

บทที่ 3

กรอบแนวคิดและระเบียบวิธีวิจัย

3.1 กรอบทฤษฎีแนวคิดของการศึกษา

การศึกษานี้จะทำการพยากรณ์ราคาผลิตภัณฑ์มันสำปะหลังที่คาดว่าจะเกิดขึ้นในอนาคต โดยใช้วิธีของบอคซ์แอนด์เจนกินส์ โดยการพยากรณ์จะนำอนุกรมเวลาในอดีตมาพยากรณ์อนุกรมเวลาในอนาคต ซึ่งเป็นวิธีการพยากรณ์ที่ให้ค่าความถูกต้อง (Accuracy) สูงกว่าวิธีอื่นในการพยากรณ์ระยะสั้น (Short term forecasting) และต้องใช้ข้อมูลอนุกรมเวลา (Time series data) ที่มีลักษณะนิ่ง (Stationary) โดยในการศึกษานี้ทำการทดสอบ Unit Root ก่อนที่จะทำการพยากรณ์โดยวิธีอาเรโน เพื่อให้ค่าความคลาดเคลื่อนจากการพยากรณ์ลดลง เนื่องจากข้อมูลสินค้าเกษตรที่เป็นอนุกรมเวลา (Time series data) ตัวนามากมีลักษณะไม่นิ่ง (Non-stationary)

3.1.1 การทดสอบความนิ่งของข้อมูลอนุกรมเวลา (Unit Root Test)

การทดสอบ Unit Root ของตัวแปรที่ใช้ในการศึกษานี้ของจากข้อมูลอนุกรมเวลา (Time series data) นักจะมีความไม่นิ่งของข้อมูล (Non-stationary) ซึ่งการนำข้อมูลที่ไม่นิ่ง (Non-stationary) มาใช้ในสมการ回帰แบบห้ามสมมุติจะทำให้เกิดความสัมพันธ์ที่ไม่แท้จริง (Spurious Regression) กล่าวคือค่าสถิติ R^2 มีค่าสูงมากและได้ค่าสถิติ t (T-statistic) มีนัยสำคัญหรือสูงเกินกว่าความเป็นจริงและ F-statistic ที่ได้จากการทดสอบที่เกิดความสัมพันธ์ที่ไม่แท้จริง (Spurious Regression) จะไม่ถูกต้องและไม่ควรนำมาใช้ เพราะมีการกระจายที่ไม่ได้มาตรฐานและตัวประมาณค่าที่ได้จากการ OLS จะไม่สามารถเชื่อถือได้ (Enders, 1995) โดยตัวแปรที่มีลักษณะนิ่ง (Stationary) จะมีคุณสมบัติ 3 ประการดังนี้

ค่าเฉลี่ย (Mean)

$$E(Y_t) = \mu$$

ความแปรปรวน (Variance)

$$\text{Var}(Y_t) = E(Y_t - \mu)^2 = \sigma^2$$

ความแปรปรวนร่วม (Covariance)

$$E[(Y_t - \mu)(Y_{t+k} - \mu)] = \gamma_k$$

โดยที่ Y_t คือ ตัวแปรที่มีลักษณะนิ่ง (Stationary)

การทดสอบ Unit Root เพื่อคุณภาพนิ่ง (Stationary) หรือความไม่นิ่ง (Non-stationary) ของข้อมูลจาก การศึกษาส่วนใหญ่ที่ผ่านมาจะนิยมการทดสอบ Unit Root โดยเป็นที่รู้จักกันดีในชื่อของ Dickey-Fuller test ซึ่งสามารถแบ่งออกได้เป็น 2 วิธี คือ

1) Dickey - Fuller Test (DF)

ทำการทดสอบตัวแปรที่เคลื่อนไหวไปตามช่วงเวลา มีลักษณะเป็น Autoregressive model โดยสามารถเขียนรูปแบบของสมการได้ออกเป็น 3 รูปแบบคือ

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

$$\text{กรณีตัวแปรมีค่าคงที่} \quad X_t = \alpha_0 + \rho X_{t-1} + \varepsilon_t \quad (2)$$

$$\text{กรณีตัวแปรมีทั้งค่าคงที่และแนวโน้มเวลา} \quad X_t = \alpha_0 + \alpha_2 t + \rho X_{t-1} + \varepsilon_t \quad (3)$$

โดยที่ X_t คือตัวแปรที่เราทำการศึกษา α_0, ρ คือค่าคงที่ t คือแนวโน้มเวลา ε_t คือตัวแปรสุ่ม มีการแจกแจงแบบปกติที่เป็นอิสระต่อกันและเหมือนกัน (Independent and Identical distribution) โดยมีค่าเฉลี่ยเท่ากับ 0 และค่าความแปรปรวนคงที่ เอียงแทนด้วยสัญญาลักษณ์ $\varepsilon_t \sim iid (0, \sigma_\varepsilon^2)$

ในการทดสอบว่า X_t มีลักษณะเป็น Stationary process [$X_t \sim I(0)$] หรือไม่ ทำการทดสอบโดยการแปลงสมการทั้งสามรูปแบบให้อยู่ในรูปของ First differencing (ΔX_t) ได้ดังนี้

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

$$\Delta X_t = X_t - X_{t-1} = \alpha_0 + \theta X_{t-1} + \varepsilon_t \quad (5)$$

$$\Delta X_t = X_t - X_{t-1} = \alpha_0 + \alpha_2 t + \theta X_{t-1} + \varepsilon_t \quad (6)$$

โดยที่ $\theta = (\rho - 1)$

2) Augmented Dickey-Fuller Test (ADF)

เป็นการทดสอบ Unit Root อีกวิธีหนึ่งที่พัฒนามาจาก DF Test เนื่องจากวิธี DF ไม่สามารถทำการทดสอบตัวแปรในกรณีที่มี Serial correlation ในค่า Error term (ε_t) ที่มีลักษณะความสัมพันธ์กันของในระดับสูง ซึ่งจะมีการเพิ่ม Lagged change $\left[\sum_{j=1}^p \lambda_j \Delta X_{t-j} \right]$ เข้าไปในสมการทางด้านขวามือ จะได้ว่า

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

$$\Delta X_t = X_t - X_{t-1} = \alpha_0 + \theta X_{t-1} + \sum_{j=1}^p \lambda_j \Delta X_{t-j} + \varepsilon_t \quad (8)$$

$$\Delta X_t = X_t - X_{t-1} = \alpha_0 + \alpha_2 t + \theta X_{t-1} + \sum_{j=1}^p \lambda_j \Delta X_{t-j} + \varepsilon_t \quad (9)$$

ซึ่งพจน์ที่ใส่เข้าไปนั้น จำนวน Lagged term (p) ก็ขึ้นอยู่กับความเหมาะสมของข้อมูลอนุกรมเวลาของแต่ละงานวิจัย หรือต้องใส่จำนวน Lag เข้าไปกระทั้งไม่เกิดปัญหา Autocorrelation ในส่วนของ Error term (Pindyck and Rubinfeld, 1998)

สำหรับการเลือก Lag Length (P-lag) ที่เหมาะสมในการทดสอบ Unit Root ของตัวแปรนั้น Walter Enders (1995) กล่าวว่า ควรเริ่มต้นจาก Lag Length ที่สูงพอ เช่น P^* และคุณว่าสัมประสิทธิ์ของ Lag Length P^* แตกต่างจากศูนย์อย่างมีนัยสำคัญทางสถิติหรือไม่ โดยดูจากค่า t-statistic ถ้าพบว่าสัมประสิทธิ์ของ Lag Length P^* นั้น ไม่แตกต่างจากศูนย์อย่างมีนัยสำคัญทางสถิติก็ทำการทดสอบ Unit Root ของตัวแปรนั้นโดยใช้ Lag Length P^*-1 จนกระทั่ง Lag length ที่ใช้นั้นจะแตกต่างจากศูนย์อย่างมีนัยสำคัญทางสถิติ

โดยในการทดสอบสมมุติฐานทั้งวิธี Dickey-Fuller test และวิธี Augmented Dickey-Fuller test ทดสอบว่าตัวแปรที่เราสนใจ (X_t) นั้นมี Unit Root หรือไม่ สามารถพิจารณาได้จากค่า θ ถ้าค่า θ มีค่าเท่ากับ 0 แสดงว่า X_t นั้นมี Unit Root ซึ่งสามารถเขียนสมมติฐานในการทดสอบได้ดังนี้

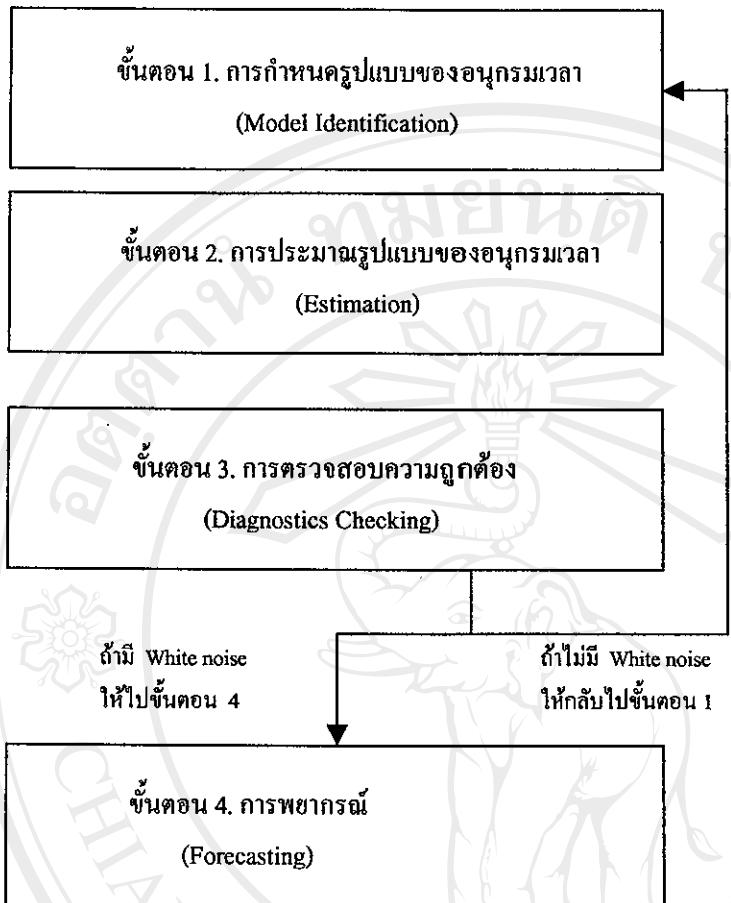
$$H_0 : \theta = 0$$

$$H_1 : \theta < 0$$

จากสมมติฐานถ้ายอมรับ H_0 แสดงว่า ข้อมูลมีลักษณะไม่มั่นคง (Non-stationary) แต่ถ้าปฏิเสธ H_0 แสดงว่า ข้อมูลนั้นมีลักษณะนิ่ง (Stationary)

3.1.2 วิธีการพยากรณ์ โดยวิธีของ Box และ Jenkins

ซึ่งเมื่อข้อมูลมีลักษณะนิ่งแล้วก็จะทำการพยากรณ์ โดยวิธีของ Box และ Jenkins ซึ่งมี 4 ขั้นตอนสามารถแสดงได้ดังนี้



รูปที่ 3.1 แสดงขั้นตอนการพยากรณ์โดยวิธีของ Box และ Jenkins

ขั้นตอน 1 การกำหนดรูปแบบของอนุกรมเวลา (Identification) ให้กับอนุกรมเวลาที่เป็น Stationary Series เป็นการหารูปแบบ ARIMA (p,q) ที่คาดว่าจะเหมาะสมให้กับอนุกรมเวลา โดยที่ Autocorrelation : P_k คือการวัดความสัมพันธ์ของแต่ละช่วงเวลา โดยมีช่วงเวลาที่ย้อนหลังไป k หน่วยเวลา โดยที่ P_k มีค่าเท่ากับ $-1 \leq P_k \leq 1$ โดยพิจารณาเปรียบเทียบค่า Autocorrelation (r_k) ของอนุกรมเวลาตัวอย่าง กับค่า Autocorrelation (P_k) ของอนุกรมเวลาของประชากร ที่มีช่วงเวลาเดียวกันหลังไป k หน่วยเวลา ซึ่งมีสูตรดังนี้

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

$$\text{โดยที่ } Y_t = \sum_{t=a}^n (Y_t) \\ q = \text{จำนวนเวลาสุดท้ายที่ข้อนหลัง}$$

Partial Autocorrelation : p_{kk} กือการวัดความสัมพันธ์ของแต่ละช่วงเวลา โดยมีช่วงเวลาที่ข้อนหลังไป k หน่วยเวลา โดยพิจารณาเปรียบเทียบค่า Partial Autocorrelation (r_{kk}) ของอนุกรมเวลาตัวอย่างกับค่า Partial Autocorrelation (p_{kk}) ของอนุกรมเวลาของประชากร ที่มีช่วงเวลาข้อนหลังไป 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 p_k และ p_{kk} พร้อมกัน หลาย ๆ ค่า ซึ่งมักจะพิจารณาจากรูปที่เรียกว่า คอลอเรโลแกรม (Correlogram) ที่ได้จากการพล็อต r_k, r_{kk}, p_k และ p_{kk} ในช่วงเวลา k ดังนั้นการพิจารณาเปรียบเทียบ จะเป็นการเปรียบเทียบ Correlogram ของค่า Autocorrelation ของอนุกรมเวลาตัวอย่าง (r_k) กับค่า Autocorrelation ของอนุกรมเวลาตัวอย่าง (r_{kk}) กับค่า Partial Autocorrelation ของอนุกรมเวลาประชากร (p_k) และ Correlogram ของค่า Partial Autocorrelation ของอนุกรมเวลาประชากร (p_{kk}) สำหรับแต่ละรูปแบบจะมี Correlogram ของ p_k และ p_{kk} ต่างกัน อนุกรมเวลาที่จะนำมากำหนดรูปแบบจะต้องเป็น อนุกรมเวลาที่ Stationary หากไม่เป็น Stationary จะต้องแปลงให้เป็น Stationary เสียก่อน

วิธีการวิเคราะห์อนุกรมเวลาของ Box – Jenkins เป็นการวิเคราะห์อนุกรมเวลาโดยการหา รูปแบบที่เหมาะสมให้กับอนุกรมเวลา โดยใช้ค่า Autocorrelation Function (ACF) และค่า Partial Autocorrelation Function (PACF) เป็นหลักในการพิจารณาและรูปแบบที่เดือกใช้จะอยู่ในกลุ่มของ รูปแบบ ARIMA (p,d,q) หรือเรียก Integrated Autoregressive – Moving Average order p and q ซึ่งเป็นรูปแบบที่กำหนดค่า parameter ในอนาคตเป็นค่าที่ได้จากการสังเกตหรือค่า parameter ก่อนหน้า และความคลาดเคลื่อนของการพยากรณ์ก่อนหน้า โดยเป็นการรวมส่วนของรูปแบบ AR(p) และรูปแบบ MA(q) เช้าด้วยกัน รูปแบบ AR(p) หมายถึงรูปแบบที่แสดงว่าค่าสังเกต Y_t จะขึ้นอยู่ กับค่า $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$ หรือค่าสังเกตที่เกิดขึ้นก่อนหน้า p ค่า ส่วนรูปแบบ MA (q) หมายถึงรูปแบบที่แสดงว่าค่าสังเกต Y_t จะต้องอยู่กับค่าของความคลาดเคลื่อน $\epsilon_{t-1}, \epsilon_{t-2}, \dots, \epsilon_{t-q}$ หรือค่าความคลาดเคลื่อนที่เกิดขึ้นก่อนหน้า q ค่าซึ่งรูปแบบ AR MA (p, q) โดยมีการกำหนดรูปแบบดังนี้

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

อนุกรมเวลาที่จะนำมาศึกษาเพื่อประโยชน์ในการพยากรณ์นี้ การเคลื่อนไหวของอนุกรมเวลาขึ้นอยู่กับส่วนประกอบต่าง ๆ ได้แก่ แนวโน้ม (Trend) ตัวแปรฤดูกาล (Seasonal factor) ตัวแปรวัฏจักร (Cyclical factor) และเหตุการณ์ที่ผิดปกติ (Irregular Movement) โดยวิธี Box – Jenkins จะสามารถแบ่งอนุกรมเวลาออกเป็น 2 ประเภทดังนี้

1) อนุกรมเวลาที่เป็น Stationary Series คืออนุกรมเวลา (Y_t) ที่มีค่าเฉลี่ยและค่าความแปรปรวนของ Y_t คงที่ นั่นคือค่าเฉลี่ย $E(Y_t)$ และค่าความแปรปรวน $V(Y_t)$ มีค่าคงที่สำหรับอนุกรมแต่ละอนุกรมเวลา ซึ่งอนุกรมเวลาที่มีแนวโน้มและ/หรืออิทธิพลฤดูกาลจะมีค่าเฉลี่ย $E(Y_t)$ ไม่คงที่และอนุกรมเวลาที่มีความแปรปรวนของ Y_t สูงจะเป็นลักษณะของอนุกรมเวลาที่ $V(Y_t)$ มีค่าไม่คงที่ซึ่งเรียกอนุกรมเวลาดังกล่าวว่า อนุกรมเวลาที่ไม่เป็น Stationary Series นอกจากนั้non อนุกรมเวลาที่เป็น Stationary Series จะเป็นอนุกรมเวลาที่มีค่าเฉลี่ยและความแปรปรวนคงที่แล้วยังจะต้องมีค่าสัมประสิทธิ์สหสัมพันธ์แบบอโศกที่ lag k ขึ้นอยู่กับค่า k อย่างเดียว อนุกรมเวลาที่กำหนดรูปแบบ ARMA(p,q) ได้จะต้องเป็นอนุกรมเวลาที่เป็น Stationary Series แล้ว

2) อนุกรมเวลาที่ไม่เป็น Stationary Series เป็นอนุกรมเวลาที่ไม่มีคุณสมบัติเป็น Stationary Series การจะหารูปแบบ ARMA (p,q) ให้กับอนุกรมเวลาดังกล่าว ได้จะต้องแปลงอนุกรมเวลาดังกล่าวให้เป็นอนุกรมเวลาใหม่ที่มีคุณสมบัติ Stationary Series เสียงก่อน การแปลงอนุกรมเวลาที่ไม่เป็น Stationary Series ให้เป็นอนุกรมเวลาที่เป็น Stationary Series อาจทำได้ด้วยวิธีการต่าง ๆ ดังนี้

2.1) การหาผลต่างปกติ (Regular differencing) ของอนุกรมเวลาเพื่อกำจัดแนวโน้มนั่นคือถ้าอนุกรมเวลา (Y_t) มีแนวโน้มอยู่ในอนุกรมเวลาจะแปลงให้เป็นอนุกรมเวลาใหม่ที่ไม่มีแนวโน้ม (Z_t) โดย $Z_t = \Delta^d Y_t$ โดย d เป็นลำดับของการหารผลต่างและ Δ คือผลต่างของตัวแปร เช่น เมื่อ $d = 1$ จะได้ $Z_t = \Delta Y_t = Y_t - Y_{t-1}$ เมื่อ $d = 2$ จะได้ $Z_t = \Delta^2 Y_t = \Delta (Y_t - Y_{t-1}) = \Delta Y_t - \Delta Y_{t-1} = Y_t - 2Y_{t-1} + Y_{t-2}$ เป็นต้นจำนวนครั้งที่หาผลต่างจะขึ้นอยู่กับว่าเมื่อหาผลต่างแล้วอนุกรมเวลาใหม่เป็น Stationary Series หรือไม่ ถ้ายังไม่เป็น Stationary Series ต้องหาผลต่างต่อไปโดยทั่วไปถ้าอนุกรมเวลามีแนวโน้มเป็นแบบเส้นตรงจะใช้ $d = 1$ อนุกรมเวลาที่มีแนวโน้มเป็นแบบคงคลิก จะใช้ $d = 2$

2.2) การหาผลต่างถูกกาล ของอนุกรมเวลา ถ้าอนุกรมเวลา มีตัวแปรถูกกาลเข้ามาเกี่ยวข้อง จะต้องแปลงอนุกรมเวลาเดิม (Y_t) ให้เป็นอนุกรมใหม่ที่ไม่มีถูกกาล (Z_t) โดย $Z_t = \Delta_L^D Y_t$ โดย D เป็นลำดับของการหาผลต่างถูกกาล และ L เป็นจำนวนถูกกาลต่อปี เช่น สำหรับอนุกรมเวลารายเดือน ($L = 12$) เมื่อ $D = 1$ จะได้ $Z_t = \Delta_{12} Y_t$ หรือ $Z_t = Y_t - Y_{t-12}$ และเมื่อ $D = 2$ จะได้ $Z_t = \Delta_{12}^2 Y_t$ หรือ $Z_t = \Delta^2(Y_t - Y_{t-12}) = Y_t - 2Y_{t-1} + Y_{t-24}$ เป็นต้น ผลต่างนี้จะทำกีรังขึ้นกับว่าเมื่อหาผลต่างแล้วอนุกรมเวลาใหม่เป็น Stationary Series หรือไม่ถ้ายังไม่เป็น Stationary Series ต้องหาผลต่างต่อไป

2.3) การหาผลต่างปกติและผลต่างถูกกาล กรณีที่อนุกรมเวลาไม่ทึ้งแนวโน้มและตัวแปรถูกกาล การปรับให้อนุกรมเวลาเป็น Stationary Series นั้นจะทำได้โดยการหาผลต่างปกติและผลต่างถูกกาล d และ D ควบคู่กันไปซึ่งค่า d เป็นลำดับของการหาผลต่างปกติ และค่า D เป็นลำดับของการหาผลต่างถูกกาล โดยที่ค่า d และ D จะมีค่าเท่าไรนั้นขึ้นอยู่กับว่าเมื่อหาผลต่างและผลต่างถูกกาลแล้วอนุกรมเวลาใหม่เป็น Stationary Series หรือไม่ ถ้ายังไม่เป็น Stationary Series ต้องหาผลต่างต่อไปเช่น อนุกรมเวลารายเดือน ที่มีทึ้งแนวโน้มและถูกกาล เมื่อ $d = 1$ และ $D = 1$ จะแปลงอนุกรมเวลาเดิม (Y_t) ให้เป็นอนุกรมเวลาใหม่ (Z_t) โดย $Z_t = \Delta \Delta_{12} Y_t = \Delta(Y_t - Y_{t-1} - Y_{t-12} + Y_{t-13})$ เป็นต้น

2.4) การหาผลการวิเคราะห์ของค่าสัมเกตในอนุกรมเวลา นั่นคือแปลงอนุกรมเวลาเดิม (Y_t) ให้เป็นอนุกรมเวลาใหม่ (Z_t) โดย $Z_t = \ln(Y_t)$ การแปลงนี้ทำเพื่อความแปรปรวนของอนุกรมเวลาไม่คงที่ นั่นคือ $V(Y_t)$ สำหรับค่าเวลา t ต่าง ๆ

โดยการพิจารณา ACF และ PACF ซึ่งสามารถระบุได้ว่าแบบจำลองจะมี Autoregressive (p), Differencing (d) และ Moving average (q) ที่ลำดับเท่าใด โดยจะพิจารณาจากตาราง 3.1

ตาราง 3.1 แสดงการพิจารณา ACF และ PACF

ชนิดของแบบจำลอง	รูปแบบของ ACF	รูปแบบของ PACF
AR(p)	- โค้งสูงเข้าหาแกน	- เกิดค่าที่ชัดเจนเพียง p ค่าแรก หายไป
MA(q)	- เกิดค่าที่ชัดเจนเพียง q ค่าแรก หายไป	- โค้งสูงเข้าหาแกน
ARMA(p,q)	- โค้งสูงเข้าหาแกน	- โค้งสูงเข้าหาแกน

ที่มา: Gujarati (2003)

จากตาราง 3.1 สามารถกำหนดค่าหน่วยแบบของแบบจำลองได้ โดยหากค่า residual โปรแกรมของ ACF มีลักษณะ โค้งสูงเข้าหาแกนในระบบ ในขณะที่ค่า residual โปรแกรม PACF เกิดมีค่าขึ้นมาไม่กี่ค่าแล้วก็หายไป จำนวนของแท่งของค่าที่เกิดขึ้นมา ให้นับเป็นค่าที่ p ของ AR (p) ตัวอย่างเช่น เมื่อพิจารณาค่า residual โปรแกรมของ ACF ที่โค้งสูงเข้าหาแกนระบบ และ PACF ที่มีแท่งค่า residual โปรแกรมเกิดขึ้นหนึ่งแท่ง แสดงว่าแบบจำลองนี้ลักษณะเป็น AR(1) สำหรับ MA(q) นั้นก็จะมี ACF ที่เกิดขึ้นมาไม่กี่ค่าแล้วหายไป ในขณะที่ PACF โค้งสูงเข้าหาแกนระบบนั้น ตัวอย่างเช่น หากค่า ACF เกิดแท่งค่า residual โปรแกรมขึ้น เพียงสองแท่งและหลังจากนั้นก็หายไป ในขณะที่ PACF โค้งสูงเข้าหาแกนระบบทั้งคู่ก็แสดงว่า แบบจำลองนี้ลักษณะเป็น MA(2) และถ้าหาก ACF และ PACF โค้งสูงเข้าหาแกนระบบทั้งคู่ก็แสดงว่า แบบจำลองนี้ลักษณะเป็น ARMA(p,q) และเมื่อร่วมกับการทดสอบความนิ่ง (Stationary) ในขั้นตอนแรกแล้วจะสามารถหาค่าของ Difference ได้ซึ่งผลจากการ Difference จำนวน d ครั้งนั้นก็จะได้แบบจำลองมีลักษณะเป็น ARIMA (p,d,q)

ขั้นตอน 2 การประมาณรูปแบบของอนุกรมเวลา (estimation) จะทำได้โดยการหาค่า ประมาณแบบง่ายหรือค่าประมาณที่ได้จากการวิเคราะห์ตัวเลข (numerical analysis) สำหรับค่า ประมาณ แบบง่ายจะทำโดยการสร้างสมการที่มาจากการความสัมพันธ์ระหว่าง p_k และ พารามิเตอร์ โดยสมการที่สร้างขึ้นจะมีจำนวนเท่ากับจำนวนพารามิเตอร์ที่ต้องการประมาณ จำนวนค่าประมาณที่ได้จากการวิเคราะห์ตัวเลขจะได้จากการแก้สมการที่สร้างขึ้นจากวิธีกำลังสองน้อยที่สุด ขั้นตอนของ การวิเคราะห์ตัวเลขจะต้องมีการกำหนดค่าประมาณเริ่มต้น ซึ่งส่วนใหญ่จะใช้การประมาณแบบง่าย เป็นค่าประมาณเริ่มต้นเมื่อการวิเคราะห์สิ้นสุดจะได้ค่าประมาณสุดท้ายที่จะนำไปใช้ประโยชน์ในการ สร้างสมการพยากรณ์

โดยพิจารณา

- **Adjusted R² (R²)** เป็นการอธิบายว่ารูปแบบจำลองที่ได้สามารถอธิบายตัวแปรได้มาก น้อยแค่ไหน

$$R^{-2} = 1 - \frac{RSS/(n-k)}{TSS/(n-1)} = 1 - (1 - R^2) \frac{n-1}{n-k}$$

- **Durbin-Watson statistic (DW)** ใช้ทดสอบ Autocorrelation แสดงความนิสัยสัมพันธ์ใน ตัวของโดยค่า DW เข้าใกล้ 2 ถือว่าไม่มีสหสัมพันธ์ในตัวเอง

- Akaike Information Criterion (AIC) เป็นการอธิบายว่ารูปแบบจำลองที่ได้มีค่าความคาดเคลื่อนของผลการพยากรณ์มากน้อยแค่ไหน

$$AIC = e^{2k/n} \frac{\sum u_i^2}{n} = e^{2k/n} \frac{RSS}{n} = e^{2k/n} \frac{\sum u_i^2}{n} = e^{2k/n} \frac{RSS}{n}$$

โดยที่ n = จำนวนของค่าสังเกต

k = จำนวนของพารามิเตอร์ที่ทำการประมาณค่า

- F-Statistic เป็นการคุณความผันแปรของตัวมันเองผันแปรต่อตัวมันเอง

ขั้นตอน 3 การตรวจสอบความถูกต้อง (Diagnostic checking) เมื่อกำหนดรูปแบบและประมาณค่าพารามิเตอร์ในแบบจำลองแล้ว จะต้องตรวจสอบทุกครั้งว่ารูปแบบที่กำหนดนั้นมีความเหมาะสมจริงหรือไม่ การตรวจสอบจะทำได้หลายวิธี ได้แก่ การพิจารณาค่าโอลิเกรมของ r_k หรือ โดยพิจารณา White noise ของค่าประมาณการความคาดเคลื่อน(estimated residual : e_t) ของรูปแบบอนุกรมเวลา (Box-Pierce, 2003) โดยพิจารณาจาก

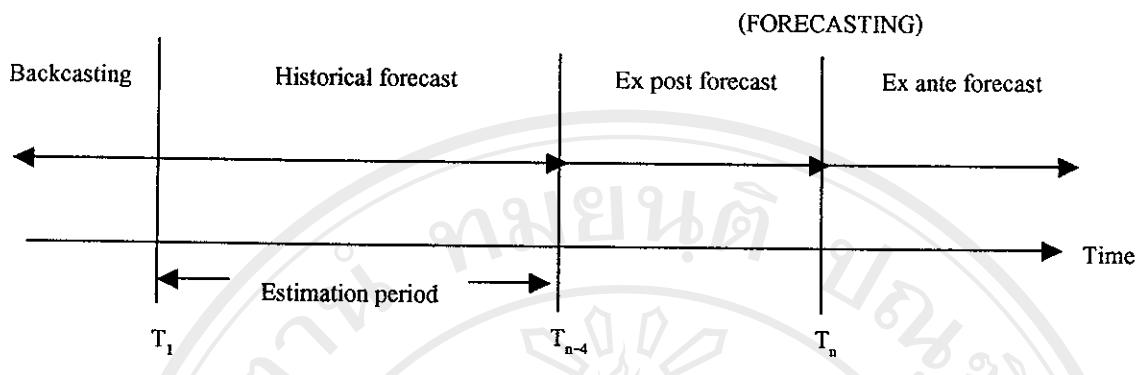
$$Q\text{-statistic} = n \sum_{k=1}^m \rho_k^2$$

โดยที่ m = ค่า Lag Length

n = จำนวนของตัวอย่าง

หากพบว่า ค่า Q-statistic ของแบบจำลอง ไม่แตกต่างจากศูนย์อย่างมีนัยสำคัญ แสดงว่า e_t เป็น White noise หรือ e_t มีการกระจายแบบปกติ (Normal distribution) มีค่าเฉลี่ย (mean) เท่ากับ 0 และค่าความแปรปรวนเท่ากับ $\sigma^2 I$ [$e_t \sim NID(0, \sigma^2 I)$] และ e_t ไม่มีสหสัมพันธ์ในตัวเอง (Autocorrelation) และ ไม่มีความแปรปรวนแตกต่างกัน หมายความว่า ตัวแปรอนุกรมเวลา ได้ผ่านการตรวจสอบความถูกต้อง (Diagnostics Checking) ดังนั้นรูปแบบจำลองที่คำนวณได้จึงมีความเหมาะสมต่อการนำไปใช้พยากรณ์ แต่หากพบว่าแบบจำลองที่คำนวณนั้นไม่เหมาะสมจะต้องทำการ **ขั้นตอน 1 เพื่อกำหนดรูปแบบของแบบจำลองใหม่**

ขั้นตอน 4 การพยากรณ์ (Forecasting) จะพิจารณาการเลือกรูปแบบ (Model) ที่มีความเหมาะสมที่สุดเพื่อที่จะนำไปพยากรณ์นั้น โดยพิจารณา Root Mean Squared Error และค่า Theil's Inequality Coefficient ที่มีค่าต่ำสุด สามารถพิจารณาผลการพยากรณ์ออกเป็น 3 ช่วง ดังต่อไปนี้



รูปที่ 3.2 แสดงการพิจารณาผลการพยากรณ์ แบ่งออกเป็น 3 ช่วง

ที่มา : Pindyck and Rubinfeld (1998)

ช่วงที่ 1 Historical forecast คือ ช่วง T_1 ถึง ช่วง T_{n-4} (รูปที่ 3.2) เป็นการพยากรณ์เพื่อเปรียบเทียบกับค่าของข้อมูลจริง ในการเลือกรูปแบบที่มีความเหมาะสมที่ โดยการพิจารณาค่า Root Mean Squared Error และค่า Theil's Inequality Coefficient ที่มีค่าต่ำสุด

$$\text{โดยที่ ค่า Root Mean Squared Error} = \sqrt{\frac{1}{T} \sum_{t=1}^T (Y_t^s - Y_t^a)^2} \quad (12)$$

$$\text{ค่า Theil's Inequality Coefficient} = \frac{\sqrt{\frac{1}{T} \sum_{t=1}^T (Y_t^s - Y_t^a)^2}}{\sqrt{\frac{1}{T} \sum_{t=1}^T (Y_t^s)^2} + \sqrt{\frac{1}{T} \sum_{t=1}^T (Y_t^a)^2}} \quad (13)$$

กำหนดให้ T = จำนวนตัวอย่างจากรูปแบบจำลอง

Y_t^s = ค่าจากรูปแบบจำลอง

Y_t^a = ค่าจากข้อมูลจริง

ช่วงที่ 2 Ex post forecast คือ ช่วง T_{n-4} ถึง ช่วง T_n (รูปที่ 3.2) เป็นการพยากรณ์เพื่อเปรียบเทียบกับค่าของข้อมูลจริง โดยใช้รูปแบบจากช่วง Historical forecast ในการเลือกรูปแบบที่มีความเหมาะสมที่สุด โดยการพิจารณาค่า Root Mean Squared Error และค่า Theil's Inequality Coefficient ที่มีค่าต่ำสุด

ช่วงที่ 3 Ex ante forecast คือ ช่วง T_u ที่พยากรณ์ต่อไปข้างหน้า (รูปที่ 3.2) โดยใช้รูปแบบจากช่วง Ex post forecast ที่มีความเหมาะสมที่สุดในการพยากรณ์

3.2 ระเบียบวิธีวิจัย

3.2.1 การวิเคราะห์แบบจำลองการพยากรณ์ราคาผลิตภัณฑ์มันสำปะหลัง โดยวิธี Box-Jenkins

การพยากรณ์อนุกรมเวลาค่าผลิตภัณฑ์มันสำปะหลัง โดยวิธี Box - Jenkins ในรูปแบบ ARIMA (p,d,q) นั้นต้องพิจารณาตัวแปรของราคาผลิตภัณฑ์มันสำปะหลัง (อนุกรม Y) ให้มีลักษณะนิ่ง (Stationary) เสียก่อน โดยการพิจารณาว่าจะมีลักษณะนิ่ง (Stationary) หรือไม่พิจารณาได้จาก

1) ค่าเฉลี่ย $E(Y_t)$ คงที่สำหรับทุกค่าของ t หรือไม่ จะทำได้โดยการแบ่งอนุกรมเวลาออกเป็นส่วนๆ แล้วทำการหาค่าเฉลี่ยในแต่ละส่วน ถ้าค่าเฉลี่ยแต่ละส่วนยังอยู่ไม่แตกต่างกันมาก สรุปได้ว่า $E(Y_t)$ คงที่

2) ค่าความแปรปรวน $E(Y_t)$ คงที่ สำหรับทุกๆ ค่าของ t หรือทำได้โดยการแบ่งอนุกรมเวลาออกเป็นส่วนๆ แล้วทำการหาค่าความแปรปรวนแต่ละส่วน ถ้าค่าความแปรปรวนในแต่ละส่วนไม่มีความแตกต่างกันนัก แสดงว่า $E(Y_t)$ คงที่

3) พิจารณาแนวโน้มและปัจจัยภายนอก ว่ามีผลต่อนุกรมหรือไม่

4) พิจารณาค่าอเรล โลแกรัมของค่าสัมประสิทธิ์สหสัมพันธ์ของอัตราของตัวอย่าง (R_k) กรณีที่อนุกรมเวลาไม่มีลักษณะนิ่ง (Stationary) ค่าอเรล โลแกรัมของ Autocorrelation ค่า R_k จะมีค่าลดลงค่อนข้างเร็วเมื่อ k เพิ่มมากขึ้น ดังนั้นถ้าค่า Autocorrelation มีค่าลดลงค่อนข้างช้าจะเป็นชี้สังเกตได้ว่าอนุกรมเวลาชุดนี้มีแนวโน้ม แต่ค่า Autocorrelation มีค่าลดลงค่อนข้างช้าและมีค่าค่อนข้างสูงที่ $k = L, 2L, 3L$ จะเป็นที่สังเกตได้ว่าอนุกรมชุดนี้มีแนวโน้มและอิทธิพลภายนอก

เมื่อพิจารณาการตรวจสอบแล้วว่า อนุกรมเวลาค่าผลิตภัณฑ์มันสำปะหลัง ที่ประกอบด้วย ราคามันเนื้คเนื้ และเป็นมันสำปะหลังที่ศึกษามีลักษณะไม่นิ่ง (Non-Stationary) จะต้องแปลงให้มีลักษณะนิ่ง (Stationary) เสียก่อน โดยการหาผลต่างสำหรับอนุกรมเวลาที่มีแนวโน้ม แต่ถ้าอนุกรมเวลาไม่มีความแปรปรวนไม่คงที่ ให้แปลงอนุกรมเวลาเดิม โดยการหาลอการิทึม ($Z_t = \ln Y_t$) จนกว่าจะได้ อนุกรมเวลาใหม่ ที่มีความแปรปรวนคงที่ การแปลงอนุกรมเวลาโดยการหาลอการิทึมของราคามันเนื้คเนื้ และเป็นมันสำปะหลัง ซึ่งก็คือ $\ln H_P$, และ $\ln S_t$ ตามลำดับ จากอนุกรมเวลาใหม่ที่มีลักษณะนิ่ง (Stationary) แล้วก็ทำตามขั้นตอนของ Box-Jenkins ต่อไป

ขั้นตอน 1 การกำหนดรูปแบบของอนุกรมเวลา (Identification) ให้กับอนุกรมเวลาที่เป็น Stationary Series เป็นการหารูปแบบ ARIMA (p,q) ที่คาดว่าจะเหมาะสมให้กับอนุกรมเวลา โดยที่ Autocorrelation : P_k คือการวัดความสัมพันธ์ของแต่ละช่วงเวลา โดยมีช่วงเวลาที่ย้อนหลังไป k หน่วยเวลา โดยที่ P_k มีค่าเท่ากับ $-1 \leq P_k \leq 1$ โดยพิจารณาเปรียบเทียบค่า Autocorrelation (r_k) ของอนุกรมเวลาตัวอ่อนย่าง กับค่า Autocorrelation (P_k) ของอนุกรมเวลาของประชากร ที่มีช่วงเวลาข้อนหลังไป k หน่วยเวลา ซึ่งมีสูตรดังนี้

$$r_k = \frac{\sum_{t=a}^{n-k} (Y_{t-q})(Y_{t+k+q})}{\sum_{t=a}^n (Y_{t-q})^2} \quad (14)$$

โดยที่ $Y_t = \sum_{t=a}^n (Y_t)$
 $q = \text{จำนวนเวลาสุดท้ายที่ย้อนหลัง}$

Partial Autocorrelation : p_{kk} คือการวัดความสัมพันธ์ของแต่ละช่วงเวลา โดยมีช่วงเวลาที่ย้อนหลังไป k หน่วยเวลา โดยพิจารณาเปรียบเทียบค่า Partial Autocorrelation (r_{kk}) ของอนุกรมเวลาตัวอ่อนย่าง กับค่า Partial Autocorrelation (p_{kk}) ของอนุกรมเวลาของประชากร ที่มีช่วงเวลาข้อนหลังไป k หน่วยเวลา ซึ่งมีสูตรดังนี้

$$r_{kk} = \frac{\sum_{j=1}^{k-1} (r_{k-1,j})(r_{k-j})}{\sum_{j=1}^{k-1} (r_{k-1,j})(r_j)} \quad (15)$$

การพิจารณาเปรียบเทียบแต่ละรูปแบบ ต้องพิจารณา r_k, r_{kk} กับ p_k และ p_{kk} พร้อมกัน หลาย ๆ ค่า จึงมักจะพิจารณาจากรูปที่เรียกว่าคอลเลറ์โลเกرام (Correlogram) ที่ได้จากการพล็อต r_k, r_{kk}, p_k และ p_{kk} ในช่วงเวลา k ดังนั้นการพิจารณาเปรียบเทียบ จะเป็นการเปรียบเทียบ Correlogram ของค่า Autocorrelation ของอนุกรมเวลาตัวอ่อนย่าง (r_k) กับค่า Autocorrelation ของอนุกรมเวลาของประชากร (p_k) และ Correlogram ของค่า Partial Autocorrelation ของอนุกรมเวลาตัวอ่อนย่าง (r_{kk}) กับค่า Partial Autocorrelation ของอนุกรมเวลาประชากร (p_{kk}) สำหรับแต่ละรูปแบบจะมี Correlogram ของ p_k และ p_{kk} ต่างกัน อนุกรมเวลาที่จะนำมากำหนดรูปแบบจะต้องเป็นอนุกรมเวลาที่ Stationary เท่านั้น หากไม่เป็น Stationary จะต้องแปลงให้เป็น Stationary เสียก่อน

โดยการพิจารณา ACF และ PACF ซึ่งสามารถระบุได้ว่าแบบจำลองจะมี Autoregressive (p), Differencing (d) และ Moving average (q) ที่สำคัญเท่าใด โดยจะพิจารณาจากตาราง 3.1

ขั้นตอน 2 การประมาณรูปแบบของอนุกรมเวลา (estimation) จะทำได้โดยการหาค่า ประมาณแบบง่ายหรือค่าประมาณที่ได้จากการวิเคราะห์ตัวเลข (numerical analysis) สำหรับค่า ประมาณ แบบง่ายจะทำโดยการสร้างสมการที่มาจากการสัมพันธ์ระหว่าง p_k และ พารามิเตอร์ โดยสมการที่สร้างขึ้นจะมีจำนวนเท่ากับจำนวนพารามิเตอร์ที่ต้องการประมาณ ส่วนค่าประมาณที่ได้จากการวิเคราะห์ตัวเลขจะได้จากการแก้สมการที่สร้างขึ้นจากวิธีกำลังสองน้อยที่สุด ขั้นตอนของ การวิเคราะห์ตัวเลขจะต้องมีการกำหนดค่าประมาณเริ่มต้น ซึ่งส่วนใหญ่จะใช้การประมาณแบบง่าย เป็นค่าประมาณเริ่มต้นเมื่อการวิเคราะห์สิ้นสุดจะได้ค่าประมาณสุดท้ายที่จะนำไปใช้ประโยชน์ในการ สร้างสมการพยากรณ์

โดยพิจารณา

- **Adjusted R² (R²)** เป็นการอธิบายว่ารูปแบบจำลองที่ได้สามารถอธิบายตัวแปรได้มาก น้อยแค่ไหน

$$R^2 = 1 - \frac{RSS/(n-k)}{TSS/(n-1)} = 1 - (1 - R^2) \frac{n-1}{n-k}$$

- **Durbin-Watson statistic (DW)** ใช้ทดสอบ Autocorrelation และความมีสหสัมพันธ์ใน ตัวเองของค่าความคลาดเคลื่อน (Error term) โดยค่า DW เข้าใกล้ 2 ถือว่าไม่มีสหสัมพันธ์ในตัวเอง และคงว่าแบบจำลองที่ใช้ในการศึกษาอยู่ในระดับที่น่าเชื่อถือได้

- **Akaike Information Criterion (AIC)** เป็นการอธิบายว่ารูปแบบจำลองที่ได้มีค่า ความคลาดเคลื่อนของผลการพยากรณ์มากน้อยแค่ไหน ถ้ามีค่าน้อยยิ่งคือ

$$AIC = e^{2k/n} \sum_{i=1}^n u_i^2 = e^{2k/n} \frac{RSS}{n} = e^{2k/n} \sum_{i=1}^n u_i^2 = e^{2k/n} \frac{RSS}{n}$$

- **F-Statistic** เป็นการดูความผันแปรของตัวมันเองผันแปรต่อตัวมันเอง

ขั้นตอน 3 การตรวจสอบความถูกต้อง (Diagnostic checking) เมื่อกำหนดรูปแบบและ ประมาณค่าพารามิเตอร์ในแบบจำลองแล้ว จะต้องตรวจสอบทุกครั้งว่ารูปแบบที่กำหนดนั้นมีความ

หมายความว่าหรือไม่ การตรวจสอบจะทำได้หลายวิธีได้แก่ การพิจารณาค่าอัลโกริทึมของ r_t หรือโดยพิจารณา White noise ของค่าประมาณการความคลาดเคลื่อน(estimated residual : e_t) ของรูปแบบอนุกรมเวลา โดยพิจารณาจาก

$$Q\text{-statistic} = n \sum_{k=1}^m \rho_k^{^2}$$

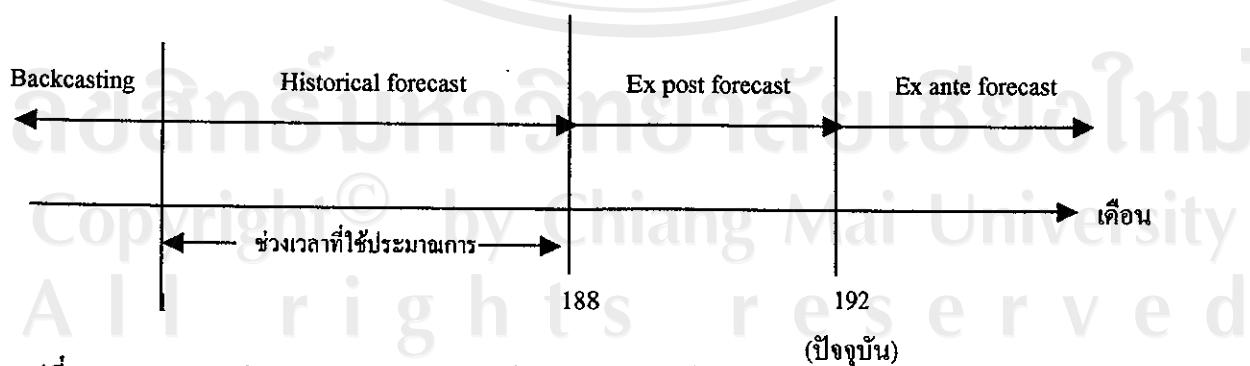
โดยที่ $m =$ ค่า Lag Length

$n =$ จำนวนของตัวอย่าง

หากพบว่า ค่า Q-statistic ของแบบจำลองไม่แตกต่างจากศูนย์อย่างมีนัยสำคัญ แสดงว่า e_t เป็น White noise หรือ e_t มีการกระจายแบบปกติ (Normal distribution) มีค่าเฉลี่ย (mean) เท่ากับ 0 และค่าความแปรปรวนเท่ากับ $e_t \sim NID(0, \sigma^2 I)$ แสดงว่า e_t ไม่มีสหสัมพันธ์ในตัวเอง (Autocorrelation) และ ไม่มีความแปรปรวนแตกต่างกัน หมายความว่า ตัวแปรอนุกรมเวลา ได้ผ่านการตรวจสอบความถูกต้อง (Diagnostics Checking) ดังนี้รูปแบบจำลองที่คำนวณ ได้จึงมีความหมายสมดุลเพื่อใช้พยากรณ์ แต่หากพบว่าแบบจำลองที่กำหนดนั้นไม่เหมาะสมจะต้องทำการปรับปรุงตามขั้นตอน 1 เพื่อกำหนดรูปแบบของแบบจำลองใหม่

ขั้นตอน 4 การพยากรณ์ (Forecasting) จะพิจารณาการเลือกรูปแบบ (Model) ที่มีความหมายสมดุลเพื่อที่จะนำไปใช้พยากรณ์นั้น โดยพิจารณา Root Mean Squared Error และค่า Theil's Inequality Coefficient ที่มีค่าต่ำสุด สามารถพิจารณาผลการพยากรณ์ออกเป็น 3 ช่วง ดังต่อไปนี้

(การพยากรณ์)



รูปที่ 3.3 แสดงการพิจารณาผลการพยากรณ์ราคากลิติกัณฑ์มันสำปะหลัง แบ่งออกเป็น 3 ช่วง
ที่มา : Pindyck and Rubinfeld (1998)

ช่วงที่ 1 Historical forecast คือ ช่วง 1 ถึง ช่วง 188 (รูปที่ 3.3) เป็นการพยากรณ์เพื่อเปรียบเทียบกับค่าของข้อมูลจริง ในการเลือกรูปแบบที่มีความเหมาะสมที่ โดยการพิจารณาค่า Root Mean Squared Error และค่า Theil's Inequality Coefficient ที่มีค่าต่ำสุด

$$\text{โดยที่ ค่า Root Mean Squared Error} = \sqrt{\frac{1}{T} \sum_{t=1}^T (Y_t^s - Y_t^a)^2} \quad (16)$$

$$\text{ค่า Theil's Inequality Coefficient (U)} = \frac{\sqrt{\frac{1}{T} \sum_{t=1}^T (Y_t^s - Y_t^a)^2}}{\sqrt{\frac{1}{T} \sum_{t=1}^T (Y_t^s)^2} + \sqrt{\frac{1}{T} \sum_{t=1}^T (Y_t^a)^2}} \quad (17)$$

กำหนดให้ T = จำนวน 192 ตัวอย่าง

Y_t^s = ค่าจากรูปแบบจำลอง

Y_t^a = ค่าจากข้อมูลจริง

ค่า Theil's Inequality Coefficient (U) มักจะอยู่ระหว่างศูนย์ถึงหนึ่ง ถ้ารูปแบบจำลองมีค่าใกล้เคียงหรือเท่ากับค่าจากข้อมูลจริง ($Y_t^s = Y_t^a$) จะทำให้ค่า Theil's Inequality Coefficient (U) เท่ากับศูนย์หรือเท่ากับศูนย์ หมายความว่า จะได้ Scale ที่มีความเหมาะสม

ช่วงที่ 2 Ex post forecast คือ ช่วง 189 ถึง ช่วง 192 (รูปที่ 3.3) เป็นการพยากรณ์เพื่อเปรียบเทียบกับค่าของข้อมูลจริง โดยใช้รูปแบบจากช่วง Historical forecast ในการเลือกรูปแบบที่มีความเหมาะสมที่สุด โดยการพิจารณาค่า Root Mean Squared Error และค่า Theil's Inequality Coefficient ที่มีค่าต่ำสุด

ช่วงที่ 3 Ex ante forecast คือ ช่วง 193 ที่พยากรณ์ต่อไปข้างหน้า (รูปที่ 3.3) โดยใช้รูปแบบจากช่วง Ex post forecast ที่มีความเหมาะสมที่สุดในการพยากรณ์