว จะได้นำรูปแบบของแนวโน้มที่ไม่เป็นเส้นตรง อีกลักษณะหนึ่งมาคำนวณ คือ รูปแบบแนวโน้มเอ็กซ์โพเนนเชียล ; $Y_t = ab^X$ ซึ่งการหาค่าประมาณของ a, b อาจทำให้ยุ่งยากขึ้น โดยการแปรรูปเข้าช่วยเพื่อกำหนดสมการเดิม เปลี่ยนรูปเป็นเส้นตรง จะได้ดังนี้

$$\log Y_t = \log a + X \log b$$

จากสมการปกติสามารถคำนวณค่าพารามิเตอร์ได้จากสูตร

$$\log \bar{a} = \frac{\sum \log Y}{N}$$

$$\log b = \frac{\sum X \log Y}{X^2}$$

ในการวิจัยนี้ จะใช้วิธีการสำหรับการพิจารณาเลือกรูปแบบแนวโน้ม ลักษณะใดที่จะมีความเหมาะสมกับข้อมูลที่นำมาศึกษาแต่ละชุดที่ดีที่สุดนี้จะเลือกรูปแบบที่ให้ค่าผลบวกของส่วนเบี่ยงเบนยกกำลังสองน้อยที่สุด และจากรูปแบบที่ได้นี้จะนำมาหาค่าแนวโน้มของแต่ละเดือนในปีต่าง ๆ ต่อไป

2.7.2 การวิเคราะห์หาค่าดัชนีฤดูกาล ดัชนีฤดูกาลนี้จะใช้เป็นเครื่องมือกำจัด Seasonal Variations ออกจากข้อมูลอนุกรมเวลา และใช้ดัชนีฤดูกาลเพื่อประโยชน์ในการหาค่าคาดคะเนประกอบกับค่าแนวโน้มอีกด้วย การหาค่าดัชนีฤดูกาลนี้อาจทำได้หลายวิธีด้วยกันคือ

ก. Ratio-to-Moving Average Method

ข. Ratio-to-Trend Method ซึ่งจะได้กล่าวถึงขั้นตอนในการคำนวณในวิธีการนี้ แต่เพียงอย่างเดียวดังนี้

1. จากการวิเคราะห์หาแนวโน้มของข้อมูลข้างต้น นำค่าแนวโน้ม (Y_t) ของแต่ละเดือนในปีต่าง ๆ กำจัดค่าแนวโน้มออกจากรายการโดยนำไปหารข้อมูลจริง จะได้ค่า

Ratio-to-Trend ; $\left[\frac{Y_t}{\hat{Y}_t} \times 100 \right]$ ของแต่ละเดือนของทุกปี

2. กำจัด C และ I จากข้อมูลในข้อ 1 โดยวิธีหาค่าเฉลี่ย ซึ่งจะใช้ค่าเฉลี่ยเลขคณิตหรือมัธยฐานก็ได้

3. นำค่าเฉลี่ยที่ได้ในแต่ละเดือนเทียบกับค่าเฉลี่ยของค่าเฉลี่ยของทุก ๆ เดือน แล้วคูณด้วย 100 ซึ่งผลที่ได้ก็คือดัชนีฤดูกาลที่ต้องการ

เมื่อได้ค่าแนวโน้มและดัชนีฤดูกาลของอนุกรมเวลาแต่ละชุดแล้ว นำมาคำนวณหาค่าคาดหมาย (Fitted Values) เพื่อเปรียบเทียบกับค่าข้อมูลจริง พร้อมทั้งหาค่าผลบวกของส่วนเบี่ยงเบนยกกำลังสอง หลังจากนั้นก็นำมาหาค่าคาดคะเน เพื่อช่วยในการพยากรณ์หรือทำนายเหตุการณ์ล่วงหน้าต่อไป



ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย