

บทที่ 3

ทฤษฎีและระเบียบวิธีวิจัย

3.1 แนวคิดเกี่ยวกับการพยากรณ์ข้อมูลอนุกรมเวลา

3.1.1 แนวคิดการพยากรณ์อนุกรมเวลา

อนุกรมเวลา (Time series) คือค่าสังเกต (Observation) ชุดหนึ่งซึ่งถูกกำหนดขึ้น ณ เวลาต่างๆ ถ้าค่าสังเกตกระทำในเวลาต่อเนื่องกัน จะเรียกว่า อนุกรมเวลาต่อเนื่อง แต่ถ้าค่าสังเกตกระทำ ณ จุดเวลาที่ไม่ต่อเนื่องกัน เรียกว่า อนุกรมเวลาไม่ต่อเนื่อง ดังนั้น การวิเคราะห์อนุกรมเวลาจึงเป็นการวิเคราะห์ค่าสังเกตที่มีการเปลี่ยนแปลงไปตามเวลาที่กระทำ ลักษณะของการเปลี่ยนแปลงอาจจะมีรูปแบบหรือไม่ก็มีก็ได้ แต่ถ้าอนุกรมเวลามีลักษณะการเปลี่ยนแปลงที่มีรูปแบบก็จะทำให้สามารถที่จะพยากรณ์รูปแบบในอนาคตได้ (ทรงศักดิ์ ศรีบุญจิตต์ และอารี วิบูลย์พงศ์, 2542)

การศึกษาอนุกรมเวลาของราคาสินค้ารายเดือน ณ ตลาดต่างๆ โดยการกำหนดรูปแบบให้กับอนุกรมเวลา เพื่อพิจารณาความมีเสถียรภาพและลักษณะรูปแบบพฤติกรรมราคามีอิทธิพลของแนวโน้มและฤดูกาลเข้ามาเกี่ยวข้องกับสินค้าที่ทำการศึกษาหรือไม่ พร้อมทั้งนำรูปแบบของสมการที่ได้ทำการวิเคราะห์อนุกรมเวลาแล้วนำมาทำนายราคาสินค้าที่ศึกษาไปล่วงหน้าเพื่อนำค่าพยากรณ์ดังกล่าวมาใช้ ในการจัดสรรทรัพยากรที่เหมาะสมต่อไป

3.1.2 การทดสอบความนิ่งของข้อมูลอนุกรมเวลา (Unit root test)

แบบจำลองที่ใช้ในการศึกษาของข้อมูลอนุกรมเวลา (time-series data) สำหรับทดสอบว่าตัวแปรแต่ละตัวมีลักษณะ นิ่ง (stationary) หรือไม่ ซึ่งเป็นการทดสอบว่ามี unit root หรือไม่นั่นเอง ทรงศักดิ์ ศรีบุญจิตต์ และอารี วิบูลย์พงศ์ (2542) กล่าวว่า ข้อสมมติ (assumptions) เบื้องหลังการประมาณค่าทางเศรษฐมิติโดยใช้ข้อมูลอนุกรมเวลานั้น คือข้อสมมติเกี่ยวกับความนิ่ง (stationary) ของข้อมูล สมมติว่าเรามีแบบจำลอง

$$Y_t = \alpha + \beta x_t + u_{1t} \quad (1)$$

และ $X_t = x_{t-1} + u_{2t} \quad ; \quad u_{2t} \sim iid(0, \sigma^2_{u_2}) \quad (2)$

โดยที่ u_{2t} เป็นอนุกรมเวลาของตัวแปรสุ่ม (random variables) ที่แจกแจงแบบปกติที่เหมือนกัน และเป็นอิสระต่อกัน โดยค่าเฉลี่ย (mean) เท่ากับศูนย์ และค่าความแปรปรวน (variance) คงที่ ซึ่ง

ตัวแปร x นั้น ก็จะเป็นแนวเดินเชิงสุ่ม (random walk) และเป็น integrated of order one, $I(1)$ เพราะฉะนั้นตัวแปร y ก็จะเป็น $I(1)$ ด้วย ซึ่งโดยทฤษฎีเศรษฐมิติแล้วการถดถอยด้วยตัวแปรที่มีลักษณะไม่นิ่ง (nonstandard distribution) การใช้ตารางมาตรฐานที่เราใช้กันโดยทั่วไปสำหรับการทดสอบค่าสถิติต่าง ๆ ก็อาจนำไปสู่การลงความเห็นหรือข้อสรุปที่ผิดพลาดได้ซึ่งนำไปสู่ความเป็นไปได้ของการมีถดถอยที่ไม่ถูกต้อง (spurious regression) (Jonhston and Dinardo, 1997)

การทดสอบ unit root นั้นสามารถทดสอบได้โดยใช้การทดสอบ DF (Dickey-Fuller (DF) test) (Dickey and Fuller, 1981) และการทดสอบ ADF (Augmented Dickey-Fuller test) (Said and Dickey 1984) สมมุติฐานว่าง (null hypothesis) ของการทดสอบ DF (DF test) คือ $H_0 : \rho = 1$ จากสมการ (3)

$$X_t = \rho X_{t-1} + \varepsilon_t \quad (3)$$

ซึ่งเรียกว่าการทดสอบ unit root โดยถ้า $|\rho| < 1$ X_t จะลักษณะนิ่ง (stationary); และถ้า $\rho = 1$ X_t จะมีลักษณะไม่นิ่ง (nonstationary) อย่างไรก็ตามการทดสอบนี้สามารถทำได้อีกทางหนึ่งซึ่งเหมือนกับสมการ (3)

$$\Delta X_t = \theta X_{t-1} + \varepsilon_t \quad (4)$$

โดยที่ $\rho = (1 + \theta)$ ถ้า θ ในสมการ (4) มีค่าเป็นลบ จะได้ว่า ρ ในสมการ (3) จะมีค่าน้อยกว่า 1 ดังนั้นสามารถจะสรุปได้ว่า การปฏิเสธ $H_0 : \theta = 0$ ซึ่งเป็นการยอมรับ $H_a : \theta < 0$ หมายความว่า $\rho < 1$ และ X_t มี integration of order zero (Charemza and Deadman, 1992) นั่นคือ X_t มีลักษณะนิ่ง (stationary) และถ้าเราไม่สามารถปฏิเสธ $H_0 : \theta = 0$ ได้ ก็จะหมายความว่า X_t มีลักษณะไม่นิ่ง (non stationary) โดย X_t มีแนวคิดเดินเชิงสุ่มซึ่งมีความโน้มเอียงทั่วไปรวมอยู่ด้วย (random walk with drift) เราเขียนแบบจำลองได้ดังนี้

$$\Delta X_t = \alpha + \theta X_{t-1} + \varepsilon_t \quad (5)$$

และมีแนวโน้มตามเวลาเชิงเส้น เราเขียนแบบจำลองได้ดังนี้

$$\Delta X_t = \alpha + \beta t + \theta X_{t-1} + \varepsilon_t \quad (6)$$

โดยที่ $t =$ แนวโน้มของเวลา

ถ้าหากสมการที่ (4) (5) และ (6) มีกระบวนการเชิงอัตถคถอยเข้ามาเกี่ยวข้องจะเรียกว่า การทดสอบโดยวิธี Augmented Dickey – Fuller test (ADF test) ได้สมการเป็นดังนี้

$$\Delta X_t = \theta X_{t-1} + \sum_{i=1}^p \phi_i \Delta X_{t-1} + \varepsilon_t \quad (7)$$

$$\Delta X_t = \alpha + \theta X_{t-1} + \sum_{i=1}^p \phi_i \Delta X_{t-1} + \varepsilon_t \quad (8)$$

$$\Delta X_t = \alpha + \beta t + \theta X_{t-1} + \sum_{i=1}^p \phi_i \Delta X_{t-1} + \varepsilon_t \quad (9)$$

ซึ่งการทดสอบแบบดังกล่าวมีการแจกแจงเหมือนกับการทดสอบ DF จึงสามารถใช้ค่าวิกฤตในการพิจารณาแบบเดียวกัน ส่วนการหา Lag Length ตามวิธีของ Ender (Ender, 1995: 227) นั้นให้เริ่มต้นที่ Lag Length ที่มากพอสมควรค่าหนึ่งแล้วค่อยๆ ลดค่า Lag Length ลงเรื่อยๆ เมื่อพบว่าค่าสถิติ t-test หรือ F-test ที่ใช้ในการทดสอบนั้นไม่มีนัยสำคัญ ณ ระดับที่กำหนด จนกระทั่งค่าสถิติมีนัยสำคัญ จึงจะถือว่าค่า Lag นั้นมีความเหมาะสม

3.1.3 การพยากรณ์โดยวิธี Box-Jenkins

วิธีของ Box – Jenkins นั้นเป็นวิธีการพยากรณ์ที่มีความถูกต้องกว่าวิธีอื่น และเหมาะสมกับการพยากรณ์ระยะสั้นในช่วงเวลา 1 เดือนถึง 3 เดือน หากต้องการจะพยากรณ์ในช่วงเวลาที่ยาวนานกว่านี้ควรนำข้อมูลที่ทันสมัยมาปรับค่าพยากรณ์ที่ได้ทำไว้แล้ว เพื่อให้ได้ค่าความคลาดเคลื่อนจากการพยากรณ์ลดลง

วิธีการของ Box-Jenkins เป็นการวิเคราะห์อนุกรมเวลาโดยการหารูปแบบที่เหมาะสมให้กับอนุกรมเวลา รูปแบบที่จะกำหนดให้กับอนุกรมเวลาจะเป็นรูปแบบในกลุ่มของรูปแบบ ARIMA (p,d,q) (Intergrated Autoregressive-Moving Average order p and q) ซึ่งเป็นการรวมส่วนของรูปแบบ AR (p) และรูปแบบ MA (q) เข้าด้วยกัน ส่วนอันดับของ d คือจำนวนครั้งที่หาผลต่าง (Intergrated) รูปแบบ AR (p) หมายถึงรูปแบบที่แสดงว่าค่าสังเกต Y_t จะขึ้นอยู่กับค่าของ Y_{t-1}, \dots, Y_{t-p} หรือค่าสังเกตที่เกิดขึ้นก่อนหน้า p ค่า ส่วนรูปแบบ MA (q) หมายถึงรูปแบบที่แสดงว่าค่าสังเกต Y_t จะขึ้นอยู่กับค่าของ ความคลาดเคลื่อน $\varepsilon_{t-1}, \dots, \varepsilon_{t-q}$ หรือความคลาดเคลื่อนที่อยู่ก่อนหน้า q ค่า ซึ่งรูปแบบ AR MA (p,q) มีการกำหนดรูปแบบดังนี้

แบบจำลองที่ใช้ในการพยากรณ์ คือแบบจำลองอาร์มา ARIMA (p, d, q) ซึ่งประกอบไปด้วย 3 ส่วนดังนี้ การถดถอยด้วยตัวเอง (Autoregressive; AR: p) การมีอันดับ (Integrated; I: d)

และการเคลื่อนที่ของความคลาดเคลื่อน (Moving Average; MA: q) สำหรับรูปแบบทั่วไปของ อารีมา (ARIMA) สามารถเขียนเป็นความสัมพันธ์ได้ดังนี้

$$\text{AR (p)} \quad \text{คือ} \quad Y_t = \theta_0 + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t$$

$$\text{MA (q)} \quad \text{คือ} \quad Y_t = \theta_0 + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q}$$

$$\text{AR MA (p,q)} \quad \text{คือ} \quad Y_t = \theta_0 + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q}$$

$$\text{ARIMA (p,d,q)} \quad \text{คือ} \quad \Delta^d Y_t = \theta_0 + \phi_1 \Delta^d Y_{t-1} + \dots + \phi_p \Delta^d Y_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q}$$

การกำหนดรูปแบบที่เหมาะสมให้กับอนุกรมเวลาจะใช้ค่าสัมประสิทธิ์สหสัมพันธ์แบบออโต (Autocorrelation Function: ACF) และค่าสัมประสิทธิ์สหสัมพันธ์บางส่วนแบบออโต (Partial Autocorrelation)

อนุกรมเวลาที่จะนำมาศึกษาเพื่อประโยชน์ในการพยากรณ์นั้นการเคลื่อนไหวของอนุกรมเวลาขึ้นอยู่กับส่วนประกอบต่างๆ ได้แก่ แนวโน้ม (Trend) ตัวแปรฤดูกาล (Seasonal factor) ตัวแปรวัฏจักร (Cyclical factor) และเหตุการณ์ที่ผิดปกติ (Irregular movement) โดยวิธี Box-Jenkins จะสามารถแบ่งอนุกรมเวลาออกเป็น 2 ประเภทดังนี้

1) อนุกรมเวลาที่เป็น Stationary series เป็นอนุกรมเวลา $\{Y_t\}$ ที่มีค่าเฉลี่ยและความแปรปรวนของ Y_t คงที่ นั่นคือค่าเฉลี่ย $E(Y_t)$ และค่าความแปรปรวน $V(Y_t)$,มีค่าคงที่สำหรับแต่ละอนุกรมเวลา ซึ่งอนุกรมเวลาที่มีแนวโน้มและ/หรืออิทธิพลฤดูกาลจะมีค่าเฉลี่ย $E(Y_t)$ ไม่คงที่และอนุกรมเวลาที่มีความแปรปรวนของ Y_t สูงจะเป็นลักษณะของอนุกรมเวลาที่ $V(Y_t)$ มีค่าไม่คงที่ซึ่งจะเรียกอนุกรมเวลาดังกล่าวนี้ว่า อนุกรมเวลาที่ไม่เป็น Stationary series นอกจากนั้นอนุกรมเวลาที่เป็น Stationary series จะเป็นอนุกรมเวลาที่มีค่าเฉลี่ยและความแปรปรวนคงที่แล้วยังจะต้องมีค่าสัมประสิทธิ์สหสัมพันธ์แบบออโตที่ lag K ขึ้นอยู่กับค่า K อย่างเดียว อนุกรมเวลาที่กำหนดรูปแบบ AR MA (p,q) ได้จะต้องเป็นอนุกรมเวลาที่เป็น Stationary series แล้ว

2) อนุกรมเวลาที่ไม่เป็น Stationary series เป็นอนุกรมเวลาที่ไม่มีความสัมพันธ์เป็น Stationary series การจะหารูปแบบ ARMA (p,q) ให้กับอนุกรมเวลาดังกล่าวได้จะต้องแปลงอนุกรมเวลาดังกล่าวให้เป็นอนุกรมเวลาใหม่ที่มีความสัมพันธ์เป็น Stationary series เสียก่อน การแปลงอนุกรมเวลาที่ไม่เป็น Stationary series ให้เป็นอนุกรมเวลาที่เป็น Stationary series อาจทำได้ด้วยวิธีการต่างๆดังนี้

2.1 การหาผลต่างปกติ (Regular differencing) ของอนุกรมเวลาเพื่อกำจัดแนวโน้ม นั่นคือถ้าอนุกรมเวลา $\{Y_t\}$ มีแนวโน้มอยู่ในอนุกรมเวลาจะแปลงให้เป็นอนุกรมเวลาใหม่

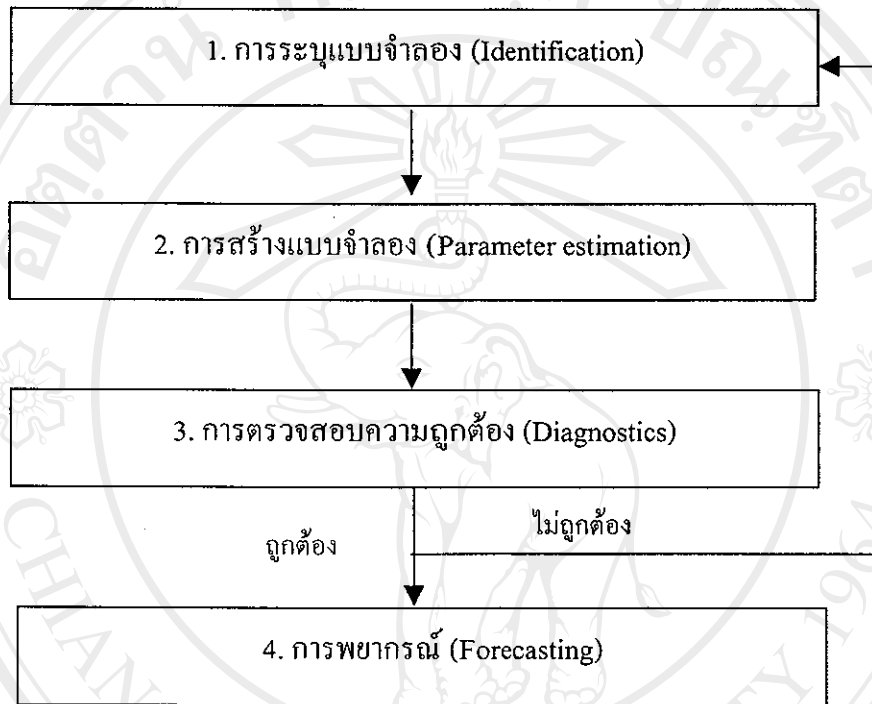
ที่ไม่มีแนวโน้ม $\{z_t\}$ โดย $z_t = \nabla^d Y_t$ โดย d เป็นลำดับของการหาผลต่างและ ∇ คือผลต่างของตัวแปร เช่นเมื่อ $d=1$ จะได้ $z_t = \nabla Y_t = Y_t - Y_{t-1}$ เมื่อ $d=2$ จะได้ $z_t = \nabla^2 Y_t = \nabla(Y_t - Y_{t-1}) = \nabla Y_t - \nabla Y_{t-1} = Y_t - 2Y_{t-1} + Y_{t-2}$ เป็นต้น จำนวนครั้งที่หาผลต่างจะขึ้นอยู่กับว่าเมื่อหาผลต่างแล้วอนุกรมเวลาใหม่เป็น Stationary series หรือไม่ ถ้ายังไม่เป็น stationaries series ต้องหาผลต่างต่อไปต่อไป โดยทั่วไป ถ้าอนุกรมเวลามีแนวโน้มเป็นแบบเส้นตรงจะใช้ $d = 1$ อนุกรมเวลาที่มีแนวโน้มเป็นแบบควอดราติก (Quadratic) จะใช้ $d=2$

2.2 การหาผลต่างฤดูกาล ของอนุกรมเวลา ถ้าอนุกรมเวลามีตัวแปรเข้ามาเกี่ยวข้อง จะต้องแปลงอนุกรมเวลาเดิม $\{Y_t\}$ ให้เป็นอนุกรมเวลาใหม่ที่ไม่มีฤดูกาล $\{z_t\}$ โดย $z_t = \nabla_L^D Y_t$ โดย D เป็นลำดับของการหาผลต่างฤดูกาล และ L เป็นจำนวนฤดูกาลต่อปี เช่น สำหรับอนุกรมเวลารายเดือน ($L = 12$) เมื่อ $D = 1$ จะได้ $z_t = \nabla_{12} Y_t$ หรือ $z_t = Y_t - Y_{t-12}$ หรือ และเมื่อ $D = 2$ จะได้ $z_t = \nabla_{12}^2 Y_t$ หรือ $z_t = \nabla^2(Y_t - Y_{t-12})$ เป็นต้นผลต่างนี้จะทำกี่ครั้งขึ้นอยู่กับว่าเมื่อหาผลต่างแล้วอนุกรมเวลาใหม่เป็น Stationary series หรือไม่ ถ้ายังไม่เป็น Stationary series หรือไม่ถ้ายังไม่เป็น Stationary series ต้องหาผลต่างต่อไป

2.3 การหาผลต่างปกติและผลต่างฤดูกาล กรณีที่อนุกรมเวลามีทั้งแนวโน้มและตัวแปรฤดูกาล การปรับให้อนุกรมเวลาเป็น Stationary series นั้นจะทำได้โดยการหาผลต่างปกติและผลต่างฤดูกาล โดยที่ค่า d และ D ควบคู่กันไปซึ่งค่า d เป็นลำดับของการหาผลต่างปกติ และค่า D เป็นลำดับของการหาผลต่างฤดูกาล โดยที่ค่า d และ D จะมีค่าเท่าใดนั้นขึ้นอยู่กับว่าเมื่อหาผลต่างปกติและผลต่างฤดูกาล แล้วอนุกรมเวลาใหม่เป็น Stationary series หรือไม่ ถ้ายังไม่เป็น Stationary series ต้องหาผลต่างต่อไป เช่น อนุกรมเวลารายเดือน ที่มีทั้งแนวโน้มและฤดูกาล เมื่อ $d = 1$ และ $D = 1$ จะแปลงอนุกรมเวลาเดิม $\{y_t\}$ ให้เป็นอนุกรมเวลาใหม่ $\{z_t\}$ ซึ่ง $z_t = \nabla \nabla_{12} Y_t = \nabla(Y_t - Y_{t-12}) = \nabla Y_t - \nabla Y_{t-12} = Y_t - Y_{t-1} - Y_{t-12} + Y_{t-13}$ เป็นต้น

2.4 การหาลอการิทึมของค่าสังเกตในอนุกรมเวลา นั่นคือ แปลงอนุกรมเวลาเดิม $\{y_t\}$ ให้เป็นอนุกรมเวลาใหม่ $\{z_t\}$ โดย $z_t = \ln(Y_t)$ การแปลงนี้จะทำเมื่อความแปรปรวนของอนุกรมเวลาไม่คงที่ นั่นคือ $V(Y_t)$ สำหรับค่าเวลา t ต่างๆ

ขั้นตอนของ Box-Jenkins ประกอบด้วย 4 ขั้นตอน ดังนี้ ขั้นตอนที่หนึ่ง คือการกำหนดรูปแบบจำลอง (Identification) ขั้นตอนที่สอง คือการประมาณค่า (Estimation) ขั้นตอนที่สาม คือวิเคราะห์ความถูกต้อง (Diagnostic Checking) และขั้นตอนที่สี่ คือการพยากรณ์ (Forecasting) ตามลำดับ ดังจะพิจารณาจากภาพ 3.1



ภาพ 3.1 แสดงขั้นตอนการพยากรณ์โดยวิธี Box and Jenkins (Gujarati , 2003)

1. การกำหนดแบบจำลอง (Identification)

การกำหนดแบบรูปแบบ (Identification) ให้กับอนุกรมเวลาที่เป็น Stationary Series เป็นการหารูปแบบ ARMA (p,q) ที่คาดว่าจะเหมาะสมให้กับอนุกรมเวลาโดยที่

Autocorrelation : ρ_k คือการวัดความสัมพันธ์ของแต่ละช่วงเวลา โดยมีช่วงเวลาที่ย้อนหลังไป k หน่วยเวลา โดยที่ ρ_k มีค่าเท่ากับ $-1 \leq \rho_k \leq 1$ โดยพิจารณาเปรียบเทียบค่า Autocorrelation (r_k) ของอนุกรมเวลาตัวอย่าง กับค่า Autocorrelation (ρ_k) ของอนุกรมเวลาของประชากร ที่มีช่วงเวลาย้อนหลังไป k หน่วยเวลา ซึ่งมีสูตรดังนี้

$$r_k = \frac{\sum_{t=a}^{n-k} (Y_{t-q})(Y_{t+k-q})}{\sum_{t=a}^n (Y_{t-q})^2} \quad (10)$$

โดยที่

$$Y_t = \sum_{t=a}^n (Y_t)$$

q = จำนวนเวลาสุดท้ายที่ย้อนหลัง

Partial Autocorrelation : ρ_{kk} คือการวัดความสัมพันธ์ของแต่ละช่วงเวลา โดยมีช่วงเวลาที่ย้อนหลังไป k หน่วยเวลา โดยพิจารณาเปรียบเทียบค่า Partial Autocorrelation (r_{kk}) ของอนุกรมเวลาตัวอย่าง กับค่า Partial Autocorrelation (ρ_{kk}) ของอนุกรมเวลาของประชากรที่มีช่วงเวลาย้อนหลังไป k หน่วยเวลา ซึ่งมีสูตรดังนี้

$$r_{kk} = \frac{\sum_{j=1}^{k-1} (r_{k-1,j})(r_{k-j})}{\sum_{j=1}^{k-1} (r_{k-1,j})(r_j)} \quad (11)$$

การพิจารณาเปรียบเทียบแต่ละรูปแบบ ต้องพิจารณา r_k , r_{kk} กับ ρ_k และ ρ_{kk} พร้อมกันหลาย ๆ ค่า จึงมักจะพิจารณาจากรูปที่เรียกว่าคอเรโลแกรม (Correlogram) ที่ได้จากการพล็อต r_k , r_{kk} , ρ_k และ ρ_{kk} ในช่วงเวลา k ดังนั้นการพิจารณาเปรียบเทียบ จะเป็นการเปรียบเทียบ Correlogram ของค่า Autocorrelation ของอนุกรมเวลาตัวอย่าง (r_k) กับค่า Autocorrelation ของอนุกรมเวลาของประชากร (ρ_k) และ Correlogram ของค่า Partial Autocorrelation ของอนุกรมเวลาตัวอย่าง (r_{kk}) กับค่า Partial Autocorrelation ของอนุกรมเวลาประชากร (ρ_{kk}) สำหรับแต่ละรูปแบบจะมี Correlogram ของ ρ_k และ ρ_{kk} ต่างกัน อนุกรมเวลาที่จะนำมากำหนดรูปแบบจะต้องเป็นอนุกรมเวลาที่ Stationary เท่านั้น หากไม่จำเป็น Stationary จะต้องแปลงให้เป็น Stationary เสียก่อน

การกำหนดลำดับชั้น p, q ในแบบจำลอง (Identifying the dependence order of model) ขั้นตอนนี้คือการระบุว่าแบบจำลองนี้ควรมี Autoregressive, p เท่าใด Differencing, d ที่ลำดับเท่าใด และ Moving average, q เท่าใด โดยพิจารณาจาก ACF และ PACF ซึ่งอาจจะใช้ตาราง 4 ดังต่อไปนี้พิจารณาพร้อม

ตาราง 3.1 ตารางแสดงการพิจารณา ACF และ PACF

ชนิดของแบบจำลอง	รูปแบบของ ACF	รูปแบบของ PACF
AR(p)	ตู้โค้งเข้าหาแกน (Tails off)	เกิดค่าที่ชัดเจนเพียง p ค่าแล้ว หายไป (Cut off after Lag p)
MA(q)	เกิดค่าที่ชัดเจนเพียง q ค่าแล้ว หายไป (Cut off after Lag p)	ตู้โค้งเข้าหาแกน (Tails off)
ARMA(p,q)	ตู้โค้งเข้าหาแกน (Tails off)	ตู้โค้งเข้าหาแกน (Tails off)

ที่มา : Gujarati, N. (2003)

จากตารางข้างต้น จะสามารถกำหนดรูปแบบของแบบจำลองได้ดังต่อไปนี้ หากคอเรลโลแกรมของ ACF มีลักษณะโค้งตู้เข้าหาแกนในระนาบ ในขณะที่คอเรลโลแกรม PACF เกิดมีค่าขึ้นมาไม่กี่ค่าแล้วก็หายไป จำนวนของแท่งของค่าที่เกิดขึ้นมา ให้นับเป็น ค่าที่ p ของ AR(p) ยกตัวอย่างเช่น เมื่อพิจารณาคอเรลโลแกรมของ ACF ที่โค้งตู้เข้าหาแกนระนาบ และ PACF ที่มีแท่งคอเรลโลแกรม เกิดขึ้น 1 แท่ง แปลได้ว่าแบบจำลองควรมีลักษณะเป็น AR(1) สำหรับ MA(q) นั่นก็จะมี ACF ที่เกิดขึ้นมาไม่กี่ค่าแล้วหายไป ในขณะที่ PACF จะตู้โค้งเข้าหาแกนระนาบนั้น ยกตัวอย่างเช่น หากค่า ACF เกิดแท่งคอเรลโลแกรมขึ้นเพียง 2 แท่ง และหลังจากนั้นก็หายไป ในขณะที่ PACF โค้งตู้เข้าหาแกนระนาบ สามารถสรุปได้ว่าแบบจำลองควรมีลักษณะเป็น MA(2) และหาก ACF และ PACF โค้งตู้เข้าหาแกนระนาบทั้งคู่ แบบจำลองควรจะเป็น ARMA(p,q) และเมื่อรวมกันกับการทดสอบความนิ่ง (Stationary) ในขั้นตอนที่ 1 แล้ว จะสามารถหาค่าของ Difference ได้ ซึ่งผลจากการ Difference จำนวน d ครั้งนั้น ก็จะได้แบบจำลอง ARIMA(p,d,q) แต่อย่างไรก็ตามหลักการดังกล่าวก็เป็นเพียงเครื่องช่วยการพิจารณาในระดับหนึ่งเท่านั้น เนื่องจากวิธีการดังกล่าวมีลักษณะที่เป็นศิลป์ (Art) มากกว่าศาสตร์ (Science) ดังนั้นเพื่อประเมินแบบจำลอง ว่าแบบจำลองใดมีความเหมาะสมที่จะใช้เป็นตัวแทนกลุ่มข้อมูลจริง สามารถพิจารณาได้จากค่าสถิติดังต่อไปนี้เพื่อประกอบในการตัดสินใจ

1.1 ค่าเฉลี่ยค่าความคลาดเคลื่อนกำลังสอง (Root Mean Square Error : RMSE)

ค่ารากที่สองของค่าเฉลี่ยค่าความคลาดเคลื่อนกำลังสอง (Root mean square Error: RMSE) เป็นการวัดค่าความคลาดเคลื่อนระหว่างค่าจริง และค่าที่ประมาณจากแบบจำลองว่ามีความแตกต่างกันมากน้อยเพียงใด ซึ่งหากค่า RMSE มีค่าเท่ากับศูนย์ จะหมายถึงแบบจำลองที่ประมาณได้มีค่าเท่ากับค่าจริงพอดี ดังนั้นหากค่า RMSE มีค่าน้อยเพียงไรก็แสดงว่าแบบจำลองนั้นสามารถเป็นตัวแทนค่าจริงได้ดีมากเพียงนั้น สามารถพิจารณาสมการค่ารากที่สองของค่าเฉลี่ยค่าความคลาดเคลื่อนกำลังสอง (RMSE) ได้ดังนี้

$$RMSE = \sqrt{\frac{1}{T} \sum_{t=1}^T (Y_t^s - Y_t^a)^2} \quad (12)$$

กำหนดให้ Y_t^s คือ ค่าที่ประมาณจากแบบจำลอง
 Y_t^a คือ ค่าข้อมูลจริง
 T คือ จำนวนของคาบเวลาที่ใช้ในการประมาณแบบจำลอง

1.2 ค่าTheil's inequality coefficient

โดยในหลักการเบื้องต้น พบว่าสมการที่ใช้ยังคงมีหลักการที่คล้ายกันกับ RMSE โดยสิ่งที่ต่างออกไปจาก RMSE คือค่าสถิตินี้จะมีค่าอยู่ระหว่าง 0 และ 1 ทั้งนี้หากค่า U มีค่าเท่ากับศูนย์ นั่นก็หมายความว่าค่าที่ได้จากการประมาณมีค่าเท่ากับพอดีกับค่าที่เป็นข้อมูลจริง แสดงถึงแบบจำลองที่ประมาณได้เป็นแบบจำลองที่เป็นตัวแทนข้อมูลจริงได้อย่างดีที่สุดในขณะที่ถ้า U มีค่าเท่ากับหนึ่ง แปลว่าแบบจำลองที่ประมาณได้เป็นแบบจำลองที่ไม่ดีที่สุด ดังนั้นวิธีการพิจารณาค่าสถิตินี้ให้เลือกจากแบบจำลองที่มีค่า U ที่น้อย ๆ ดังจะพิจารณาได้จากสมการที่ (13)

$$U = \frac{\sqrt{\frac{1}{T} \sum_{t=1}^T (Y_t^w - Y_t^a)^2}}{\sqrt{\frac{1}{T} \sum_{t=1}^T (Y_t^s)^2 + \frac{1}{T} \sum_{t=1}^T (Y_t^a)^2}} \quad (13)$$

กำหนดให้ Y_t^s คือ ค่าที่ประมาณจากแบบจำลอง
 Y_t^a คือ ค่าข้อมูลจริง
 T คือ จำนวนของคาบเวลาที่ใช้ในการประมาณแบบจำลอง

1.3 ค่า Adjusted R^2

ค่า Adjusted R^2 คือ การวัดค่าตัวแปรอิสระสามารถอธิบายตัวแปรตามได้ดีเพียงใด หากค่านี้เท่ากับ 1 ก็หมายความว่าตัวแปรอิสระสามารถอธิบายตัวแปรตามได้ 100 % ในทางกลับกัน หากค่านี้มีค่าเท่ากับ 0 แปลความหมายว่าตัวแปรอิสระไม่สามารถอธิบายตัวแปรตามได้เลย แต่อย่างไรก็ตาม พบว่าหากมีการเพิ่มตัวแปรอิสระเข้าไปในสมการมาก ๆ ก็จะทำให้ค่า R^2 มากขึ้นด้วย ซึ่งนับเป็นข้อจำกัดของค่าสถิตินี้ โดยสามารถพิจารณาในรูปแบบสมการได้จากสมการที่ (14) ดังนั้นเพื่อปรับปรุงข้อจำกัดข้างต้น จึงเกิดค่าสถิติใหม่ คือค่า Adjusted R^2 (\bar{R}^2) ซึ่งจะมีการผูกพันกันระหว่างตัวแปรที่เพิ่มเข้าไปกับค่า R^2 ที่ได้เพิ่มขึ้นมา ดังแสดงในสมการที่ (15)

$$R^2 = 1 - \frac{\sum \hat{u}_i^2}{\sum y_i^2} \quad (14)$$

$$\bar{R}^2 = 1 - \frac{\sum \hat{u}_i^2 / (n - k)}{\sum y_i^2 / (n - 1)} \quad (15)$$

1.4 ค่า Akaike Information Criterion (AIC)

ค่า Akaike Information Criterion (AIC) คือ ค่าสถิติที่ประยุกต์คล้ายกับ \bar{R}^2 แต่ใช้รูปแบบการใส่ค่าลอการิทึมฐานธรรมชาติ (Natural logarithm) โดยหากค่าสถิตินี้มีค่าน้อยเพียงใด นั่นก็แปลว่าแบบจำลองที่ประมาณได้นั้นสามารถเป็นตัวแทนข้อมูลจริงได้ดีเพียงนั้น ทั้งนี้ค่าสถิติที่เหมาะสมที่จะนำไปใช้ในการหาค่าย้อนหลัง (Lag Length) ที่เหมาะสมอีกด้วย ซึ่งแสดงในสมการที่ (16)

$$\ln AIC = \left(\frac{2k}{n} \right) + \ln \left(\frac{\sum \hat{u}_i^2}{n} \right) \quad (16)$$

กำหนดให้ $\sum \hat{u}_i^2$ คือ ผลรวมของค่าความคลาดเคลื่อน

n คือ ค่าสังเกตทั้งหมด

จากค่าสถิติข้างต้นทั้งหมดจะนำมาใช้ประกอบในการพิจารณาเลือกแบบจำลอง ARIMA (p, d, q) ที่เหมาะสมที่สุด โดยจะคัดเลือกแบบจำลองในขั้นตอนนี้ไว้ 3 – 4 แบบจำลอง เพื่อทำการเลือกอีกครั้งเพื่อที่จะเปรียบเทียบว่าแบบจำลองใดจะมีความสามารถในการพยากรณ์มากที่สุด

2. การประมาณค่าพารามิเตอร์ (Parameter estimation)

การประมาณค่าพารามิเตอร์ คือการประมาณค่าสัมประสิทธิ์ที่มาจากรูปแบบการถดถอยในตัวเอง (AR) และรูปแบบการเคลื่อนที่ของค่าคลาดเคลื่อน (MA) โดยสามารถเลือกใช้วิธีการถดถอยเชิงเส้นอย่างง่าย (Simple Least Square) แต่สามารถที่จะใช้วิธีการถดถอยแบบไม่เป็นเชิงเส้น (Nonlinear) เพื่อสร้างความสัมพันธ์ของสมการที่จะสามารถนำไปใช้ในการพยากรณ์ได้ หากรูปแบบความสัมพันธ์นั้นเป็นรูปแบบที่มีความเหมาะสมที่สุด

3. การตรวจสอบความถูกต้อง (Diagnostics)

การตรวจสอบแบบจำลอง เมื่อกำหนดรูปแบบและประมาณค่าพารามิเตอร์ในแบบจำลอง จะต้องตรวจสอบทุกครั้งว่ารูปแบบที่กำหนดนั้นมีความเหมาะสมจริงหรือไม่ การตรวจสอบจะทำได้หลายวิธี ยกตัวอย่าง เช่น การพิจารณาคอเรลโลแกรมของอัตรสหสัมพันธ์ของกลุ่มตัวอย่าง (ρ_k) แต่อย่างไรก็ตาม Gujarati (2003) ได้เสนอการทดสอบวิเคราะห์ความเหมาะสมของแบบจำลอง โดยใช้การทดสอบของ Box และ Pierce ซึ่งจะแสดงได้โดยใช้ Q statistic ดังในสมการที่ (15)

$$Q = n \sum_{k=1}^m \rho_k^2 \quad (17)$$

กำหนดให้ n คือจำนวนของข้อมูล

m คือค่า Lag Length

จากสมการที่ (15) ค่า Q นั้นจะพบว่ามีแจกแจงเป็นแบบ Chi-square ที่มีดีกรีเท่ากับ m ซึ่งอยู่ภายใต้ข้อสมมติฐานว่า สมมติฐานว่าง คือค่าความคลาดเคลื่อนที่ได้จากการประมาณมีลักษณะเป็น White Noise นั่นก็แปลว่าแบบจำลองมีลักษณะปราศจากอัตรสหสัมพันธ์ (Autocorrelation) ดังนั้นหากตรวจสอบพบว่าแบบจำลองนั้นปราศจากอัตรสหสัมพันธ์แล้ว จะใช้แบบจำลองนั้นในการพยากรณ์ต่อไป แต่หากแบบจำลองนั้นไม่เหมาะสมต้องทำตามขั้นตอนที่ 1 เพื่อกำหนดรูปแบบจำลองใหม่

4. การพยากรณ์ (Forecasting)


การพยากรณ์จะทำได้ทั้งแบบจุด (Point Forecast) และแบบช่วง (Interval Forecast) ซึ่งการพยากรณ์ควรจะเป็นการพยากรณ์ในช่วงระยะเวลาสั้นๆ เพื่อความเหมาะสมกับเครื่องมือทางเศรษฐมิติ ในการศึกษาค้นคว้าครั้งนี้คือ อาริมา

ขั้นตอนต่าง ๆ ในการพยากรณ์ซึ่งสามารถแบ่งได้ 3 ขั้นตอนดังนี้

4.3 Estimation Period หมายถึง การใช้แบบจำลองเพื่อคาดคะเนในช่วงข้อมูลตั้งแต่ T_1 ถึง T_2 จากข้อมูลทั้งหมดที่มีถึง T_2

4.3 Ex-Post Forecast หมายถึง การพยากรณ์โดยใช้ข้อมูล T_2 ถึง ข้อมูลปัจจุบัน T_3 เพื่อเปรียบเทียบความแม่นยำในการพยากรณ์ของแต่ละแบบจำลอง โดยนำค่าพยากรณ์ที่ได้มาเปรียบเทียบกับข้อมูลที่เราถืออยู่จริง

4.3 Ex-ante Forecast หมายถึง การพยากรณ์ในช่วงเวลาต่อไปถัดจาก T_3 เป็นต้นไป



ภาพ 3.2 แสดงช่วงเวลาที่ใช้ในการพยากรณ์ (Pindyck and Rubinfeld, 1997)

3.2 ระเบียบวิธีวิจัย

การพยากรณ์ปริมาณการซื้ออาหารจากฝ่ายโภชนาการระหว่างประเทศ บริษัท การบินไทย จำกัด (มหาชน) โดยวิธี ARIMA เป็นการนำเอาข้อมูลอนุกรมเวลามาหารูปแบบแบบจำลองที่เหมาะสมที่สุด โดยมีขั้นตอนดังนี้

1. การหาลอการิทึมธรรมชาติ (Natural Logarithm : ln) ข้อมูลอนุกรมเวลาปริมาณการซื้ออาหาร และ X_t ได้ถูกเปลี่ยนเป็น Q_t ตัวแปรที่จะใช้ในสมการต่างๆจึงถูกเปลี่ยนเป็น $\ln Q_t$

2. การทดสอบความนิ่งของข้อมูล เป็นการพิจารณาว่าข้อมูลอนุกรมเวลามีลักษณะนิ่งหรือไม่ โดยการทดสอบ Unit Root ดังสมการต่อไปนี้

$$\Delta Q_t = \theta Q_{t-1} + \sum_{i=1}^p \phi_i \Delta Q_{t-i} + \varepsilon_t \quad (18)$$

$$\Delta Q_t = \alpha + \theta Q_{t-1} + \sum_{i=1}^p \phi_i \Delta Q_{t-i} + \varepsilon_t \quad (19)$$

$$\Delta Q_t = \alpha + \beta t + \theta Q_{t-1} + \sum_{i=1}^p \phi_i \Delta Q_{t-i} + \varepsilon_t \quad (20)$$

3. การกำหนดรูปแบบแบบจำลอง (Identification) ARIMA (p,d,q) โดยการพิจารณาคอเรลโลแกรม Autocorrelation Function (ACF) และ Partial Autocorrelation Function (PACF) เพื่อจะสามารถระบุว่าเป็นแบบจำลองควรมี Autoregressive (p) เท่าใด และ Moving Average (q) เท่าใด โดยจะเลือกมาเพื่อหาแบบจำลองที่เหมาะสมที่สุด

4. การประมาณค่าพารามิเตอร์ เพื่อที่จะนำค่าที่ได้ไปทำการพยากรณ์ปริมาณซื้อในอนาคตได้

5. การตรวจสอบความถูกต้อง ทำการทดสอบโดยพิจารณาจากค่า Q-Statistic จากคอเรลโลแกรมของอดีตสหสัมพันธ์ของกลุ่มข้อมูลตัวอย่าง

6. การพยากรณ์ ทำได้โดยการแบ่งการพยากรณ์ออกเป็น 3 ช่วง คือ Historical Forecast คือ ตั้งแต่เดือนมกราคม ค.ศ. 1999 ถึงเดือนกันยายน ค.ศ. 2003, Ex-post Forecast ตั้งแต่เดือนตุลาคม ค.ศ. 2003 ถึงเดือนธันวาคม ค.ศ. 2003 และ Ex-ante Forecast ตั้งแต่เดือนมกราคม ค.ศ. 2004 ถึงเดือนมีนาคม ค.ศ. 2004