

บทที่ 2

ทฤษฎีและผลงานวิจัยที่เกี่ยวข้อง

2.1 แนวคิดและทฤษฎี

2.1.1 ทฤษฎีการตั้งราคาหลักทรัพย์ (Capital Asset Pricing Model: CAPM)

การประมาณค่าอัตราผลตอบแทนที่คาดหวังและความเสี่ยงของหลักทรัพย์โดยใช้ Capital Asset Pricing Model (CAPM) Sharpe (1964, อ้างถึงใน จิรัตน์ สังข์แก้ว 2542) ได้เสนอแนวคิดในการประมาณค่าอัตราผลตอบแทนและความเสี่ยงของหลักทรัพย์โดยเริ่มจากวิธี Single Factor Model และประยุกต์มาเป็น Capital Asset Pricing Model (CAPM)

Single Factor Model แบบจำลองนี้เป็นการประมาณค่าความเสี่ยงของหลักทรัพย์โดยนำมาเทียบกับตลาดซึ่งจะพบว่าโดยทั่วไปแล้วราคาของหลักทรัพย์มักจะเปลี่ยนแปลงไปตามการเปลี่ยนแปลงของราคาตลาดถึงแม้ว่าราคาหุ้นส่วนใหญ่จะเปลี่ยนแปลงไปในทิศทางเดียวกับตลาด แต่เนื่องจากคุณสมบัติเฉพาะตัวของแต่ละหลักทรัพย์ จึงทำให้ลักษณะการเคลื่อนไหวของราคาเปลี่ยนแปลงไปตามสภาพตลาดเป็นไปในอัตราที่ไม่เท่ากัน ดังนั้น Sharpe จึงได้พิจารณาการเปลี่ยนแปลงของราคาหลักทรัพย์อันเนื่องมาจากการเปลี่ยนแปลงของราคาตลาดซึ่งเป็นเครื่องชี้แนวโน้มเพียงตัวเดียวเท่านั้น จึงเรียกการศึกษาเช่นนี้ว่า Single Factor Model มีรูปแบบดังนี้

$$R_{it} = \alpha_i + \beta_i R_{mt} + e_{it} \quad (2.1)$$

โดยที่

R_{it} คือ อัตราผลตอบแทนของหลักทรัพย์ i ในเวลา t

R_{mt} คือ อัตราผลตอบแทนของตลาด ในเวลา t

α_i คือ จุดตัดแกนตั้ง แสดงถึงอัตราผลตอบแทนของหลักทรัพย์ i เมื่ออัตราผลตอบแทนของตลาดมีค่าเป็นศูนย์

β_i คือ ค่าความชันของเส้นสมการถดถอยซึ่งเป็นการวัดค่าความอ่อนไหว (sensitivity) ของอัตราผลตอบแทนของหลักทรัพย์ i ที่มีต่อการ

ปรับตัวต่อการเปลี่ยนแปลงของอัตราผลตอบแทนตลาด

e_t คือ ค่าความคลาดเคลื่อน ในเวลา t

ความเสี่ยงของแต่ละหลักทรัพย์สามารถวัดได้จากความเสี่ยงหรือความแปรปรวนของหลักทรัพย์ที่มีต่อความเสี่ยงหรือความแปรปรวนของตลาด ดังนั้นความเสี่ยงของหลักทรัพย์แต่ละตัวจะเป็นค่าความแปรปรวนร่วม(covariance)ของหลักทรัพย์ที่ i และตลาด

Capital Asset Pricing Model เป็นแบบจำลองที่ใช้ในการอธิบายความสัมพันธ์ระหว่างอัตราผลตอบแทนของหลักทรัพย์ใด ๆ กับความเสี่ยงของหลักทรัพย์

$$E(R_i) = \alpha + b\beta_i \quad (2.2)$$

โดยที่

$E(R_i)$ คือ อัตราผลตอบแทนที่คาดหวังจากการลงทุนในแต่ละหลักทรัพย์ i

α คือ ผลตอบแทนของหลักทรัพย์ที่ไม่มีความเสี่ยง

b คือ ความเสี่ยงที่เป็นระบบเกิดจากการลงทุนในหลักทรัพย์ i

β_i คือ ค่าความชันของเส้นตลาดหลักทรัพย์ (SML)

ถ้า $\beta_i = 0$ คือหลักทรัพย์ที่ไม่มีความเสี่ยงจะได้ว่า $R_i = \alpha + b(0) = \alpha$ ดังนั้น α คือ ผลตอบแทนของหลักทรัพย์ที่ไม่มีความเสี่ยง (R_f) ดังนั้น $R_f = \alpha$

ถ้า $\beta_i = 1$ คือความเสี่ยงของหลักทรัพย์เท่ากับความเสี่ยงของตลาด

ให้ R_m คือ อัตราผลตอบแทนตลาด

จะได้ว่า $R_m = \alpha + \beta(1)$

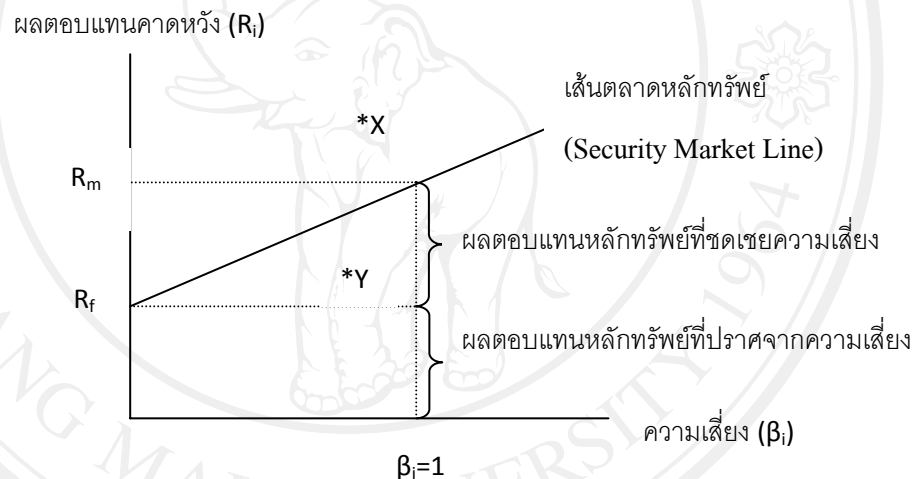
จาก $R_f = \alpha$

จะได้ $R_i = R_f + \beta_i (R_m - R_f) \quad (2.3)$

เส้นตลาดหลักทรัพย์ เป็นเส้นตรงที่ลากเชื่อมระหว่างจุดสองจุดบนแกนผลตอบแทนที่คาดหวัง และแกนความเสี่ยง โดยที่จุดแรกได้มาจากความสัมพันธ์ของผลตอบแทนเฉลี่ยของหลักทรัพย์ที่

ปราศจากความเสี่ยงกับความเสี่ยงของการลงทุนในตลาด ($\beta_i = 0$) โดยหมายความว่าหากนักลงทุนเป็นผู้หลีกเลี่ยงความเสี่ยง และลงทุนในหลักทรัพย์ที่ไม่มีความเสี่ยง อัตราผลตอบแทนจากการลงทุนเท่ากับผลตอบแทนหลักทรัพย์ที่ไม่มีความเสี่ยง และในจุดที่สองได้มาจากความสัมพันธ์ของอัตราผลตอบแทนเฉลี่ยของหลักทรัพย์กับความเสี่ยงของการลงทุนในตลาด โดยหมายความว่าหากนักลงทุนต้องการลงทุนในหลักทรัพย์ที่มีความเสี่ยงเท่ากับ 1 อัตราผลตอบแทนจากการลงทุนจะเท่ากับอัตราผลตอบแทนของตลาดซึ่งความสัมพันธ์ระหว่างความเสี่ยงและผลตอบแทนคาดหวังสามารถแสดงโดยเส้นตลาดหลักทรัพย์ดังนี้

รูปที่ 2.1 แสดงความสัมพันธ์ระหว่างผลตอบแทนที่คาดหวังกับความเสี่ยงจากการลงทุนในหลักทรัพย์



ที่มา : Fischer and Jordan (1995)

จากภาพ ณ จุด X อัตราผลตอบแทนหลักทรัพย์สูงกว่าเส้นตลาดหลักทรัพย์ แสดงว่าหลักทรัพย์มีลักษณะ under value คือมีราคาซื้อขายต่ำกว่าระดับราคาที่เหมาะสม และจุด Y อัตราผลตอบแทนต่ำกว่าเส้นตลาดหลักทรัพย์ แสดงว่าหลักทรัพย์มีลักษณะ over value คือมีราคาซื้อขายสูงกว่าระดับราคาที่เหมาะสม

จากสมการที่ (2.1) และ(2.3) จะได้

$$\begin{aligned} R_i &= R_f + \beta_i (R_m - R_f) \\ &= (1 - \beta_i) R_f + \beta_i R_m \end{aligned}$$

ค่า α จากสมการที่ (2.1) ก็คือ $(1 - \beta_i) R_f$ ของสมการที่ (2.3)

ดังนั้นสามารถระบุค่าที่แท้จริงของหลักทรัพย์ดังนี้

1. ถ้า $\alpha = (1 - \beta_i) R_f$ หมายความว่าอัตราผลตอบแทนจากการลงทุนในตลาดหลักทรัพย์แห่งประเทศไทยของหลักทรัพย์ใดหลักทรัพย์หนึ่ง มีค่าเท่ากับ อัตราผลตอบแทนจากการลงทุนในตลาดหลักทรัพย์แห่งประเทศไทยของทั้งตลาด

2. ถ้า $\alpha < (1 - \beta_i) R_f$ หมายความว่าอัตราผลตอบแทนจากการลงทุนในตลาดหลักทรัพย์แห่งประเทศไทยของหลักทรัพย์ใดหลักทรัพย์หนึ่ง มีค่าน้อยกว่า อัตราผลตอบแทนจากการลงทุนในตลาดหลักทรัพย์แห่งประเทศไทยของทั้งตลาด นั่นคือ ผู้ลงทุนควรจะเลือกลงทุนในหลักทรัพย์นั้นเพราะให้ผลตอบแทนต่ำ

3.. ถ้า $\alpha > (1 - \beta_i) R_f$ หมายความว่าอัตราผลตอบแทนจากการลงทุนในตลาดหลักทรัพย์แห่งประเทศไทยของหลักทรัพย์ใดหลักทรัพย์หนึ่ง มีค่ามากกว่า อัตราผลตอบแทนจากการลงทุนในตลาดหลักทรัพย์แห่งประเทศไทยของทั้งตลาด นั่นคือ ผู้ลงทุนควรจะเลือกลงทุนในหลักทรัพย์นั้นเพราะให้ผลตอบแทนสูง

2.1.2 การวิเคราะห์อนุกรมเวลา (Time Series Analysis)

การวิเคราะห์อนุกรมเวลาเป็นวิธีที่ใช้ในการวิเคราะห์ข้อมูลหรือค่าสังเกตที่มีการเปลี่ยนแปลงไปตามลำดับเวลาที่เกิดขึ้น หรือการเปลี่ยนแปลงของตัวแปรในช่วงเวลาที่ผ่านไป ลักษณะของการเปลี่ยนแปลงอาจมีหรือไม่มีรูปแบบก็ได้ แต่ถ้าอนุกรมเวลาแสดงให้เห็นรูปแบบการเปลี่ยนแปลงในช่วงเวลาที่ผ่านไปในอดีตก็จะทำให้สามารถคาดการณ์ได้ว่าในอนาคตลักษณะการเปลี่ยนแปลงควรอยู่ในรูปแบบใด และสามารถพยากรณ์การเปลี่ยนแปลงข้อมูลในอนาคตได้ การวิเคราะห์ข้อมูลอนุกรมเวลานี้จะขึ้นอยู่กับลักษณะการเปลี่ยนแปลงของเวลาในอดีตเป็นพื้นฐาน(ศิริลักษณ์ เล็กสมบูรณ์, 2531)

2.1.3 การทดสอบความนิ่งของข้อมูล (Stationary)

การทดสอบว่าข้อมูลที่น่ามาศึกษามีความนิ่งหรือไม่ สามารถทำได้โดยการทดสอบ Unit Root ซึ่งทำได้โดยใช้การทดสอบ DF (Dickey – Fuller Test) และการทดสอบ ADF (Augmented Dickey – Fuller Test)

ข้อมูลอนุกรมเวลาที่มีลักษณะนิ่ง(Stationary) คือ ข้อมูลที่ค่าเฉลี่ยและความแปรปรวนของกระบวนการเชิงสุ่มนั้นมีค่าคงที่เมื่อเวลาได้เปลี่ยนไป และค่าความแปรปรวนระหว่างสองคาบเวลา

ขึ้นอยู่กับความล่า Lag ระหว่างคาบเวลาทั้งสอง โดยสามารถเขียนเป็นสมการได้ดังนี้ (ทรงศักดิ์ ศรีบุญจิตต์ และ อารี วิบูลย์พงษ์, 2542)

$$\text{ค่าเฉลี่ย (mean)} : E(X_t) = \mu \quad (2.4)$$

$$\text{ความแปรปรวน (variance)} : V(X_t) = E(X_t - \mu)^2 = \sigma^2 \quad (2.5)$$

$$\text{ความแปรปรวนร่วม (covariance)} : COV(X_t, X_{t+k}) = E(X_t - \mu)(X_{t+k} - \mu) = \sigma_k - \mu \quad (2.6)$$

โดยที่ X_t แทนข้อมูลอนุกรมเวลาซึ่งเป็นกระบวนการเชิงสุ่ม

ในการวิเคราะห์ข้อมูลที่เป็นอนุกรมเวลานั้น ข้อมูลจะต้องมีลักษณะหนึ่ง เนื่องจากข้อมูลอนุกรมเวลานั้นมาจากกระบวนการเชิงสุ่ม (random process) การนำข้อมูลอนุกรมเวลาไปใช้โดยไม่ได้ทำการตรวจสอบว่าข้อมูลมีลักษณะหนึ่งนั้น ค่าสถิติที่เกิดขึ้นจะมีการแจกแจงไม่มาตรฐาน ทำให้นำไปสู่การลงความเห็นว่าผิดพลาด กล่าวคือ R^2 มีค่าสูงมากและได้ค่าสถิติ t-test มีนัยสำคัญหรือสูงเกินกว่าความเป็นจริง

1) การทดสอบ DF (Dickey and Fuller test)

$$\text{กรณีตัวแปรไม่คงที่} \quad X_t = \rho X_{t-1} + \varepsilon_t \quad (2.7)$$

$$\text{โดยกำหนดสมมติฐานหลัก} \quad H_0 : \rho = 1$$

$$\text{และสมมติฐานรอง} \quad H_1 : |\rho| < 1$$

ถ้ายอมรับ $H_0 : \rho = 1$ แสดงว่าข้อมูลมีลักษณะไม่คงที่

แต่ถ้าปฏิเสธ $H_0 : \rho = 1$ หรือยอมรับ $H_1 : |\rho| < 1$ แสดงว่าข้อมูลนั้นมีลักษณะหนึ่ง

นอกจากนี้การทดสอบนี้ยังสามารถแปลงสมการได้ดังนี้ คือ

$$\text{กรณีไม่มีค่าคงที่และแนวโน้มเวลา} \quad \Delta X_t = \theta X_{t-1} + \varepsilon_t \quad (2.8)$$

$$\text{กรณีมีเฉพาะค่าคงที่} \quad \Delta X_t = \alpha + \theta X_{t-1} + \varepsilon_t \quad (2.9)$$

$$\text{กรณีมีทั้งค่าคงที่และแนวโน้มเวลา} \quad \Delta X_t = \alpha + \beta T + \theta X_{t-1} + \varepsilon_t \quad (2.10)$$

$$\text{โดยกำหนดสมมติฐานหลัก} \quad H_0 : \theta = 0$$

$$\text{และสมมติฐานรอง} \quad H_1 : \theta < 0$$

2) การทดสอบ ADF (Augmented Dickey and Fuller test)

การทดสอบอนุกรมเวลาที่มีปัญหา Serial Correlation ในค่า Error term (ε_t) เป็นการทดสอบที่ DF-Test ไม่สามารถทำได้ ดังนั้น ADF จึงเพิ่มค่า Lagged Change $\left[\sum_{i=1}^p \lambda_i \Delta X_{t-i} \right]$ เข้าไป จะได้ดังนี้

$$\text{กรณีไม่มีค่าคงที่และแนวโน้มเวลา} \quad \Delta X_t = \theta X_{t-1} + \sum_{i=1}^p \phi_i \Delta X_{t-i} + \varepsilon_t \quad (2.11)$$

$$\text{กรณีมีเฉพาะค่าคงที่} \quad \Delta X_t = \alpha + \theta X_{t-1} + \sum_{i=1}^p \phi_i \Delta X_{t-i} + \varepsilon_t \quad (2.12)$$

$$\text{กรณีมีทั้งค่าคงที่และแนวโน้มเวลา} \quad \Delta X_t = \alpha + \beta T + \theta X_{t-1} + \sum_{i=1}^p \phi_i \Delta X_{t-i} + \varepsilon_t \quad (2.13)$$

2.1.4 แบบจำลอง Autoregressive Integrated Moving Average (ARIMA)

แบบจำลอง Autoregressive Integrated Moving Average (ARIMA) ได้มีการศึกษาโดย George Box และ Gwilym Jenkins (1976) แต่ Wold (1938) ได้เป็นผู้ให้พื้นฐานทางทฤษฎีของกระบวนการหรือระบบ ARIMA บนพื้นฐานของ Wold แบบจำลอง ARIMA ได้ถูกพัฒนาขึ้นในสามทิศทาง ซึ่งได้แก่ ขั้นตอนการประมาณค่าและการบ่งชี้ที่มีประสิทธิภาพ (efficient identification and estimation procedures) (สำหรับกระบวนการหรือระบบ AR, MA และ ARMA) การคลอบคลุมไปถึงผลลัพธ์ที่ได้รวบรวมเอาอนุกรมเวลาเชิงฤดูกาล (seasonal time series) และการขยายของเขตไปเพื่อรวมเอากระบวนการหรือระบบไม่นิ่ง (nonstationary process (ARIMA)) เข้าไว้ด้วย (ทรงศักดิ์ ศรีบุญจิตต์, 2547)

โดยทั่วไปแล้วข้อมูลอนุกรมเวลาส่วนใหญ่มีลักษณะไม่นิ่ง (nonstationary) เนื่องจากข้อมูลอนุกรมเวลานั้นมาจากกระบวนการเชิงสุ่ม (random process) แต่ด้วยทฤษฎีของ AR และ MA หมายถึงข้อมูลอนุกรมเวลาที่มีลักษณะนิ่ง (stationary) ดังนั้นเมื่อข้อมูลที่รวบรวมได้มีลักษณะไม่นิ่ง เราจึงต้องทำการหาผลต่าง (differencing)

1) กระบวนการหรือระบบอัตถดถอย (Autoregressive Processes)

กระบวนการหรือระบบ AR (p) ซึ่งก็คือกระบวนการหรือระบบ AR ที่มีอันดับที่ p เขียนในรูปของ ARIMA (p,d,q) ได้ดังนี้คือ

ARIMA (p,0,0)

$$X_t = \mu' + \varphi_1 X_{t-1} + \varphi_2 X_{t-2} + \dots + \varphi_p X_{t-p} + e_t \quad (2.14)$$

โดยที่ μ' คือ พจน์คงที่หรือคงตัว (constant term)

φ_j คือ พารามิเตอร์อัตโนมัติเคลื่อนที่ตัวที่ j

e_t คือ พจน์ความคลาดเคลื่อน ณ เวลา t

2) กระบวนการหรือระบบเฉลี่ยเคลื่อนที่ (Moving Average Processes)

กระบวนการหรือระบบ MA(q) ซึ่งก็คือกระบวนการหรือระบบ MA ที่มีอันดับ q เขียนในรูปของ ARIMA(p,d,q) ได้ดังนี้คือ

ARIMA (0,0,q)

$$X_t = \mu' - e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (2.15)$$

โดยที่ μ' คือ พจน์คงที่หรือคงตัว (constant term)

θ_j คือ พารามิเตอร์เฉลี่ยเคลื่อนที่ตัวที่ j

e_t คือ พจน์ความคลาดเคลื่อน ณ เวลา t

ดังนั้นการผสมกันระหว่าง AR และ MA ในรูปของกระบวนการ หรือระบบ ARIMA สำหรับข้อมูลที่มีลักษณะนิ่ง (stationary) จะมีรูปแบบเป็น ARIMA (p,0,q) สมมติให้ AR(1) และ MA(1) เราสามารถเขียนในรูป ARIMA ได้คือ ARIMA (1,0,1) ดังจะแสดงในสมการต่อไปนี้

$$X_t = \mu' + \theta_1 X_{t-1} + e_t - \theta_1 e_{t-1}$$

$$\text{หรือ } (1 - \theta_1 B) X_t = \mu' + (1 - \theta_1 B) e_t$$

AR(1)

MA(1)

แต่ถ้าข้อมูลมีลักษณะไม่นิ่ง (nonstationary) จะต้องหาผลต่าง (difference) d ครั้ง เพื่อให้ข้อมูลมีลักษณะนิ่ง ดังนี้

ARIMA (1,1,1)

$$(1-B)(1-\phi_1 B)X_t = \mu' + (1-\theta_1 B)e_t$$

\uparrow \uparrow \uparrow
 First difference AR(1) MA(1)

หรือ

$$\left[1 - B(1 + \phi_1) + \phi_1 B^2\right] X_t = \mu' + e_t - \theta_1 e_{t-1}$$

$$X_t = (1 + \phi_1)X_{t-1} - \phi_1 X_{t-2} + \mu' + e_t - \theta_1 e_{t-1}$$

2.1.5 แบบจำลอง Autoregressive Conditional Heteroscedasticity (ARCH)

ในการวิเคราะห์อนุกรมเวลาส่วนใหญ่แล้วจะมีการกำหนด stochastic variable ให้มีความแปรปรวนคงที่ (homoscedastic) ซึ่งในการประยุกต์ใช้กับบางข้อมูลนั้นค่าความแปรปรวนของค่าความคลาดเคลื่อน (error term) จะไม่ใช่ฟังก์ชันของตัวแปรอิสระแต่มีค่าเปลี่ยนแปลงไปตามช่วง เวลาขึ้นอยู่กับขนาดของความคลาดเคลื่อนที่เกิดขึ้นในอดีต และในบางงานศึกษา เช่น แบบจำลองของเงินเพื่อ อัตราดอกเบี้ยหรือผลตอบแทนจากตลาดหลักทรัพย์ ในบางคาบเวลาจะมีค่าความผันผวน (volatility) สูง (และความคลาดเคลื่อนขนาดใหญ่) ตามด้วยคาบเวลาที่มีค่าความผันผวน (volatility) ต่ำ (และมีค่าความคลาดเคลื่อนที่มีขนาดเล็ก) สรุปได้ว่าค่าความแปรปรวนของค่าความคลาดเคลื่อนจากการถดถอยจะขึ้นอยู่กับค่าความผันผวน (volatility) ของความคลาดเคลื่อนในอดีตที่ผ่านมา (ทรงศักดิ์ ศรีบุญจิตต์, 2547: 641)

ความเป็นไปได้ในการหาค่าเฉลี่ยและความแปรปรวนของอนุกรมเวลาไปพร้อมกันนั้น ในขั้นตอนการพยากรณ์อย่างมีเงื่อนไขจะมีความแม่นยำเหนือกว่าการพยากรณ์อย่างไม่มีเงื่อนไขมาก ซึ่งจากแบบจำลอง Autoregressive Moving Average (ARMA) ซึ่งแสดงได้ดังนี้

$$X_t = a_0 + a_1 X_{t-1} + \varepsilon_t \quad (2.16)$$

และการพยากรณ์อย่างมีเงื่อนไขของ X_{t+1} ดังนี้คือ

$$E_t X_{t+1} = a_0 + a_1 X_t \quad (2.17)$$

และค่าเฉลี่ยแบบมีเงื่อนไขในการพยากรณ์ X_{t+1} ค่าความคลาดเคลื่อนของความแปรปรวนอย่างมีเงื่อนไขที่พยากรณ์ได้ดังนี้คือ

$$E_t \left[(X_{t+1} - a_0 - a_1 X_t)^2 \right] = E_t \varepsilon_{t+1}^2 = \sigma^2 \quad (2.18)$$

ถ้าเปลี่ยนไปใช้การพยากรณ์อย่างไม่มีเงื่อนไขแล้ว ผลที่จะใช้เป็นค่าเฉลี่ยในช่วง Long-Run ของลำดับ $\{X_t\}$ ซึ่งเท่ากับ $\frac{a_0}{(1-a_1)}$ จะได้ค่าความคลาดเคลื่อนของการพยากรณ์อย่างไม่มีเงื่อนไขดังนี้

$$\begin{aligned} E \left\{ \left(X_{t+1} - \frac{a_0}{1-a_1} \right)^2 \right\} &= E \left[(\varepsilon_{t+1} + a_1 \varepsilon_t + a_1^2 \varepsilon_{t-1} + a_1^3 \varepsilon_{t-2} + \dots)^2 \right] \\ &= \frac{\sigma^2}{(1-a_1)^2} \end{aligned} \quad (2.19)$$

เนื่องจาก $\frac{1}{(1-a_1)^2} > 1$ เพราะฉะนั้นความแปรปรวน (variance) จากการพยากรณ์แบบไม่มีเงื่อนไข (unconditional variance) จึงมีค่าสูงกว่าความแปรปรวนของการพยากรณ์แบบมีเงื่อนไข ในลักษณะเดียวกันถ้าความแปรปรวนของ $\{\varepsilon_t\}$ ไม่เป็นค่าคงที่ จะสามารถประมาณค่าแนวโน้มของการเปลี่ยนแปลงความแปรปรวนโดยใช้ ARMA Model โดยให้ ε_t แทนส่วนที่เหลือที่ได้จากการประมาณจากสมการ(2.10) ดังนั้น ค่าความแปรปรวนแบบมีเงื่อนไขของ X_{t+1} จะได้ดังนี้

$$\text{Var}(X_{t+1} | X_t) = E \left[(X_{t+1} - a_0 - a_1 X_t)^2 \right] = E_t \varepsilon_{t+1}^2 \quad (2.20)$$

และจากที่ให้ $E_t \varepsilon_{t+1}^2 = \sigma_{t+1}^2$ จึงแสดงว่าความแปรปรวนอย่างมีเงื่อนไขไม่ใช่ค่าคงที่และจะได้แบบจำลองในการประมาณค่าส่วนที่เหลือ (residuals) ออกมาดังนี้

$$\varepsilon_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \dots + \alpha_q \varepsilon_{t-q}^2 + V_t \quad (2.21)$$

เมื่อ V_t =white noise process

ถ้าค่าของ $\alpha_1, \alpha_2, \dots, \alpha_q$ มีค่าเท่ากับศูนย์ ความแปรปรวนที่ประมาณค่ามาได้ (estimated variance) จะมีค่าคงที่หรือคงตัว (constant variance) α_0 อีกนัยหนึ่ง คือ ค่าความแปรปรวนอย่างมีเงื่อนไขของ X_t จะมีการเปลี่ยนแปลงสอดคล้องกับในสมการ (2.21) และค่าพยากรณ์สามารถเขียนได้ดังนี้

$$E_t \hat{\varepsilon}_{t+1}^2 = \alpha_0 + \alpha_1 \hat{\varepsilon}_t^2 + \alpha_2 \hat{\varepsilon}_{t-1}^2 + \dots + \alpha_q \hat{\varepsilon}_{t+1-q}^2 \quad (2.22)$$

จากเหตุผลที่กล่าวมา สมการ (2.21) เรียกว่า Autoregressive Conditional Heteroscedastic (ARCH) Model และสมการ (2.22) เป็น ARCH(q) โดยค่า $E_t \hat{\varepsilon}_{t+1}^2$ หรือ σ_{t+1}^2 จะประกอบด้วย 2 องค์ประกอบ คือ ค่าคงที่และความผันผวน (volatility) ในคาบเวลาที่ผ่านมา ซึ่งเขียนได้เป็นส่วนเหลือกำลังสองของคาบในอดีต (ARCH term) ส่วนค่าสัมประสิทธิ์ ($\alpha_0, \alpha_1, \dots, \alpha_q$) สามารถหาค่าได้โดยใช้วิธี Maximum likelihood

2.1.6 แบบจำลอง Generalized Autoregressive Conditional Heteroscedasticity (GARCH)

แบบจำลอง ARCH ของ Engle, Robert F. ได้มีการพัฒนาต่อโดย Bollerslev ในปี 1986 ด้วยการให้ความแปรปรวนแบบมีเงื่อนไข (conditional variance) มีลักษณะเป็น ARMA process โดยที่ให้ error process มีลักษณะดังนี้

$$\varepsilon_t = V_t \sqrt{\sigma_t^2} \quad (2.23)$$

โดยที่ความแปรปรวนของ $V_t = \sigma_v^2 = 1$ และ

$$\sigma_t^2 = \omega + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2 \quad (2.24)$$

เมื่อ $\{V_t\}$ คือ White noise process ที่เป็นค่าอิสระจากเหตุการณ์ในอดีต (ε_{t-1}) ค่าเฉลี่ยแบบมีเงื่อนไขของ ε_t จะเท่ากับศูนย์ ดังนี้

$$E\varepsilon_t = EV_t\sqrt{\sigma_t^2} = 0$$

ประเด็นสำคัญในการหาความแปรปรวนแบบมีเงื่อนไขของ ε_t ถูกกำหนดโดย

$$E_{t-1}\varepsilon_t^2 = \sigma_t^2 = \omega + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2 \quad (2.25)$$

โดยที่ $\omega > 0$ และ $\left(\sum_{i=1}^q \alpha_i + \sum_{j=1}^p \beta_j \right) < 1$

ดังนั้นความแปรปรวนแบบมีเงื่อนไขของ ε_t ถูกกำหนดโดย σ_t^2 ในสมการ(2.25) แบบจำลองนี้จึงเรียกว่า Generalized Autoregressive Conditional Heteroscedasticity (GARCH) หรือ GARCH (p,q) นั้นใช้กระบวนการ Autoregressive และ Moving Average ในการหาความแปรปรวนที่มีลักษณะ Heteroscedastic Variance จะเห็นว่า ถ้า p=0 และ q=1 เป็น GARCH (0,1) หรือคือ ARCH (1) นั่นเอง โดยสรุปว่าถ้า β_j ทั้งหมดมีค่าเป็นศูนย์แบบจำลอง GARCH (p,q) จะเทียบเท่ากับแบบจำลอง ARCH (q) คุณสมบัติที่สำคัญของแบบจำลอง GARCH คือค่าความแปรปรวนอย่างมีเงื่อนไขของ disturbances ของค่า X_t สร้างขึ้นมาจากกระบวนการ ARMA จึงสามารถคาดได้ว่าส่วนเหลือจากการทำ ARMA จะแสดงถึงรูปแบบคุณลักษณะเดียวกัน เช่น ถ้าการประมาณค่า $\{X_t\}$ ด้วยกระบวนการ ARMA ค่า Autocorrelation Function (ACF) ซึ่งเป็นสหสัมพันธ์ระหว่างตัวแปรสุ่มที่หน่วยเวลาห่างกันของกระบวนการเดียวกันและ Partial Autocorrelation Function (PACF) ของส่วนที่เหลือ (residuals) ควรจะบ่งถึงกระบวนการ white noise และ ACF ของกำลังสองของส่วนที่เหลือ (squared residuals) นำมาช่วยในการระบุถึงลำดับ (order) ของกระบวนการ GARCH (ทรงศักดิ์ ศรีบุญจิตต์, 2547: 648)

แบบจำลอง GARCH ต่างๆนอกจากใช้ได้ประสบผลสำเร็จ แต่ก็มีข้อเสียอยู่สองประการในการประยุกต์ใช้กับการตั้งหรือคำนวณค่าทรัพย์สินประเภททุน

ประการแรก คือ ในกระบวนการ GARCH แบบสมมาตรนั้น ถ้ามีความผิดปกติ หรือ SHOCK เกิดขึ้นไม่ว่าในทางบวกหรือทางลบ แต่อยู่ในระดับหรือขนาดเดียวกัน ซึ่งให้ระดับความไม่แน่นอนที่เท่ากันแล้ว ค่าความแปรปรวนอย่างมีเงื่อนไขก็จะเพิ่มขึ้นในทางบวกหรือทางลบอย่างมากจนน่าตกใจ (Booerslev, 1986) อย่างไรก็ตาม Black (1976) ได้พบความสัมพันธ์ที่เป็นลบหรือตรงกันข้ามกันระหว่างผลตอบแทนในปัจจุบันกับความไม่แน่นอนที่เกิดจากความผันผวน (Volatility) ในอนาคต เช่น ความไม่แน่นอนมักจะสูง เมื่อมีข่าวร้ายและลดลงเมื่อมีข่าวดี ลักษณะ

ความไม่สมมาตรของความแปรปรวนแบบมีเงื่อนไขนี้ เรียกว่า leverage effect คือ อิทธิพลจากค่ายกกำลัง ซึ่งแบบจำลอง GARCH แบบเส้นตรงไม่สามารถจับรูปแบบนี้ให้เห็นได้ เพราะค่าบวกหรือลบของผลตอบแทนในอดีตจะไม่มีส่วนมากำหนดความไม่แน่นอนที่ผันผวนในอนาคต หรือกล่าวเฉพาะขนาดของค่าความคลาดเคลื่อนจากการประมาณการถดถอยโดยมีการทอดระยะเวลา (lagged residuals) เท่านั้นที่มีส่วนกำหนดค่าความแปรปรวนอย่างมีเงื่อนไข แต่ความเป็นบวกหรือลบของค่าความคลาดเคลื่อนไม่มีส่วนเกี่ยวข้อง ซึ่งข้อจำกัดนี้เป็นจุดสำคัญประการแรกที่ทำให้มีการพัฒนาแบบจำลอง EGARCH และ TGARCH

ประการที่สอง แบบจำลอง GARCH ต่างๆ กำหนดให้ตัวแปรต่างๆ ต้องไม่เป็นค่าลบเพื่อบังคับค่าความแปรปรวนอย่างมีเงื่อนไขมีค่าเป็นบวกเสมอ อย่างไรก็ตามข้อกำหนดบังคับนี้มักถูกฝ่าฝืนจากค่าสัมประสิทธิ์ที่ได้มาจากการคำนวณ

2.1.7 แบบจำลอง Exponential GARCH (EGARCH)

EGARCH หรือ Exponential GARCH model ถูกเสนอโดย Nelson (1991) EGARCH model ให้ความแปรปรวนอย่างมีเงื่อนไขมีค่าดังสมการ

$$\log(\sigma_t^2) = \omega + \sum_{j=1}^p \beta_j \log(\sigma_{t-j}^2) + \sum_{i=1}^q \left(\alpha_i \left| \frac{\varepsilon_{t-i}}{\sigma_{t-i}} \right| + \theta_i \frac{\varepsilon_{t-i}}{\sigma_{t-i}} \right) \quad (2.26)$$

โดยที่ $\omega > 0$ และ $\sum_{j=1}^p \beta_j < 1$

ด้านซ้ายมือของสมการ คือ ค่า Log ของค่าความแปรปรวนอย่างมีเงื่อนไข หมายความว่าอิทธิพลจากค่ายกกำลัง (leverage effect) เป็นค่าเลขยกกำลังสูง (Exponential) ดังนั้นการทำนายค่าความแปรปรวนอย่างมีเงื่อนไข จะได้ค่าที่ไม่เป็นลบเสมอ

นอกจากนี้การประมาณค่าแบบจำลอง EGARCH โดยใช้โปรแกรม Eviews จะมีข้อแตกต่างระหว่างโมเดลของ Nelson อยู่สองประการคือ

- 1) Nelson มีสมมติฐานว่า ค่าความคลาดเคลื่อน มีการแจกแจงแบบ general distribution ส่วน Eviews มีสมมติฐานว่า ค่าความคลาดเคลื่อน มีการแจกแจงแบบ normal distribution
- 2) ค่า log ของความแปรปรวนอย่างมีเงื่อนไข มีลักษณะแตกต่างกันเล็กน้อยดังนี้

Nelson

$$\log(\sigma_t^2) = \omega + \beta \log(\sigma_{t-1}^2) + \left(\alpha \left| \frac{\varepsilon_{t-1}}{\sigma_{t-1}} \right| + \sqrt{\frac{2}{\Pi}} \right) + \theta \frac{\varepsilon_{t-1}}{\sigma_{t-1}} \quad (2.27)$$

Eviews

$$\log(\sigma_t^2) = \omega + \sum_{j=1}^p \beta_j \log(\sigma_{t-j}^2) + \sum_{i=1}^q \left(\alpha_i \left| \frac{\varepsilon_{t-1}}{\sigma_{t-1}} \right| + \theta \frac{\varepsilon_{t-1}}{\sigma_{t-1}} \right) \quad (2.28)$$

ในการประมาณค่าแบบจำลองภายใต้สมมติฐานที่ว่าค่าความคลาดเคลื่อน มีการแจกแจงแบบ normal distribution ของ Eviews นั้นจะให้ค่าที่เหมือนกันยกเว้นค่า intercept term ω ที่แตกต่างกันเท่ากับ $\alpha \sqrt{\frac{2}{\Pi}}$

2.1.8 แบบจำลอง Threshold GARCH (TGARCH)

Threshold GARCH ถูกนำเสนอโดย Zakoian (1994) and Glosten, Jagannathan, and Runkle (1993). โดย TGARCH model ให้ความแปรปรวนอย่างมีเงื่อนไขมีค่าดังสมการ

$$\sigma_t^2 = \omega + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2 + \sum_{k=1}^r \gamma_k \varepsilon_{t-k}^2 d_{t-k} \quad (2.29)$$

โดย d_t เป็นตัวแปรหุ่น

และ $d_t = 1$, เมื่อ $\varepsilon_{t-1} < 0$

$d_t = 0$, เมื่อ $\varepsilon_{t-1} \geq 0$

ในแบบจำลองนี้ positive shocks คือ $\varepsilon_{t-i} \geq 0$ negative shocks คือ $\varepsilon_{t-i} < 0$ มีผลกระทบแตกต่างกันขึ้นกับความแปรปรวนแบบมีเงื่อนไข ถ้าเป็น positive shocks มีผลต่อ α_i ขณะที่ negative shocks มีผลต่อ $\alpha_i + \gamma_i$

ถ้า $\gamma_k > 0$ negative shocks จะทำให้ความผันผวนเพิ่มขึ้นสูง


ถ้า $\gamma_k \leq 0$ positive shocks จะทำให้ความผันผวนเพิ่มขึ้นแต่น้อยกว่า negative shocks

ดังนั้นจึงเรียกว่า Leverage effect คือ ความไม่แน่นอนมักจะสูง เมื่อมี negative shocks และลดลงเมื่อมี positive shocks ตามลักษณะความไม่สมมาตรของความแปรปรวนแบบมีเงื่อนไข

2.1.9 การพยากรณ์ (Forecasting)

การศึกษานี้ได้แบ่งการพยากรณ์ออกเป็น 3 ช่วงคือ Historical Forecast Ex-post Forecast และ Ex-ante Forecast โดย Historical Forecast คือ การพยากรณ์ข้อมูลในอดีตจนถึงช่วงเวลาที่พิจารณา และเนื่องจากการพยากรณ์ข้อมูลล่วงหน้าจะทำให้เกิดข้อจำกัดที่ว่าความแม่นยำของข้อมูลที่ได้จากการพยากรณ์นั้น มีความน่าเชื่อถือมากน้อยเพียงใด และแบบจำลองอาร์มา เหมาะสำหรับการพยากรณ์ในระยะสั้น ดังนั้นเพื่อที่จะทราบว่าแบบจำลองที่ประมาณขึ้นมาสามารถที่จะพยากรณ์ได้ถูกต้องแม่นยำเพียงใด ได้ใช้การพยากรณ์แบบ Ex-post Forecast กล่าวคือ เป็นการพยากรณ์ข้อมูล ณ ช่วงเวลาที่มีข้อมูลจริงเกิดขึ้นแล้ว ยกตัวอย่างเช่น จะลดจำนวนค่าสังเกตของอนุกรมเวลาจากข้อมูลที่มีทั้งหมด n ข้อมูล เหลือ $n-5$ ข้อมูล แล้วทำการถดถอยข้อมูลใหม่เพื่อหาค่า RMSE (Root Mean Squared Error) และทำการพยากรณ์ล่วงหน้า (Ex-post Forecast) จำนวน 5 ข้อมูล เพื่อเปรียบเทียบกับข้อมูลจริงที่มีอยู่ และก็จะได้ค่า RMSE แล้วใช้ค่าสถิติดังกล่าวประกอบการพิจารณาเลือกแบบจำลองที่มีความเหมาะสม เมื่อได้แบบจำลองที่เหมาะสมภายหลังจากการวิเคราะห์ความถูกต้องแล้ว ก็สามารถนำแบบจำลองดังกล่าวใช้ในการพยากรณ์

รูปที่ 2.2 แสดงช่วงเวลาที่ใช้ในการพยากรณ์



ที่มา: Pindyck and Rubinfeld (1998)

ภายหลังจากที่เลือกแบบจำลองที่ใช้เป็นตัวแทนอนุกรมเวลาข้อมูลได้แล้ว จะทำการพยากรณ์ล่วงหน้า (Ex-ante Forecast) กล่าวคือเป็นการพยากรณ์ในช่วงเวลาที่ยังไม่มีข้อมูลจริงเกิดขึ้นต่อไป

2.1.10 การตรวจสอบรูปแบบ (Diagnostic Checking)

การสร้างสมการที่ใช้ในการประมาณค่าพารามิเตอร์นั้น จะต้องทำการตรวจสอบรูปแบบว่าสมการที่ได้มามีความเหมาะสมหรือไม่ และรูปแบบใดของสมการเป็นรูปแบบที่ดีที่สุด โดยใช้การทดสอบดังนี้

1) การทดสอบ Ljung-Box Q-Statistic

การทดสอบ Ljung-Box Q-Statistic เป็นการทดสอบว่าสหสัมพันธ์ในตัวเองในส่วนเหลือทุกช่วงเวลาที่ยาวกัน k มีความเป็นอิสระกันหรือไม่ โดยมีสมมติฐานดังนี้

$$H_0 : \rho(a_1) = \rho(a_2) = \dots = \rho(a_k) = 0$$

$$H_1 : \rho(a_1) \neq \rho(a_2) \neq \dots \neq \rho(a_k) \neq 0$$

จะได้

$$Q_{LB} - stat = T(T+2) \sum (r_j^2 / T - j) \quad (2.30)$$

เมื่อ r_j คือสหสัมพันธ์ในตัวเองลำดับที่ j โดยที่ $j=1, \dots, k$

T คือจำนวนค่าสังเกต

โดย Q_{LB} มีการแจกแจงแบบไคสแควร์ (χ^2) ด้วยระดับความเป็นอิสระ (Degree of Freedom) เท่ากับจำนวนของสายสัมพันธ์ในตัวเองลบด้วยจำนวนของพารามิเตอร์ Autoregressive (AR) และ Moving Average (MA) ที่ได้มาจากการประมาณหรือ $k-m$

จะยอมรับสมมติฐานหลักเมื่อ $Q_{LB} \leq \chi_{\alpha, k-m}^2$ คือส่วนที่เหลือเป็นอิสระต่อกันที่ความล่าช้า k และถ้าปฏิเสธสมมติฐานหลักเมื่อ $Q_{LB} \geq \chi_{\alpha, k-m}^2$ คือเกิดสหสัมพันธ์ในตัวเองอย่างน้อยหนึ่งค่าในส่วนเหลือที่ไม่เท่ากับศูนย์

2) เกณฑ์การเลือกรูปแบบของแบบจำลองที่ดีที่สุด (Information criteria)

ในการหารูปแบบของแบบจำลองที่ดีที่สุด โดยพิจารณาจากค่า Akaike Information Criterion (AIC) และ Schwartz Criterion (SC) ซึ่งรูปแบบของแบบจำลองที่ให้ค่า AIC และ SC น้อยที่สุดจะเป็นรูปแบบที่ดีที่สุด สามารถคำนวณได้ดังนี้

$$\text{Akaike Information Criterion (AIC)} \quad -2l/\eta + 2k/\eta \quad (2.31)$$

$$\text{Schwartz Criterion (SC)} \quad -2l/\eta + k \log \eta/\eta \quad (2.32)$$

โดยที่ k เป็นจำนวนของพารามิเตอร์ที่ทำการประมาณค่า

η เป็นจำนวนของค่าสังเกต

l เป็นค่าของ log likelihood function ที่ใช้พารามิเตอร์ที่ถูกประมาณค่า k ตัว

2.1.11 การทดสอบความแม่นยำของการพยากรณ์ที่ได้

ในการศึกษาครั้งนี้จะทำการทดสอบความแม่นยำของการพยากรณ์ด้วยวิธี รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย RMSE (Root Mean Squared Error) ซึ่งเป็นการวัดค่าความแตกต่างระหว่างค่าจริง และค่าที่ประมาณได้จากแบบจำลอง ถ้า RMSE มีค่าน้อย แสดงว่าแบบจำลองสามารถประมาณค่าประมาณได้ใกล้เคียงกับค่าจริง (Pindyck and Rubinfeld, 1998) ดังนั้นหากมีค่าเท่ากับศูนย์แล้ว จะหมายความว่า ไม่เกิดความคลาดเคลื่อนในแบบจำลองนี้เลย โดย RMSE คำนวณได้ดังนี้

$$RMSE = \sqrt{\frac{1}{T} \sum_{t=1}^T (Y_t^s - Y_t^a)^2} \quad (2.33)$$

โดยกำหนด Y_t^s = ค่าประมาณจากแบบจำลอง

Y_t^a = ค่าที่แท้จริง

T = จำนวนคาบเวลาที่ใช้ในการประมาณแบบจำลอง

2.2 เอกสารและงานวิจัยที่เกี่ยวข้อง

เยาวลักษณ์ จันทรดี (2547) ได้ทำการศึกษาเรื่องการวิเคราะห์ทางเทคนิคด้วยแบบจำลองการช่อ้ม ในหลักทรัพย์กลุ่มสื่อสาร โดยได้ศึกษาถึงการนำเอาเทคนิคการช่อ้มมาประยุกต์ใช้ และทำการทดสอบความแม่นยำของแบบจำลองการช่อ้มซึ่งในการศึกษาได้ใช้ข้อมูลหลักทรัพย์ในกลุ่มสื่อสารจำนวน 5 หลักทรัพย์ ประกอบด้วย บริษัท แอดวานซ์ อินโฟ เซอร์วิส จำกัด (มหาชน) ADVA บริษัทชินคอร์ปอเรชั่น จำกัด (มหาชน) SHIN บริษัท เทเลคอม เอเชีย จำกัด (มหาชน) TA บริษัท ทีแอนดีที จำกัด (มหาชน) TTNT บริษัท ยูไนเต็ล คอมมูนิเคชั่น จำกัด (มหาชน) UCOM ซึ่งเป็นหลักทรัพย์ที่มีสัดส่วนประมาณร้อยละสูงสุด 5 อันดับแรก ของหลักทรัพย์ในกลุ่มสื่อสาร โดยใช้ข้อมูลราคาปิดของหลักทรัพย์รายสัปดาห์ ตั้งแต่เดือนมกราคม 2542 ถึงเดือนธันวาคม 2546 รวม 260 สัปดาห์ในการศึกษาได้แบ่งการศึกษากออกเป็นสองส่วน ในส่วนแรกได้ทำการศึกษาถึงความสัมพันธ์ของการเคลื่อนไหวของราคาหลักทรัพย์ในปัจจุบันกับราคาปิดของหลักทรัพย์ในอดีต และความเสียหายที่แทนด้วยความแปรปรวนอย่างมีเงื่อนไขของหลักทรัพย์ด้วยแบบจำลอง ARMA ด้วยเทคนิค GARCH-M ผลการศึกษาพบว่าทุกหลักทรัพย์ยกเว้น UCOM มีราคาปิดในปัจจุบันขึ้นอยู่กับราคาปิดอย่างมีนัยสำคัญแต่หลักทรัพย์ทุกตัวมีราคาปิดในปัจจุบันขึ้นอยู่กับความคลาดเคลื่อนในอดีตอย่างมีนัยสำคัญ และในข้อมูลหลักทรัพย์ ADVA SHIN และ TA ปรากฏเพียงเทอมของ ARCH แต่ของ TTNT และ UCOM ปรากฏทั้งเทอมของ ARCH และ GARCH เป็นตัวแสดงถึงความแปรปรวนอย่างมีเงื่อนไขที่เกิดขึ้น

ส่วนที่สองได้ศึกษาการวิเคราะห์หลักทรัพย์ทางด้านเทคนิค แบบจำลอง ARMA ด้วยเทคนิค GARCH-M และเปรียบเทียบประสิทธิภาพในการวิเคราะห์ทางเทคนิคของช่วงความเชื่อมั่นที่ได้กับดัชนีกำลังสัมพันธ์ (RSI) โดยจำลองสถานการณ์การช่อ้มหลักทรัพย์ให้ขึ้นอยู่กับสัญญาณช่อ้มที่เกิดขึ้น ผลการศึกษาพบว่า ช่วงความเชื่อมั่นจากแบบจำลองจะให้สัญญาณช่อ้มดีกว่าดัชนีกำลังสัมพันธ์ ซึ่งจะเหมาะกับนักลงทุนระยะสั้น ในหลักทรัพย์ SHIN และ TA ช่วงความเชื่อมั่นจากแบบจำลอง ARMA ด้วยเทคนิค GARCH-M ให้ผลตอบแทนดีกว่าดัชนีกำลังสองสัมพันธ์ แต่หลักทรัพย์ ADVA, TTNT และ UCOM ดัชนีกำลังสัมพันธ์ ให้ผลตอบแทนดีกว่าช่วงความเชื่อมั่นจาก ARMA ด้วยเทคนิค GARCH-M

จิตติ ตันเสนีย์ (2548) ทำการเปรียบเทียบความแม่นยำในการพยากรณ์ราคาหลักทรัพย์ระหว่างแบบจำลองนิเวศน์กับแบบจำลองอีมาและอีการช่อ้ม การศึกษาแบ่งเป็นสองส่วน ในส่วนแรกทำการศึกษาเพื่อหาแบบจำลอง Neural Networks และแบบจำลอง ARIMA with EGARCH-M ที่ดีที่สุดของข้อมูลแต่ละชุดเพื่อใช้สำหรับการพยากรณ์ และส่วนที่สองเป็นการนำผล

การพยากรณ์ของแบบจำลองทั้งสองค่ามาเปรียบเทียบกันโดยใช้ค่า MAPE (Mean Absolute percentage Error) โดยในการศึกษาได้ใช้ดัชนีราคาหุ้นตลาดหลักทรัพย์แห่งประเทศไทย (SET Index) คัดนี้ SET 50 ราคาหลักทรัพย์ของบริษัท PTT TPI และ BBL ซึ่งเป็นหลักทรัพย์ที่มีมูลค่าการซื้อขายสูงสุดในช่วงปี 2546 – 2548 โดยใช้ข้อมูลตั้งแต่วันที่ 1 มกราคม 2548 ถึง 31 ธันวาคม 2548 เป็นจำนวน 783 วัน

ผลการศึกษการพยากรณ์ด้วยแบบจำลอง Neural Networks ของข้อมูล SET 50 PTT TPI BBL ได้ค่า MAPE เท่ากับ 1.2956 1.2928 1.5367 3.4879 และ 1.1967 และในแบบจำลอง ARIMA with EGARCH-M ได้ค่า MAPE เท่ากับ 0.5972 0.6980 1.1554 2.1304 และ 0.9382 ตามลำดับ ดังนั้นในการศึกษาครั้งนี้เมื่อประเมินด้วย MAPE พบว่าแบบจำลอง ARIMA with EGARCH-M มีความแม่นยำในการพยากรณ์สูงกว่าแบบจำลอง Neural Networks

นทพร จำปาวัน(2550) ทำการศึกษการประมาณค่าความผันผวนสำหรับอัตราแลกเปลี่ยนของประเทศไทยโดยแบบจำลองอาร์มาร์คซ์และแบบจำลองอาร์มาร์คซ์ โดยทำการหาแบบจำลองที่เหมาะสมเพื่อใช้ประมาณค่าความผันผวนของผลตอบแทนของอัตราแลกเปลี่ยนของประเทศไทยโดยใช้ข้อมูลราคาปิดรายวันของอัตราแลกเปลี่ยนตั้งแต่เดือน มกราคม 2546 ถึงเดือน มิถุนายน 2549 จำนวน 856 ข้อมูล โดยผลการศึกษาพบว่าแบบจำลองที่มีความเหมาะสมมากที่สุดคือแบบจำลอง AR(6) MA(6) และ GARCH(1,1) และแบบจำลอง AR(6) MA(6) และ EGARCH(1,1) และได้ให้ข้อสรุปว่าแบบจำลองที่เหมาะสมในการพยากรณ์ผลตอบแทนของอัตราแลกเปลี่ยนเป็นแบบจำลองที่แตกต่างกันขึ้นอยู่กับลักษณะการเคลื่อนไหวของอัตราแลกเปลี่ยน

ปิยนุช เรืองขจร (2549) ทำการประมาณค่าความผันผวนของผลตอบแทนของราคาน้ำมันดิบ ถ่านหิน และก๊าซธรรมชาติโดยวิธีอาร์มาร์คซ์ อาร์มาร์คซ์เอ็มและอาร์มาร์คซ์ ซึ่งใช้ข้อมูลอนุกรมเวลาราคาปิดรายวันของราคาน้ำมันดิบเบรนท์ในตลาดซื้อขายล่วงหน้า NYMEX ของประเทศสหรัฐอเมริกา จำนวน 1,040 ข้อมูล ข้อมูลราคาปิดของราคาถ่านหิน จำนวน 876 ข้อมูล และข้อมูลปิดรายวันของตลาดประเทศสหรัฐอเมริกา จำนวน 881 ข้อมูล

ผลการทดสอบ unit root โดยวิธี Augmented Dickey-Fuller test (ADF test) พบว่าข้อมูลผลตอบแทนของราคาพลังงานทั้ง 3 ชนิดมีลักษณะนิ่งที่ระดับ Level (I(0)) จากการพิจารณาผลคอเรลโลแกรม ได้ทำการเลือกแบบจำลองที่เหมาะสมเพียงรูปแบบเดียวสำหรับผลตอบแทนราคาพลังงานแต่ละชนิดโดยใช้ แบบจำลองอาร์มาร์คซ์ อาร์มาร์คซ์เอ็มและอาร์มาร์คซ์ และเมื่อทำการตรวจสอบความถูกต้องของแบบจำลองทั้งหมดพบว่า มีลักษณะเป็น white noise ณ ระดับนัยสำคัญทางสถิติที่ 0.05 ผลการพยากรณ์ผลตอบแทนของราคาพลังงานแต่ละชนิดในช่วง

historical forecast และ ex-post forecast พบว่าแบบจำลองที่ให้ค่า root mean square error ต่ำที่สุด สำหรับผลตอบแทนของราคาน้ำมันดิบ ถ่านหิน และก๊าซธรรมชาติคือ แบบจำลอง AR(1) AR(9) MA(1) MA(9) MA(14) และ E-GARCH(1,2) , แบบจำลอง AR(1) AR(10) MA(1) MA(10) และ GARCH(1,1) และแบบจำลอง AR(2) AR(10) MA(2) MA(10) และ GARCH(1,1) ตามลำดับ ดังนั้นแบบจำลองดังกล่าวจึงมีความเหมาะสมที่สุดในการพยากรณ์ผลตอบแทนล่วงหน้าในอนาคตของราคาน้ำมันดิบ ถ่านหิน และก๊าซธรรมชาติ



ลิขสิทธิ์มหาวิทยาลัยเชียงใหม่
Copyright© by Chiang Mai University
All rights reserved