

บทที่ 3 ระเบียนวิธีวิจัย

งานวิจัยนี้มีวัตถุประสงค์เพื่อที่จะพยากรณ์ภายในตัวแปร โดยจะทำการวิเคราะห์ตัวแปร ผลตอบแทน (Y), มูลค่าซึ่งขยายหลักทรัพย์สุทธิของนักลงทุนชาวต่างชาติในตลาดหลักทรัพย์แห่งประเทศไทย (X_1), สัดส่วนการลงทุนในหลักทรัพย์ของนักลงทุนต่างชาติกับการลงทุนในหลักทรัพย์ทั้งหมด (X_2) และ Interaction term ($X_3=X_1*X_2$) หรือก็คือปฏิกริยาawan ของ X_1 และ X_2 ร่วมกันในช่วงระยะเวลาเดียวกันเพื่อพยากรณ์ถึงผลตอบแทนของหลักทรัพย์ในตลาดหลักทรัพย์แห่งประเทศไทย และ ARFIMAX (p,d,q,X) model ได้ถูกนำมาใช้ในการพยากรณ์ผลตอบแทนหลักทรัพย์

3.1 วิธีการทดสอบ Unit root.

3.1.1 DF-Test, ADF Test (1979)

DF-Test ใช้ 3 สมการเพื่อทดสอบ unit root ใน Y_t และ Y_{t-1} คือ ข้อมูลอนุกรมเวลา

$$DY_t = \alpha Y_{t-1} + U_t \quad \text{----- (1B) [ไม่มีการสกัดกั้น]}$$

$$DY_t = \beta_t + \alpha Y_{t-1} + U_t \quad \text{----- (2B) [มีตัวสกัดกั้น]}$$

$$DY_t = \beta_1 + \beta_t + \alpha Y_{t-1} + U_t \quad \text{----- (3B) [การสกัดกั้น + แนวโน้ม]}$$

โดยที่

$\alpha = (\rho - 1)$: สมมติฐานหลัก คือ $\alpha = (\rho - 1) = 0$ (ข้อมูลที่ไม่หยุดนิ่ง ($\rho > 1$))

ถ้า $\alpha >$ ค่าสถิติ Mackinnon สรุปได้ว่า ข้อมูลอนุกรมเวลาเป็นมีการหยุดนิ่ง หรือ

$I(d) = I(0)$ มิฉะนั้น จะปฏิเสธ สมมติฐานหลัก ที่ว่า $\alpha = (\rho - 1) = 0$ หรือ [$\rho = 1$] เพราะถ้าหากว่า α มีนัยยะสำคัญทางสถิติ ในทุกระดับ ทำให้ $\alpha \neq 0$ ($\rho \neq 1$).

ถ้า $\alpha < \text{ค่าสถิติ Mackinnon สรุปได้ว่า } \text{ข้อมูลอนุกรรมเวลานั้นไม่หยุดนิ่ง หรือ } I(d) = I(d) \text{ และยอมรับสมมติฐานหลัก ที่ว่า } \alpha = (\rho - 1) = 0 \text{ or } [\rho = 1] \text{ เพราะถ้าหากว่า } \alpha \text{ ไม่มี} \text{ นัยสำคัญทางสถิติ ณ ระดับใดๆ ทำให้ } \alpha = 0 (\rho = 1).$

ADF-Test ใช้สำหรับ การทดสอบ unit root เมื่อพบว่า ปัญหาสาเหตุของตัวบวกวน สูงขึ้น ในข้อมูลอนุกรรมเวลา โดยก่อนที่จะใช้ ADF-Test, dw จะต้องถูกตรวจสอบด้วย ค่าสถิติจาก สมการ DF-Test (2B) และ (3B)

$$D Y_t = \beta_1 + \beta_t + \alpha Y_{t-1} + \beta_i \sum_{i=1}^m \Delta Y_{t-i} + \varepsilon_t \quad (4B)$$

เมื่อแทนค่า $(\beta_i \sum_{i=1}^m \Delta Y_{t-i})$ ในสมการ (4B) จากนั้น ค่า t-statistics ของ α ก่อน Y_{t-1} จะเปลี่ยนแปลง และ ค่า t-statistics จะเปลี่ยนแปลงด้วย ดังนั้น ADF-Test จะเป็นจริง สำหรับ higher order serial correlation โดยการเพิ่ม lagged differenced terms ในด้านขวา การทดสอบสมมติฐาน สำหรับ unit root ในข้อมูลอนุกรรมเวลา โดยใช้ วิธีการ ADF-Test สำหรับ วิธีการ DF-test และ ข้อสรุปเดียวกัน ของข้อมูลอนุกรรมเวลา คือ หยุดนิ่ง หรือ ไม่หยุดนิ่ง

3.1.2 Phillips-Perron Test (PP-Test:1987,1988)

กระบวนการทดสอบ unit root นี้ พัฒนาโดย Phillips and Perron (1988) ซึ่งได้

นำเสนอ วิธีการ nonparametric สำหรับ การควบคุม higher-order serial correlation ในข้อมูล อนุกรรมเวลา

$$D Y_t = \alpha + \beta_t Y_{t-1} + \varepsilon_t \quad (5B)$$

PP-test ทำให้เกิดความถูกต้องของค่า t-statistic สำหรับค่า γ coefficient ของ AR(1) regression เพื่ออธิบาย serial correlation ในสมการ(5B) การตรวจสอบจะเป็น nonparametric เมื่อใช้ ในการประมาณค่า spectrum ของสมการ(5B) ที่ความถี่เท่ากับศูนย์ ซึ่งตรงกับ heteroskedasticity และ autocorrelation ของรูปแบบที่ไม่ระบุ

$$\gamma_j = (1/T) \sum_{t=j+1}^T \varepsilon_t^* \varepsilon_{t-j}^* \quad (6B)$$

$$W^2 = \gamma_0 + 2 \sum_{j=1}^q [1 - j/(q+1)] \gamma_j \quad \dots \quad (7B)$$

โดย

W^2 = ตัวประมาณค่า Newey-west heteroskedasticity autocorrelation consistent

γ_j = ค่า coefficient จาก AR(1) ในสมการ(5B)

$\varepsilon_t^* \varepsilon_{t-j}^*$ = ค่าความคลาดเคลื่อน ที่ได้จากสมการ(5B)

$q = \text{floor}(4(T/100)^{2/9})$, [q คือ truncation lag]

และการทำ PP-Test (t_{pp}) มีค่า t-statistic จำนวนตามสมการ (8B) เมื่อเทียบกับที่ t_b , s_b ซึ่งคือค่า t-statistics และ ความคลาดเคลื่อนมาตรฐาน (β_r) ได้จากการทดสอบในสมการ (5B) และ s^* คือค่าความคลาดเคลื่อนมาตรฐาน ที่ได้จากการทดสอบ ในสมการเดียวกัน

โดย

$$\text{PP-Test } (t_{pp}) = [(\gamma_0^{1/2} t_b) / (W)] - [(W^2 - \gamma_0) T s_b / (2 W s^*)] \quad (8B)$$

การแยกแข่งขันกับ สำหรับ PP-Test (t_{pp}) เมื่อเทียบกับ ADF-Test และมีการทดสอบสมมติฐานดังนี้

H_0 : สมมติฐานหลัก โดย ข้อมูลอนุกรมเวลา ไม่หยุดนิ่ง

H_1 : อนุกรมเวลา หยุดนิ่ง

ถ้า $\text{PP-Test } (t_{pp}) >$ ค่าสถิติ Mackinnon สรุปได้ว่า ข้อมูลอนุกรมเวลา มีการหยุดนิ่ง

มิฉะนั้น ปฏิเสธ สมมติฐานหลัก ที่เป็นข้อมูล ไม่หยุดนิ่ง

ถ้า $\text{PP-Test } (t_{pp}) <$ ค่าสถิติ Mackinnon สรุปได้ว่า ข้อมูลอนุกรมเวลา ไม่หยุดนิ่ง

พร้อมกันกับ ยอมรับสมมติฐานหลัก

3.2 Long Memory Test

เป็นการทดสอบว่าตัวแปรนั้น ๆ มี Long Memory หรือไม่ ซึ่งตัวแปรที่มี Long Memory คือ ตัวแปรที่จะได้รับผลกระทบได้ในระยะยาว แต่ในระยะสั้นแล้วจะไม่ได้รับผลกระทบนั้นเอง

โดยมีสมมุติฐานคือ $H_0 : d = 0$ (ไม่มี Long Memory)

$H_a : d \neq 0$ (มี Long Memory)

3.2.1 Test for Long Memory : การทดสอบ R/S

การทดสอบ R/S test ถูกพัฒนาโดย Harold Edwin Hurst ในช่วง 1960 และ Mandelbrot & Wallis(1969) ใช้ในการคำนวณค่า พารามิเตอร์ H , ที่ใช้วัด ความหนาแน่นของ long range dependence ในอนุกรมเวลา

อนุกรมเวลาของช่วง T แบ่งออกเป็น n sub-series ของช่วง m และสำหรับทุกๆ sub-series โดยแต่ละ sub-series จะมีค่า $m = 1, \dots, n$, to เพื่อหาค่ามัธยฐาน (E_m) และส่วนเบี่ยงเบนมาตรฐาน (S_m) และขั้ด ค่ามัธยฐานตัวอย่าง ที่ $Z_{i,m} = X_{i,m} - E_m$ สำหรับ $i = 1, \dots, m$

หลังจากนั้นจึง สร้างอนุกรมเวลาโดยใช้รูปแบบของ $W_{i,m} = \sum_{j=1}^i Z_j$ โดยที่ $i = 1, \dots, m$ และ เพื่อหา ระยะของ $R_m = \max\{W_{1,m}, \dots, W_{n,m}\} - \min\{W_{1,m}, \dots, W_{n,m}\}$

การกำหนด rescaled range ของ R_m โดยใช้ $\frac{R_m}{S_m}$ แบบเดียวกับในกรณีของอนุกรมเวลา สามารถหาค่า R, S และ H ตามข้อกำหนดต่อไปนี้

- กำหนดให้ R คือ ระยะที่อยู่ในตัวแปร $, k$ คือ ค่าคงที่ และ T คือ ช่วงความยาว ของเวลา
- กำหนดให้ R/S คือ rescaled range, m จำนวนครั้งของการสำรวจ, k คือ ค่าคงที่ และ H คือ Hurst exponent จะสามารถนำมาใช้ในอนุกรมเวลาขนาดใหญ่ได้

$$\frac{R}{S} = k \times m^H$$

- ค่า Hurst exponent หาได้จาก :

$$\log(R/S)m = \log k + H \log m$$

และมีข้อกำหนดดังนี้ :

- ถ้า H value = 0.5 อนุกรมเวลาจะเป็นเคลื่อนไปอย่างสุ่ม และ เป็นอิสระ
- ถ้า H value = (0, 0.5) อนุกรมเวลาจะเป็นแบบไม่คงตัว กระบวนการจะคลอบคลุมเพียงแค่ วงแคบ เมื่อเทียบกับกรณีการเคลื่อนไปอย่างสุ่ม
- ถ้า H value =(0.5, 1) อนุกรมเวลา จะเป็นชุดข้อมูลที่คงตัว กระบวนการจะคลอบคลุมเป็น วงกว้าง เมื่อเทียบกับกรณีการเคลื่อนไปอย่างสุ่ม

3.2.2 Test for Long Memory : การทดสอบ Modified R/S

การทดสอบ modified R/S พัฒนามาจาก การทดสอบ classical R/S ที่เสนอโดย Hurst(1951) ในขณะที่กำลังศึกษา ข้อมูลอนุกรมเวลาทางอุทกวิทยาของแม่น้ำไนล์ สำหรับชุด คำต่อไป $\{x_1, x_2, \dots, x_T\}$ นั้น Lo (1991) ปรับปรุง ทดสอบแบบ classical โดยการให้นิยาม (คุณสมบัติ (1))

$$Q_T = \frac{\hat{R}}{\hat{\sigma}_T^2} \quad (1)$$

โดยที่

$$\hat{R} = \max_{0 < i \leq T} \sum_{t=1}^i (x_i - \bar{X}) - \min_{0 < i \leq T} \sum_{t=1}^i (X_t - \bar{X}),$$

$$\hat{\sigma}_T^2 = \hat{\sigma}^2 + 2 \sum_{j=1}^q w_j(q) \hat{\gamma}_j,$$

และกำหนดให้ :

$$w_j(q) = 1 - |j/q|,$$

$\hat{\sigma}^2$ = การเปลี่ยนแปลงของข้อมูลตามปกติ

\bar{X} = ค่ามัธยฐานของข้อมูล

$\hat{\gamma}_j$ = lag-j autocovariance ของข้อมูลและช่วงที่ต้องการของ lag q หากได้จากสมการที่ 2

$$q = \text{int} \left[((3T)/2)^{1/3} ((2\hat{\rho})/1-\hat{\rho}^2)^{2/3} \right] \quad (2)$$

โดยที่ $\hat{\rho}$ คือ sample autocorrelation coefficient อันดับแรก และ $\text{int} []$ คือ พิมพ์ชั้นจำนวนเต็ม ภายใต้สมมติฐานหลัก ที่ไม่มีความทรงจำระยะยาว หรือไม่มี rang dependence ระยะยาว ซึ่ง Lo (1991) เสนอว่า การกระจายที่มีขอบเขต ของค่าสถิติ Q_T ในสมการ (1) ได้มาจาก พิมพ์ชั้นการกระจาย ของความแตกต่างระหว่าง ค่าสูงสุดและต่ำสุดของ Brownian bridge บนช่วง ของแต่ละหน่วย เพราะฉะนั้น เป็นการง่ายที่จะทำการทดสอบให้ได้ค่า p-value

3.2.3 Test for Long Memory : GPH Test

กระบวนการ GPH Test ถูกพัฒนาโดย Geweke, J. และ S. Porter-Hudak(1983) เพื่อ แสดงถึง การประมาณค่า OLS estimator ของ d จากสมการทดสอบ : (equation 3)

$$\ln[I(\xi)] = \alpha - \hat{d} \ln[\sin^2(\frac{\xi}{2})] + e_\lambda \quad \lambda = 1, \dots, v \quad \text{--- (3)}$$

โดยที่

$$I(\xi) = \frac{1}{2\pi T} \left| \sum_{t=1}^T e^{it\xi} (x_t - \bar{x}) \right|^2 \quad \text{--- (4)}$$

และสมการที่ 4 คือ Periodogram (การประมาณค่าความหนาแน่น ของ spectral) ของค่า x ที่ frequency (ξ) เมื่อันกันกับ ค่า bandwidth v ถูกเลือกไว้สำหรับ $T \rightarrow \infty, v \rightarrow \infty$ แต่ $\frac{v}{T} \rightarrow 0$ แนวคิดของ Geweke and Porter-Hudak พิจารณาว่า อิทธิพลของ T จะอยู่ระหว่าง (0.5,0.6) และสมมติฐานหลักของกระบวนการความทรงจำระยะยาว ความชันของสมการทดสอบ d เท่ากับศูนย์ และ ค่า t-statistics สามารถใช้ในการแสดงผลการทดสอบได้

3.3 Run ARFIMAX(p,d,q)

สามารถแสดงได้ดังนี้ (ดูสมการที่ 1.1J)

$$y_t = c_1 y_{t-1} + c_2 y_{t-2} + \dots + c_k y_{t-k} + \varepsilon_t + d_1 \varepsilon_{t-1} + d_2 \varepsilon_{t-2} + \dots + d_l \varepsilon_{t-l}, \quad \text{--- (1.1J)}$$

หรือ

$$\left(1 - \sum_{i=1}^k C_i L^i \right) y_t = \left(1 + \sum_{i=l}^l d_i L^i \right) \varepsilon_t$$

และ L คือ the lag operator $\{ \sum_{i=1}^3 (L^i) y_t = y_{t-1} + y_{t-2} + y_{t-3} \}$ เหมือนกันกับ ARMA โดยมี ตัวแปรภายนอก หรือ ARMAX (k,l) : (ดูสมการที่ 1.2J)

$$c(L)(y_t - X_t / \beta) = D(L)\varepsilon_t, \quad \text{----- (1.2J)}$$

โดย

$$c(L) = \left(1 - \sum_{i=1}^k C_i L^i \right)$$

$$D(L) = \left(1 + \sum_{i=1}^l d_i L^i \right) \varepsilon_t$$

แบบจำลอง ARFIMAX (p, d^*, q, X) $\{p=k, d^*=\text{Fractional differencing operator}, q=l\}$

สามารถเขียนอยู่ในรูปสมการ 1.3J ดังนี้

$$c(L)(1 - L)^{d^*}(y_t - X_t / \beta) = D(L)\varepsilon_t, \quad \text{----- (1.3J)}$$

โดยที่ $(1-L)^{d^*}$ คือ การทำงานของ fractional differencing และ $d^* \in (-0.5, 0.5)$ คือ พารามิเตอร์ของ fractional differencing

โดย Y คือ Return ของหลักทรัพย์ PTT, PTTEP, SCC, KBANK และ CPALL

X1 คือ มูลค่าซื้อขายหลักทรัพย์สุทธิของนักลงทุนชาวต่างชาติในตลาดหลักทรัพย์แห่งประเทศไทย

X2 คือ สัดส่วนการลงทุนในหลักทรัพย์ของนักลงทุนต่างชาติกับการลงทุนในหลักทรัพย์ทั้งหมด

X3 คือ ปฏิกริยาร่วมของ X1 และ X2 (Interaction term = $X1 * X2$)

3.4 เลือก Best Model

- คัดเลือกแบบจำลอง

ที่มีค่าของ Autoregressive และ moving average ที่มีนัยสำคัญทางสถิติ ณ ระดับ 1%, 5% และ 10% มาพิจารณา

- พิจารณาค่า d parameter

โดยคำนวณจาก $A + (1.96 * S.E)$ โดย A คือค่าสัมประสิทธิ์ของ d parameter ในแบบจำลองนั้น ๆ และค่า S.E. คือ ค่าความคลาดเคลื่อนของ d parameter ในแบบจำลองนั้น ๆ หากตัวเลขที่คำนวณออกมาก ได้นั้นอยู่ในช่วง -0.5 ถึง 0.5 จะแสดงว่า d parameter นั้น Stationary

- พิจารณา Bayesian information criterion

พิจารณาค่าของ Bayesian information criterion (BIC) โดย BIC จะถูกใช้ในการเลือกแบบจำลองที่ดีที่สุดของ ARFIMAX (p,d,q,X) เนื่องจาก BIC หมายความว่าการพิจารณาข้อมูลที่มีจำนวนมาก ๆ และ ในการพยากรณ์ผลตอบแทนหลักทรัพย์ แบบจำลองที่ดีที่สุดนั้น จะต้องมีค่าของ Bayesian information criterion (BIC) ของแบบจำลองน้อยที่สุด

BIC อยู่ภายใต้สมมติฐานว่าการกระจายข้อมูลที่มีลักษณะดังนี้

- $x = \text{ข้อมูล}$
- $n = \text{จำนวนข้อมูล } x$
- $k = \text{จำนวน}_{\text{พารามิเตอร์}}$
- $p(x | k) = \text{ความน่าจะเป็นของการข้อมูลที่กำหนดค่าพารามิเตอร์}$
- $L = \text{ค่า maximized value of the likelihood function ของการประมาณ}$

BIC สูตรสำหรับเป็นดังนี้

$$-2 \cdot \ln p(x|k) \approx \text{BIC} = -2 \cdot \ln L + k \ln(n).$$

ภายใต้สมมติฐานของโมเดลที่ผิดพลาดหรือตัวบ่งชี้ เป็นการกระจายแบบปกติทำให้กลไกมาเป็น

$$\text{BIC} = \ln(\sigma_e^2) + \frac{k}{n} \ln(n).$$

โดยที่ σ_e^2 เป็นความแปรปรวนข้อผิดพลาด

3.5 ดูความคลาดเคลื่อนระหว่างค่าที่แท้จริงกับค่าที่พยากรณ์ออกมาได้

3.5.1 The Mean Absolute Error (MAE)

ค่ามัธยฐานของความคลาดเคลื่อนที่เป็นค่าสัมบูรณ์ (MAE) ในทางสถิติ ค่ามัธยฐานของความคลาดเคลื่อนที่เป็นค่าสัมบูรณ์ (MAE) เป็นค่าปริมาณ ที่ใช้แสดงความใกล้เคียงของการทำนายและการพยากรณ์ ต่อผลผลิตขั้นสุดท้าย ค่ามัธยฐานของความคลาดเคลื่อนที่เป็นค่าสัมบูรณ์ (MAE) แสดงในสมการ (1X)

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |f_i - y_i| = \frac{1}{n} \sum_{i=1}^n |e_i|. \quad \text{----- (1X)}$$

จากการแนะนำตามข้อ ค่ามัธยฐานของความคลาดเคลื่อนที่เป็นค่าสัมบูรณ์ กือค่าเฉลี่ยของความคลาดเคลื่อนที่เป็นค่าสัมบูรณ์ $e_i = f_i - y_i$, โดย f_i คือค่าของตัวพยากรณ์ และ y_i คือค่าที่แท้จริง สังเกตว่า การกำหนดทางเลือก จะรวมถึง ความถี่สัมพัทธ์ เป็นค่าถ่วงน้ำหนัก ค่ามัธยฐานของความคลาดเคลื่อนที่ค่าสัมบูรณ์ เป็นตัวตรวจสอบปกติ สำหรับความคลาดเคลื่อนของการทำนายในการวิเคราะห์อนุกรมเวลา และ บทความนี้ใช้ ค่ามัธยฐานของความคลาดเคลื่อนค่าสัมบูรณ์ (MAE) ตรวจความคลาดเคลื่อนของผลตอบแทนของหลักทรัพย์ โดยมีพื้นฐานจากแนวคิดวิธีการพยากรณ์แบบ ARFIMA

3.5.2 The Mean Absolute Percentage Error (MAPE)

ค่าร้อยละของมัธยฐานของความคลาดเคลื่อนที่เป็นค่าสัมบูรณ์ (MAPE) ในทางสถิติ ค่ามัธยฐานของความคลาดเคลื่อนที่เป็นค่าสัมบูรณ์ (MAE) เป็นตัววัดความแม่นยำในค่าอนุกรมเวลาที่เหมาะสมในทางสถิติ โดยเฉพาะแนวโน้ม ซึ่งโดยเฉลี่ยกับ การแสดงความแม่นยำเป็นร้อยละ และ ข้อกำหนดของ MAPE สามารถแสดงได้ตามสมการ (2X)

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \quad \text{----- (2X)}$$

โดย A_t คือค่าที่แท้จริง และ F_t คือค่าที่ได้จากการพยากรณ์

ความแตกต่างระหว่าง A_t และ F_t จากนั้นจึงหารด้วย A_t อีกรัง ค่าสัมบูรณ์ของการคำนวณนี้ เป็นผลรวมของทุกๆ จุดที่เหมะสม หรือจุดที่พยากรณ์ และหารอีกรังด้วย จุดที่เหมะสม n ทำให้เป็นร้อยละของความคลาดเคลื่อน ที่สามารถเปรียบเทียบกับ ความคลาดเคลื่อนของอนุกรมเวลาที่เหมะสม ที่แตกต่างกันในส่วนของระดับ และในบทความนี้ใช้ MAPE ตรวจวัดความแม่นยำใน ผลตอบแทนของหลักทรัพย์ โดยมีพื้นฐานจากแนวคิด วิธีการพยากรณ์ ARFIMA

ประโยชน์ของ ค่า MAPE คือความสามารถในการเปรียบเทียบระหว่างความแตกต่างของแบบจำลองการพยากรณ์ และมีความชัดเจนในการแปรความหมาย (Fretchling, 1996) ตัวชี้นำของการแปลความหมายMAPE's เป็นดังนี้

- ถ้าหากค่า MAPE น้อยกว่า 10% การทำนายจะมี“ความแม่นยำสูงมาก”
- ถ้าหากค่า MAPE อยู่ระหว่าง 10%-20% การทำนายจะมี“ความแม่นยำสูง”
- ถ้าหากค่า MAPE อยู่ระหว่าง 20-50% การทำนายจะมี“ความแม่นยำปานกลาง”
- ถ้าหากค่า MAPE สูงกว่า 50% การทำนายจะ “ไม่มีความแม่นยำ” (Lewis, 1982)

ดังนั้น แบบจำลองที่ดีที่สุดของ ARFIMA (p,d,q) models จะลูกใช้ในการพยากรณ์ ผลตอบแทนของหลักทรัพย์ในตลาดหลักทรัพย์แห่งประเทศไทย