บทที่ 3
ระเบียบวิธีการวิจัย

3.1 ข้อมูลที่ใช้ในการศึกษา

ข้อมูลที่ใช้ในการศึกษาเป็นข้อมูลทุติยภูมิแบบรายปี ซึ่งทำการเก็บรวบรวมจาก 5 แหล่ง คือ สำนักงานคณะกรรมพัฒนาการเศรษฐกิจและสังคมแห่งชาติ ธนาคารโลก กองทุนเงินระหว่างประเทศ กระทรวงศึกษาธิการ และระบบฐานข้อมูลด้านสังคมและคุณภาพชีวิต ได้แก่ สัมประสิทธิ์จีนี่ (Gini Coefficient) รายได้มวลรวมประชาชาติต่อหัวประชากร (Gross National Income per Capita) อัตราเงินเฟ้อ (Inflation Rate) อัตราการว่างงาน (Unemployment Rate) ร้อยละของนักเรียน นิสิต และนักศึกษา ต่อประชากรในวัยเรียน และอัตราการเปิดประเทศ (Degree of openness) ตั้งแต่ปี พ.ศ. 2533 ถึงปี พ.ศ. 2552

3.2 แบบจำลองที่ใช้ในการศึกษา

ในการศึกษาผลกระทบของตัวแปรด้านเศรษฐกิจและคุณภาพชีวิตต่อการกระจายรายได้ในประเทศไทย โดยใช้วิธีเบย์เซียน ออโต้รีเกรสชั่นนั้น ตัวแปรที่ใช้ในการศึกษา ได้แก่ สัมประสิทธิ์จีนี่ (Gini Coefficient) รายได้มวลรวมประชาชาติต่อหัวประชากร (Gross National Income per Capita) อัตราเงินเฟ้อ (Inflation Rate) อัตราการว่างงาน (Unemployment Rate) ร้อยละของนักเรียน นิสิต และนักศึกษา ต่อประชากรในวัยเรียน และอัตราการเปิดประเทศ (Degree of openness)โดยแบบจำลองความสัมพันธ์สามารถแสดงได้ดังนี้

$$GINI = \mathrm{f}\,(GNI, INF, UER, EDU, DO)$$

โดยที่

$GINI$ คือ สัมประสิทธิ์จีนี่

GNI คือ รายได้มวลรวมประชาชาติต่อหัวประชากร

INF คือ อัตราเงินเฟ้อ

UER คือ อัตราการว่างงาน

EDU คือ ร้อยละของนักเรียน นิสิต และนักศึกษา ต่อประชากรในวัยเรียน

DO คือ อัตราการเปิดประเทศ

3.3 สมมติฐานในการศึกษา

โดยการศึกษาครั้งนี้ ได้อธิบายความสัมพันธ์ระหว่างตัวแปร ซึ่งได้กำหนดไว้ในแบบจำลองดังกล่าวข้างต้น ซึ่งมีสมมติฐานการวิจัยดังนี้

1. รายได้มวลรวมประชาชาติต่อหัวประชากร (Gross National Income per Capita) คาดว่าจะมีความสัมพันธ์ในทิศทางตรงกันข้ามกับสัมประสิทธิ์จีนี่ หมายความว่า ถ้ารายได้มวลรวมประชาชาติต่อหัวประชากรเพิ่มสูงขึ้นแล้วจะทำให้สัมประสิทธิ์จีนี่ของประเทศนั้นๆ ลดต่ำลง (ศุภกร สารารัตน์ และคณะ, 2549; ราเชนทร์ ชินทยารังสรรค์, 2554)

2. อัตราเงินเฟ้อ (Inflation Rate) คาดว่าจะมีความสัมพันธ์ในทิศทางเดียวกับสัมประสิทธิ์จีนี่ หมายถึง ถ้าอัตราเงินเฟ้อเพิ่มสูงขึ้นแล้วจะทำให้สัมประสิทธิ์จีนี่ของประเทศนั้นๆ เพิ่มสูงขึ้นเช่นกัน (สมศจี ศิกษมัต, 2554)

3. อัตราการว่างงาน (Unemployment Rate) คาดว่าจะมีความสัมพันธ์ในทิศทางเดียวกับสัมประสิทธิ์จีนี่ หมายความว่า ถ้าอัตราการว่างงานเพิ่มสูงขึ้นแล้วจะทำให้สัมประสิทธิ์จีนี่ของประเทศนั้นๆ เพิ่มสูงขึ้นเช่นกัน (ศิรินธร เอี๊ยบศิริเมธี, 2544)

4. ร้อยละของนักเรียน นิสิต และนักศึกษา ต่อประชากรในวัยเรียน คาดว่าจะมีความสัมพันธ์ในทิศทางตรงกันข้ามกับสัมประสิทธิ์จีนี่ หมายความว่า ถ้าร้อยละของนักเรียน นิสิต และนักศึกษา ต่อประชากรในวัยเรียนสูงขึ้นแล้วจะทำให้สัมประสิทธิ์จีนี่ของประเทศนั้นๆ ลดต่ำลง (ธันวา จิตต์สงวน และรัชนี ชัยยาภรณ์, 2546; ศุภกร สารารัตน์ และคณะ, 2549; ราเชนทร์ ชินทยารังสรรค์, 2554)

5. อัตราการเปิดประเทศ คาดว่าจะมีความสัมพันธ์ในทิศทางตรงกันข้ามกับสัมประสิทธิ์จีนี่ หมายถึง ถ้าอัตราการเปิดประเทศเพิ่มสูงขึ้นแล้วจะทำให้สัมประสิทธิ์จีนี่ของประเทศนั้นๆ ลดต่ำลง (จิระ บุรีคำ, 2544)

3.4 วิธีการวิเคราะห์ข้อมูล

ในงานวิจัยนี้จะทำการศึกษาและเปรียบเทียบความแม่นยำในการพยากรณ์การกระจายรายได้ระหว่างวิธีเบย์เซียน เวคเตอร์ออโต้ รีเกรสชั่น และวิธีเวคเตอร์ออโต้ รีเกรสชั่น ซึ่งมีวิธีการ 6 ขั้นตอนดังนี้

1) นำตัวแปรแต่ละตัวมาทดสอบคุณสมบัติความนิ่งของข้อมูล (Stationary) โดยการทดสอบ Unit Root ทั้งหมด 2 วิธี คือ การทดสอบ Augmented Dickey-Fuller (ADF) และการทดสอบ Phillips-Perron

2) นำตัวแปรต่างๆ ที่ได้มาใส่ลงในแบบจำลองเวคเตอร์ออโต้รีเกรสชั่น เพื่อหาค่าความล่าช้า (Lag) ของแบบจำลองเวคเตอร์ออโต้รีเกรสชั่นที่เหมาะสม

3) สร้างแบบจำลองเวคเตอร์ออโต้รีเกรสชั่น และวิเคราะห์ปฏิกิริยาตอบสนองต่อความแปรปรวน

4) สร้างแบบจำลองเบย์เซียน เวคเตอร์ออโต้รีเกรสชั่น โดยกำหนดให้มีความล่าช้าที่เหมาะสมเท่ากับค่าความล่าช้าที่เหมาะสมที่ได้จากขั้นตอนที่ 2 และวิเคราะห์ปฏิกิริยาตอบสนองต่อความแปรปรวน

5) พยากรณ์สัมประสิทธิ์จีนี่จากแบบจำลองเวคเตอร์ออโต้รีเกรสชั่น และแบบจำลองเบย์เซียน เวคเตอร์ออโต้รีเกรสชั่น

6) เปรียบเทียบประสิทธิภาพของการพยากรณ์การกระจายรายได้ระหว่างวิธีเบย์เซียน เวคเตอร์ออโต้รีเกรสชั่น และวิธีเวคเตอร์ออโต้รีเกรสชั่น ด้วยค่า Root Mean Squared Error

3.4.1 การทดสอบความนิ่งของข้อมูล (Unit Root Test)

เนื่องจากข้อมูลสัมประสิทธิ์จีนี่ รายได้มวลรวมประชาชาติต่อหัวประชากร อัตราเงินเฟ้อ อัตราการว่างงาน ร้อยละของนักเรียน นิสิต และนักศึกษาต่อประชากรในวัยเรียน และอัตราการเปิดประเทศที่ใช้เป็นข้อมูลรายปี แบบอนุกรมเวลา จึงต้องนำมาทดสอบความนิ่งด้วยวิธียูนิทรูท ซึ่งแบ่งออกเป็น 2 วิธี ซึ่งมีรายละเอียดดังนี้

1) การทดสอบ Augmented Dickey-Fuller (ADF)(Said and Dickey, 1984)

None $$\Delta Y_t = \theta Y_{t-1} + \sum_{i=1}^{p} \phi_i \Delta Y_{t-i} + \varepsilon_t \quad (3.1)$$

Intercept $$\Delta Y_t = \alpha + \theta Y_{t-1} + \sum_{i=1}^{p} \phi_i \Delta Y_{t-i} + \varepsilon_t \quad (3.2)$$

Trend and Intercept $$\Delta Y_t = \alpha + \beta t + \theta Y_{t-1} + \sum_{i=1}^{p} \phi_i \Delta Y_{t-1} + \varepsilon_t \quad (3.3)$$

โดย ΔY_t คือ ค่าการถดถอยในตัวเองลำดับที่หนึ่งของตัวแปรที่กำลังศึกษา

Y_t คือ ข้อมูลอนุกรมเวลาของตัวแปรที่กำลังศึกษา ณ เวลา t

Y_{t-1} คือ ข้อมูลอนุกรมเวลาของตัวแปรอิสระ ณ เวลา t-1

$\alpha, \beta, \theta, \phi$ คือ ค่าคงที่ หรือสัมประสิทธิ์ของตัวแปร

t คือ ค่าแนวโน้มเวลา

ε_t คือ ค่าความคลาดเคลื่อนเชิงสุ่ม

จากสมการ None, Intercept และ Trend and Intercept สามารถนำมาเขียนเป็นสมการที่ใช้ทดสอบแบบ Augmented Dickey-Fuller ของทุกตัวแปรที่ใช้ในการศึกษา ดังตารางที่ 3.1

ตารางที่ 3.1 : สมการ Augmented Dickey-Fuller ของตัวแปรที่ใช้ในการศึกษา

ตัวแปร	**สมการ Augmented Dickey-Fuller Test**		
GINI	None	$\Delta \mathrm{GINI}_t = \theta \mathrm{GINI}_{t-1} + \sum_{i=1}^{p} \phi_i \Delta \mathrm{GINI}_{t-i} + \varepsilon_t$	(3.4)
	Intercept	$\Delta \mathrm{GINI}_t = \alpha + \theta \mathrm{GINI}_{t-1} + \sum_{i=1}^{p} \phi_i \Delta \mathrm{GINI}_{t-i} + \varepsilon_t$	(3.5)
	Trend and Intercept	$\Delta \mathrm{GINI}_t = \alpha + \beta t + \theta GINI_{t-1} + \sum_{i=1}^{p} \phi_i \Delta GINI_{t-1} + \varepsilon_t$	(3.6)
GNI	None	$\Delta \mathrm{GNI}_t = \theta \mathrm{GNI}_{t-1} + \sum_{i=1}^{p} \phi_i \Delta \mathrm{GNI}_{t-i} + \varepsilon_t$	(3.7)
	Intercept	$\Delta \mathrm{GNI}_t = \alpha + \theta \mathrm{GNI}_{t-1} + \sum_{i=1}^{p} \phi_i \Delta \mathrm{GNI}_{t-i} + \varepsilon_t$	(3.8)
	Trend and Intercept	$\Delta \mathrm{GNI}_t = \alpha + \beta t + \theta \mathrm{GNI}_{t-1} + \sum_{i=1}^{p} \phi_i \Delta \mathrm{GNI}_{t-1} + \varepsilon_t$	(3.9)
INF	None	$\Delta \mathrm{INF}_t = \theta \mathrm{INF}_{t-1} + \sum_{i=1}^{p} \phi_i \Delta \mathrm{INF}_{t-i} + \varepsilon_t$	(3.10)
	Intercept	$\Delta \mathrm{INF}_t = \alpha + \theta \mathrm{INF}_{t-1} + \sum_{i=1}^{p} \phi_i \Delta \mathrm{INF}_{t-i} + \varepsilon_t$	(3.11)
	Trend and Intercept	$\Delta \mathrm{INF}_t = \alpha + \beta t + \theta \mathrm{INF}_{t-1} + \sum_{i=1}^{p} \phi_i INF_{t-1} + \varepsilon_t$	(3.12)
UER	None	$\Delta UER_t = \theta UER_{t-1} + \sum_{i=1}^{p} \phi_i \Delta \mathrm{UER}_{t-i} + \varepsilon_t$	(3.13)
	Intercept	$\Delta \mathrm{UER}_t = \alpha + \theta \mathrm{UER}_{t-1} + \sum_{i=1}^{p} \phi_i \Delta \mathrm{UER}_{t-i} + \varepsilon_t$	(3.14)
	Trend and Intercept	$\Delta \mathrm{UER}_t = \alpha + \beta t + \theta UER_{t-1} + \sum_{i=1}^{p} \phi_i \Delta UER_{t-1} + \varepsilon_t$	(3.15)

ตารางที่ 3.1 (ต่อ)

ตัวแปร	สมการ Augmented Dickey-Fuller Test		
EDU	None	$\Delta \mathrm{EDU}_t = \theta \mathrm{EDU}_{t-1} + \sum_{i=1}^{p} \phi_i \Delta \mathrm{EDU}_{t-i} + \varepsilon_t$	(3.16)
	Intercept	$\Delta \mathrm{EDU}_t = \alpha + \theta \mathrm{EDU}_{t-1} + \sum_{i=1}^{p} \phi_i \Delta \mathrm{EDU}_{t-i} + \varepsilon_t$	(3.17)
	Trend and Intercept	$\Delta \mathrm{EDU}_t = \alpha + \beta t + \theta EDU_{t-1} + \sum_{i=1}^{p} \phi_i \Delta EDU_{t-1} + \varepsilon_t$	(3.18)
DO	None	$\Delta \mathrm{DO}_t = \theta \mathrm{DO}_{t-1} + \sum_{i=1}^{p} \phi_i \Delta \mathrm{DO}_{t-i} + \varepsilon_t$	(3.19)
	Intercept	$\Delta \mathrm{DO}_t = \alpha + \theta \mathrm{DO}_{t-1} + \sum_{i=1}^{p} \phi_i \Delta \mathrm{DO}_{t-i} + \varepsilon_t$	(3.20)
	Trend and Intercept	$\Delta \mathrm{DO}_t = \alpha + \beta t + \theta DO_{t-1} + \sum_{i=1}^{p} \phi_i \Delta DO_{t-1} + \varepsilon_t$	(3.21)

จากสมการข้างต้นสามารถเขียนสมมติฐานตามแบบทดสอบ Augmented Dickey-Fuller Test ได้ดังนี้ (Enders, 1995)

$\mathrm{H}_0 : \theta = 0$ (Non-stationary)

$\mathrm{H}_1 : \theta < 0$ (Stationary)

ถ้ายอมรับสมมติฐานหลัก $\mathrm{H}_0 : \theta = 0$ แสดงว่าตัวแปรที่กำลังศึกษา (Y_t) มีลักษณะไม่นิ่งหรือมียูนิทรูท ในทางกลับกัน ถ้ายอมรับสมมติฐานรอง $\mathrm{H}_1 : \theta < 0$ แสดงว่าตัวแปรที่กำลังศึกษา (Y_t) มีลักษณะนิ่งหรือไม่มียูนิทรูท ซึ่งข้อสรุปดังกล่าวได้มาจากการเปรียบเทียบค่า t-statistics ที่คำนวณได้กับค่าในตาราง Augmented Dicky-Fuller ค่า t-statistics ที่จะนำมาทดสอบสมมติฐานในแต่ละรูปแบบนั้นจะต้องนำไปเปรียบเทียบกับตาราง Augmented Dicky-Fuller ณ ระดับต่างๆ ถ้าสามารถปฏิเสธสมมติฐานได้ทุกระดับ แสดงว่าตัวแปรที่นำมาทดสอบมีลักษณะนิ่งหรือเป็น Integral of Order Zero ซึ่งเขียนแทนด้วย $Y_t \sim \mathrm{I}(0)$

ในกรณีที่การทดสอบสมมติฐานพบว่า ตัวแปรที่ศึกษามีลักษณะไม่นิ่งหรือมียูนิทรูทนั้น จะต้องนำค่า ΔY_t มาทำ Differencing จนกระทั่งสามารถปฏิเสธสมมติฐานที่ว่า Y_t มีลักษณะไม่นิ่งได้ เพื่อทราบว่า Order of Integration (d) ว่าอยู่ในระดับใด [$Y_t \sim \mathrm{I}(d); d > 0$] (Enders, 1995)

2) การทดสอบ Phillips-Perron (PP)(Phillips and Perron, 1988)

วิธีการทดสอบยูนิทรูทหรือความนิ่งของข้อมูลโดยวิธีการทดสอบ Phillips-Perron (Phillips and Perron, 1988) เป็นวิธีการทดสอบสำหรับสถิตินอนพาราเมทริกซ์ (Nonparametric Statistics) ที่ใช้ในการควบคุมความสัมพันธ์แบบอนุกรม (serial correlation) ของข้อมูลอนุกรมเวลา (Time Series Data) วิธีการทดสอบของ Phillips-Perron สามารถทำได้โดยการถดถอยสมการ (2.1) ดังนี้

$$\Delta Y_t = \alpha + \beta Y_{t-1} + \varepsilon_t \qquad (3.22)$$

ซึ่งสามารถเขียนให้อยู่ในรูป None, Intercept และ Trend and Intercept ได้ดังนี้

None $\quad \Delta Y_t = \beta Y_{t-1} + \varepsilon_t$ (3.23)

Intercept $\quad \Delta Y_t = \alpha + \beta Y_{t-1} + \varepsilon_t$ (3.24)

Intercept and trend $\quad \Delta Y_t = \alpha + a_0 t + \beta Y_{t-1} + \varepsilon_t$ (3.25)

จากสมการ None, Intercept และ Trend and Intercept สามารถนำมาเขียนเป็นสมการที่ใช้ทดสอบแบบ Philips-Perron ของทุกตัวแปรที่ใช้ในการศึกษา ดังตารางที่ 3.2

ตารางที่ 3.2 : สมการ Phillips-Perron ของตัวแปรที่ใช้ในการศึกษา

ตัวแปร	**สมการ Phillips-Perron**		
GINI	None	$\Delta \mathrm{GINI}_t = \beta \mathrm{GINI}_{t-1} + \varepsilon_t$	(3.26)
	Intercept	$\Delta \mathrm{GINI}_t = \alpha + \beta \mathrm{GINI}_{t-1} + \varepsilon_t$	(3.27)
	Trend and Intercept	$\Delta \mathrm{GINI}_t = \alpha + a_0 t + \beta GINI_{t-1} + \varepsilon_t$	(3.28)
GNI	None	$\Delta \mathrm{GNI}_t = \beta \mathrm{GNI}_{t-1} + \varepsilon_t$	(3.29)
	Intercept	$\Delta \mathrm{GNI}_t = \alpha + \beta \mathrm{GNI}_{t-1} + \varepsilon_t$	(3.30)
	Trend and Intercept	$\Delta \mathrm{GNI}_t = \alpha + a_0 t + \beta GNI_{t-1} + \varepsilon_t$	(3.31)
INF	None	$\Delta \mathrm{INF}_t = \beta \mathrm{INF}_{t-1} + \varepsilon_t$	(3.32)
	Intercept	$\Delta \mathrm{INF}_t = \alpha + \beta \mathrm{INF}_{t-1} + \varepsilon_t$	(3.33)
	Trend and Intercept	$\Delta \mathrm{INF}_t = \alpha + a_0 t + \beta INF_{t-1} + \varepsilon_t$	(3.34)
UER	None	$\Delta \mathrm{UER}_t = \beta \mathrm{UER}_{t-1} + \varepsilon_t$	(3.35)
	Intercept	$\Delta \mathrm{UER}_t = \alpha + \beta \mathrm{UER}_{t-1} + \varepsilon_t$	(3.36)
	Trend and Intercept	$\Delta \mathrm{UER}_t = \alpha + a_0 t + \beta UER_{t-1} + \varepsilon_t$	(3.37)

ตารางที่ 3.2 (ต่อ)

ตัวแปร	สมการ Phillips-Perron		
EDU	None	$\Delta \text{EDU}_t = \beta \text{EDU}_{t-1} + \varepsilon_t$	(3.38)
	Intercept	$\Delta \text{EDU}_t = \alpha + \beta \text{EDU}_{t-1} + \varepsilon_t$	(3.39)
	Trend and Intercept	$\Delta \text{EDU}_t = \alpha + a_0 t + \beta EDU_{t-1} + \varepsilon_t$	(3.40)
DO	None	$\Delta \text{DO}_t = \beta \text{DO}_{t-1} + \varepsilon_t$	(3.41)
	Intercept	$\Delta \text{DO}_t = \alpha + \beta \text{DO}_{t-1} + \varepsilon_t$	(3.42)
	Trend and Intercept	$\Delta \text{DO}_t = \alpha + a_0 t + \beta DO_{t-1} + \varepsilon_t$	(3.43)

นอกจากนั้นวิธีของ Phillips-Perron ยังทำการปรับค่า t-statistic ของค่าสัมประสิทธิ์ (γ_j) จากกระบวนการถดถอยในตัวเอง (AR(1)) ในสมการ (2.13) เพื่อให้เกิดความสัมพันธ์อย่างต่อเนื่อง โดยทำการแก้ไขการเกิดปัญหา Heteroskedasticity และ Autocorrelation ด้วยวิธีการของ Newey-West ดังนี้

$$\omega^2 = \gamma_0 + \sum_{u=1}^{q} \left(1 - \frac{u}{q+1}\right)\gamma_j \tag{3.44}$$

$$\gamma_j = \frac{1}{T} \sum_{t=j+1}^{T} \hat{\varepsilon}_t \hat{\varepsilon}_{t-j} \tag{3.45}$$

โดยที่ ω^2 คือ Newey-West heteroskedasticity autocorrelation consistent estimation

γ_j คือ ค่าสัมประสิทธิ์จากกระบวนการถดถอยในตัวเอง (AR(1)) ในสมการ (2.13)

โดยค่า t-statistic ของ Phillips-Perron สามารถคำนวณได้ดังนี้

$$t_{pp} = \frac{\gamma_0^{1/2} t_b}{\omega} - \frac{(\omega^2 - \gamma_0) T s_b}{2\omega s} \tag{3.46}$$

โดยที่ t_{pp} คือ ค่าสถิติทดสอบ Philips-Perron (PP-Test)

t_b คือ ค่า t-test ของ β

s_b คือ ค่า Standard Error ของ β

s คือ ผลทดสอบการถอยหลังของลำดับเลขผิดพลาด

q คือ Truncation Lag

ค่าสถิติทดสอบ Philips-Perron (PP-Test) มีลักษณะการกระจายเช่นเดียวกับค่าสถิติทดสอบ t-statistics ในการทดสอบ Augmented Dickey-Fuller (ADF) โดยมีข้อสมมติฐานดังนี้

H_0: ข้อมูลอนุกรมเวลาของตัวแปรที่ศึกษา ณ เวลา t มีลักษณะไม่นิ่ง

H_1: ข้อมูลอนุกรมเวลาของตัวแปรที่ศึกษา ณ เวลา t มีลักษณะนิ่ง

ข้อสรุปของสมมติฐานสามารถพิจารณาได้โดย ถ้าค่าสถิติทดสอบ Phillips-Perron (PP-Test) มีค่ามากกว่าค่าสถิติ Mackinnon (MacKinnon Statistics) จะยอมรับสมมติฐานหลัก และสรุปได้ว่าข้อมูลอนุกรมเวลาของตัวแปรที่ศึกษา ณ เวลา t มีลักษณะไม่นิ่งหรือมียูนิทรูท ในทางกลับกัน ถ้าค่าสถิติทดสอบ Phillips-Perron (PP-Test) มีค่าน้อยกว่าค่าสถิติ Mackinnon (MacKinnon Statistics) จะปฏิเสธสมมติฐานหลัก และสรุปได้ว่าข้อมูลอนุกรมเวลาของตัวแปรที่ศึกษา ณ เวลา tมีลักษณะนิ่งหรือไม่มียูนิทรูท

3.4.2 การเลือกความล่าช้า (Lag) ที่เหมาะสม

ในการศึกษานี้ใช้ Akaike Information Criteria (AIC) และ Schwarz's Bayesian Information Criterion (SC, BIC หรือ SBC) เป็นเกณฑ์ในการพิจารณาจำนวนความล่าช้าหรือ Lag ที่เหมาะสมของแบบจำลอง โดยมีสูตรดังนี้

$$AIC = \log \hat{\sigma}^2 + 2\frac{p+q}{T} \tag{3.47}$$

$$SC = \log \hat{\sigma}^2 + 2\frac{p+q}{T}\log T \tag{3.48}$$

โดยที่ $\hat{\sigma}^2$ คือ ค่าประมาณของความแปรปรวนของ e_t

หลักเกณฑ์ในการตัดสินใจเลือกแบบจำลองคือจะเลือกแบบจำลองที่ให้ค่า AIC หรือ SC ที่มีค่าน้อยที่สุดค่า AIC และ SC จะมีค่าน้อยจากสาเหตุดังต่อไปนี้คือมีความแปรปรวนและความแปรปรวนร่วมน้อยมีจำนวนของตัวแปรและจำนวน Lag น้อยและสุดท้ายมีจำนวนข้อมูลในการประมาณค่ามาก

ในขณะที่เกณฑ์ทั้งสองดังกล่าวมีความแตกต่างกัน จะทำการเลือกใช้ SC ก่อน เนื่องจาก SC มีคุณสมบัติว่า SC จะเลือกแบบจำลองที่ถูกต้องเกือบแน่นอนสำหรับ AIC นั้นมีแนวโน้มที่จะเป็นลักษณะเชิงเส้นกำกับในแบบจำลองที่มีพารามิเตอร์มากเกินไป (เจษฎา กาวีวงศ์, 2552)

3.4.3 แบบจำลองเวคเตอร์ออโต้ รีเกรสชั่น (VAR)

แบบจำลอง VAR เป็นแบบจำลองที่ใช้ในการศึกษาข้อมูลที่มีลักษณะและความสัมพันธ์ของตัวแปรอาจไม่ชัดเจนและเป็นความสัมพันธ์ในเชิงพลวัตร อีกทั้งยังตั้งข้อสมมติให้ตัวแปรแต่ละตัวไม่ส่งผลต่อตัวแปรอื่นๆในช่วงเวลาเดียวกัน (Johnston and Dinardo, 1997)

เนื่องจากความสัมพันธ์ของตัวแปรแต่ละตัวมีความสัมพันธ์ในลักษณะที่ไม่แน่นอนซึ่งส่งผลกระทบระหว่างกันทั้งทางตรงและทางอ้อม โดยข้อสมมติประการหนึ่งที่จำเป็นต่อการศึกษา คือ ตัวแปรแต่ละตัวจะไม่ส่งผลกระทบต่อตัวแปรตัวอื่นในช่วงเวลาเดียวกัน หรืออาจกล่าวได้ว่าตัวแปรแต่ละตัวจะไม่ส่งผลกระทบอย่างทันทีเมื่อตัวแปรหนึ่งเปลี่ยนแปลงเพราะการตอบสนองต่อ Shock ที่เกิดขึ้น ซึ่งส่งผลต่อตัวแปรต่างๆในระบบเศรษฐกิจนั้นยังมีความล่าช้า (Non-Contemporaneous Effect) (Gujarati, 2003)

Johnston and Dinardo (1997) สร้างแบบจำลองของเวกเตอร์นี้ในรูปของค่าในอดีตของเวกเตอร์ดังกล่าวนี้ผลที่ได้ก็คือ Vector Autoregression (VAR) สามารถเขียนได้ดังนี้

$$y_t = m + A_1 y_{t-1} + A_2 y_{t-2} + \ldots + A_p y_{t-p} + \varepsilon_t \tag{3.49}$$

โดยสามารถเขียนแบบจำลอง VAR ของตัวแปรที่ศึกษาให้อยู่ในรูปสมการได้ดังนี้

$$\begin{aligned} GINI_t = {} & a_{10} + a_{11}{}^{1}GINI_{t-1} + a_{12}{}^{1}GDP_{t-1} + \ldots + a_{18}{}^{1}DO_{t-1} + \ldots + a_{11}{}^{p}GINI_{t-p} \\ & + a_{12}{}^{p}GDP_{t-p} + \ldots + a_{18}{}^{p}DO_{t-p} + e_{1t} \end{aligned} \tag{3.50}$$

$$\begin{aligned} GNI_t = {} & a_{20} + a_{21}{}^{1}GINI_{t-1} + a_{22}{}^{1}GDP_{t-1} + \ldots + a_{28}{}^{1}DO_{t-1} + \ldots + a_{21}{}^{p}GINI_{t-p} \\ & + a_{22}{}^{p}GDP_{t-p} + \ldots + a_{28}{}^{p}DO_{t-p} + e_{2t} \end{aligned} \tag{3.51}$$

$$\begin{aligned} INF_t = {} & a_{30} + a_{31}{}^{1}GINI_{t-1} + a_{32}{}^{1}GDP_{t-1} + \ldots + a_{38}{}^{1}DO_{t-1} + \ldots + a_{31}{}^{p}GINI_{t-p} \\ & + a_{32}{}^{p}GDP_{t-p} + \ldots + a_{38}{}^{p}DO_{t-p} + e_{3t} \end{aligned} \tag{3.52}$$

$$\begin{aligned} UER_t = {} & a_{40} + a_{41}{}^{1}GINI_{t-1} + a_{42}{}^{1}GDP_{t-1} + \ldots + a_{48}{}^{1}DO_{t-1} + \ldots + a_{41}{}^{p}GINI_{t-p} \\ & + a_{42}{}^{p}GDP_{t-p} + \ldots + a_{48}{}^{p}DO_{t-p} + e_{4t} \end{aligned} \tag{3.53}$$

$$\begin{aligned} EDU_t = {} & a_{50} + a_{51}{}^{1}GINI_{t-1} + a_{52}{}^{1}GDP_{t-1} + \ldots + a_{58}{}^{1}DO_{t-1} + \ldots + a_{51}{}^{p}GINI_{t-p} \\ & + a_{52}{}^{p}GDP_{t-p} + \ldots + a_{58}{}^{p}DO_{t-p} + e_{5t} \end{aligned} \tag{3.54}$$

$$\begin{aligned} DO_t = {} & a_{60} + a_{61}{}^{1}GINI_{t-1} + a_{62}{}^{1}GDP_{t-1} + \ldots + a_{68}{}^{1}DO_{t-1} + \ldots + a_{61}{}^{p}GINI_{t-p} \\ & + a_{62}{}^{p}GDP_{t-p} + \ldots + a_{68}{}^{p}DO_{t-p} + e_{6t} \end{aligned} \tag{3.55}$$

หรือสามารถเขียนเป็นรูปเมทริกซ์ได้ดังนี้

$$\begin{bmatrix} GINI_t \\ GNI_t \\ INF_t \\ UER_t \\ EDU_t \\ DO_t \end{bmatrix} = \begin{bmatrix} a_{10} \\ a_{20} \\ a_{30} \\ a_{40} \\ a_{50} \\ a_{60} \end{bmatrix} + \begin{bmatrix} a_{11}^{1} & a_{12}^{1} & a_{13}^{1} & a_{14}^{1} & a_{15}^{1} & a_{16}^{1} & a_{17}^{1} & a_{18}^{1} \\ a_{21}^{1} & a_{22}^{1} & a_{23}^{1} & a_{24}^{1} & a_{25}^{1} & a_{26}^{1} & a_{27}^{1} & a_{28}^{1} \\ a_{31}^{1} & a_{32}^{1} & a_{33}^{1} & a_{34}^{1} & a_{35}^{1} & a_{36}^{1} & a_{37}^{1} & a_{38}^{1} \\ a_{41}^{1} & a_{42}^{1} & a_{43}^{1} & a_{44}^{1} & a_{45}^{1} & a_{46}^{1} & a_{47}^{1} & a_{48}^{1} \\ a_{51}^{1} & a_{52}^{1} & a_{53}^{1} & a_{54}^{1} & a_{55}^{1} & a_{56}^{1} & a_{57}^{1} & a_{58}^{1} \\ a_{61}^{1} & a_{62}^{1} & a_{63}^{1} & a_{64}^{1} & a_{65}^{1} & a_{66}^{1} & a_{67}^{1} & a_{68}^{1} \end{bmatrix} \begin{bmatrix} GINI_{t-1} \\ GNI_{t-1} \\ INF_{t-1} \\ UER_{t-1} \\ EDU_{t-1} \\ DO_{t-1} \end{bmatrix} +$$

$$\ldots\ldots + \begin{bmatrix} a_{11}^{p} & a_{12}^{p} & a_{13}^{p} & a_{14}^{p} & a_{15}^{p} & a_{16}^{p} & a_{17}^{p} & a_{18}^{p} \\ a_{21}^{p} & a_{22}^{p} & a_{23}^{p} & a_{24}^{p} & a_{25}^{p} & a_{26}^{p} & a_{27}^{p} & a_{28}^{p} \\ a_{31}^{p} & a_{32}^{p} & a_{33}^{p} & a_{34}^{p} & a_{35}^{p} & a_{36}^{p} & a_{37}^{p} & a_{38}^{p} \\ a_{41}^{p} & a_{42}^{p} & a_{43}^{p} & a_{44}^{p} & a_{45}^{p} & a_{46}^{p} & a_{47}^{p} & a_{48}^{p} \\ a_{51}^{p} & a_{52}^{p} & a_{53}^{p} & a_{54}^{p} & a_{55}^{p} & a_{56}^{p} & a_{57}^{p} & a_{58}^{p} \\ a_{61}^{p} & a_{62}^{p} & a_{63}^{p} & a_{64}^{p} & a_{65}^{p} & a_{66}^{p} & a_{67}^{p} & a_{68}^{p} \end{bmatrix} \begin{bmatrix} GINI_{t-p} \\ GNI_{t-p} \\ INF_{t-p} \\ UER_{t-p} \\ EDU_{t-p} \\ DO_{t-p} \end{bmatrix} + \begin{bmatrix} e_{1t} \\ e_{2t} \\ e_{3t} \\ e_{4t} \\ e_{5t} \\ e_{6t} \end{bmatrix}$$

3.4.4 แบบจำลองเบย์เซียน เวคเตอร์ออโต้ รีเกรสชั่น (BVAR)

สำหรับวิธีการศึกษาผลกระทบของตัวแปรด้านเศรษฐกิจและคุณภาพชีวิตต่อการกระจายรายได้ในประเทศไทย โดยใช้วิธีเบย์เซียน ออโต้รีเกรสชั่นในครั้งนี้ จะใช้คุณสมบัติเบื้องต้นเกี่ยวกับทฤษฎีของเบย์ Bayes' Rule (Bayes, 2005) ที่ใช้ความน่าจะเป็นของเหตุการณ์ก่อนหน้าในการพยากรณ์ เพื่อเลือกข้อมูลให้ใกล้เคียงกับค่าในอนาคตของตัวแปรที่ศึกษามากที่สุด ซึ่งถือได้ว่าเป็นวิธีที่มีประสิทธิภาพในการพยากรณ์สูง ซึ่งสามารถอธิบายได้ดังต่อไปนี้

กำหนดให้ $A_1, A_2, ..., A_6$ แทน สัมประสิทธิ์จีนี่ และตัวแปรทางเศรษฐกิจและคุณภาพชีวิต ได้แก่ สัมประสิทธิ์จีนี่ รายได้มวลรวมประชาชาติต่อหัวประชากร อัตราเงินเฟ้อ อัตราการว่างงาน ละของนักเรียน นิสิต และนักศึกษาต่อประชากรในวัยเรียน และอัตราการเปิดประเทศ สามารถเขียนแทนด้วย $GINI_t, GNI_t, INF_t, UER_t, EDU_t, DO_t$ ตามลำดับ ซึ่งเป็นเหตุการณ์ใดๆ ในแซมเปิลสเปซ S (แซมเปิลสเปซ S แทน ตัวแปรทางเศรษฐกิจและคุณภาพชีวิต) ที่ไม่เกิดร่วมกัน นั่นคือ

$$\overset{5}{\underset{i=1}{U}} A_i = S \qquad (3.56)$$

และ $A_i \cap A_j = \phi$ เมื่อ $i \neq j$

และกำหนดให้ B เป็นเหตุการณ์ใดๆ โดยที่ B แทนตัวแปรทางเศรษฐกิจและคุณภาพชีวิตก่อนหน้า $GINI_{t-i}, GNI_{t-i}, INF_{t-i}, UER_{t-i}, EDU_{t-i}, DO_{t-i}$ และ $B \subset S$ จากความน่าจะเป็นแบบมีเงื่อนไข (Conditional Probability) สามารถเขียนค่าความน่าจะเป็นของตัวแปรทางเศรษฐกิจ

และคุณภาพชีวิต ณ เวลาปัจจุบัน (เหตุการณ์ A) เมื่อทราบตัวแปรทางเศรษฐกิจและคุณภาพชีวิตในอดีต (เหตุการณ์ B) ดังนี้

$$P(A|B) = \frac{P(A \cap B)}{P(B)} \tag{3.57}$$

ดังนั้น

$$P(A \cap B) = P(A|B)P(B) \tag{3.58}$$

ทำนองเดียวกัน

$$P(B|A) = \frac{P(A \cap B)}{P(A)} \tag{3.59}$$

และได้ว่า

$$P(A \cap B) = P(B|A)\ P(A) \tag{3.60}$$

โดยที่

$$\begin{aligned} B &= A \cap B \\ &= (A_1 \cup A_2 \cup \ldots \cup A_6) \cap B \\ &= (A_1 \cap B) \cup (A_2 \cap B) \cup \ldots \cup (A_6 \cap B) \end{aligned} \tag{3.61}$$

ดังนั้น

$$\begin{aligned} P(B) &= P(A_1 \cap B) + P(A_2 \cap B) + \ldots + P(A_6 \cap B) \\ &= P(B|A_1)P(A_1) + P(B|A_2)P(A_2) + \ldots + P(B|A_6)P(A_6) \\ &= \sum_{i=1}^{6} P(B|A_i)P(A_i) \end{aligned} \tag{3.62}$$

ความน่าจะเป็นแบบมีเงื่อนไข (Conditional Probability) สามารถเขียนได้ ดังนี้

$$P(A_k|B) = \frac{P(A_k \cap B)}{P(B)} = \frac{P(B|A_k)P(A_k)}{\sum_{i=1}^{n} P(B|A_i)P(A_i)} \tag{3.63}$$

สำหรับการวิเคราะห์โดยแบบจำลองเบย์เซียน เวคเตอร์ออโต้รีเกรสชั่น สามารถแสดงได้ดังรายละเอียดต่อไปนี้

1) เขียนสมการเวคเตอร์ ออโต้รีเกรสชั่น (VAR) ให้อยู่ในรูปเมตริกซ์

$$y_t = c_t + \sum_{j=1}^{p} A_j y_{t-j} + \varepsilon_t \tag{3.64}$$

เมื่อ y_t คือ เวคเตอร์ขนาด $M \times 1$ ซึ่งประกอบด้วยค่าสังเกตจำนวนหนึ่งบนตัวแปรอนุกรมเวลา M และ $t = 1,...,T$ z

ε_t คือ เวคเตอร์ ของค่าความคลาดเคลื่อนขนาด $M \times 1$

c_t คือ เวคเตอร์ของค่าคงที่ขนาด $M \times 1$

A_j คือ เมทริกซ์ของค่าสัมประสิทธิ์ขนาด $M \times M$

$$\begin{bmatrix} GINI_t \\ GNI_t \\ INF_t \\ UER_t \\ EDU_t \\ DO_t \end{bmatrix} = \begin{bmatrix} a_{10} \\ a_{20} \\ a_{30} \\ a_{40} \\ a_{50} \\ a_{60} \end{bmatrix} + \begin{bmatrix} a_{11}{}^{1} & a_{12}{}^{1} & a_{13}{}^{1} & a_{14}{}^{1} & a_{15}{}^{1} & a_{16}{}^{1} & a_{17}{}^{1} & a_{18}{}^{1} \\ a_{21}{}^{1} & a_{22}{}^{1} & a_{23}{}^{1} & a_{24}{}^{1} & a_{25}{}^{1} & a_{26}{}^{1} & a_{27}{}^{1} & a_{28}{}^{1} \\ a_{31}{}^{1} & a_{32}{}^{1} & a_{33}{}^{1} & a_{34}{}^{1} & a_{35}{}^{1} & a_{36}{}^{1} & a_{37}{}^{1} & a_{38}{}^{1} \\ a_{41}{}^{1} & a_{42}{}^{1} & a_{43}{}^{1} & a_{44}{}^{1} & a_{45}{}^{1} & a_{46}{}^{1} & a_{47}{}^{1} & a_{48}{}^{1} \\ a_{51}{}^{1} & a_{52}{}^{1} & a_{53}{}^{1} & a_{54}{}^{1} & a_{55}{}^{1} & a_{56}{}^{1} & a_{57}{}^{1} & a_{58}{}^{1} \\ a_{61}{}^{1} & a_{62}{}^{1} & a_{63}{}^{1} & a_{64}{}^{1} & a_{65}{}^{1} & a_{66}{}^{1} & a_{67}{}^{1} & a_{68}{}^{1} \end{bmatrix} \begin{bmatrix} GINI_{t-1} \\ GNI_{t-1} \\ INF_{t-1} \\ UER_{t-1} \\ EDU_{t-1} \\ DO_{t-1} \end{bmatrix} +$$

$$\ldots\ldots + \begin{bmatrix} a_{11}{}^{p} & a_{12}{}^{p} & a_{13}{}^{p} & a_{14}{}^{p} & a_{15}{}^{p} & a_{16}{}^{p} & a_{17}{}^{p} & a_{18}{}^{p} \\ a_{21}{}^{p} & a_{22}{}^{p} & a_{23}{}^{p} & a_{24}{}^{p} & a_{25}{}^{p} & a_{26}{}^{p} & a_{27}{}^{p} & a_{28}{}^{p} \\ a_{31}{}^{p} & a_{32}{}^{p} & a_{33}{}^{p} & a_{34}{}^{p} & a_{35}{}^{p} & a_{36}{}^{p} & a_{37}{}^{p} & a_{38}{}^{p} \\ a_{41}{}^{p} & a_{42}{}^{p} & a_{43}{}^{p} & a_{44}{}^{p} & a_{45}{}^{p} & a_{46}{}^{p} & a_{47}{}^{p} & a_{48}{}^{p} \\ a_{51}{}^{p} & a_{52}{}^{p} & a_{53}{}^{p} & a_{54}{}^{p} & a_{55}{}^{p} & a_{56}{}^{p} & a_{57}{}^{p} & a_{58}{}^{p} \\ a_{61}{}^{p} & a_{62}{}^{p} & a_{63}{}^{p} & a_{64}{}^{p} & a_{65}{}^{p} & a_{66}{}^{p} & a_{67}{}^{p} & a_{68}{}^{p} \end{bmatrix} \begin{bmatrix} GINI_{t-p} \\ GNI_{t-p} \\ INF_{t-p} \\ UER_{t-p} \\ EDU_{t-p} \\ DO_{t-p} \end{bmatrix} + \begin{bmatrix} e_{1t} \\ e_{2t} \\ e_{3t} \\ e_{4t} \\ e_{5t} \\ e_{6t} \end{bmatrix}$$

และสามารถเขียน Vector Autoregression (VAR) ให้อยู่ในรูปสมการได้ดังนี้

$$\begin{aligned} GINI_t \;=\; & a_{10} + a_{11}{}^{1}GINI_{t-1} + a_{12}{}^{1}GDP_{t-1} + \ldots + a_{18}{}^{1}DO_{t-1} + \ldots + a_{11}{}^{p}GINI_{t-p} \\ & + a_{12}{}^{p}GDP_{t-p} + \ldots + a_{18}{}^{p}DO_{t-p} + e_{1t} \end{aligned} \tag{3.65}$$

$$\begin{aligned} GNI_t \;=\; & a_{20} + a_{21}{}^{1}GINI_{t-1} + a_{22}{}^{1}GDP_{t-1} + \ldots + a_{28}{}^{1}DO_{t-1} + \ldots + a_{21}{}^{p}GINI_{t-p} \\ & + a_{22}{}^{p}GDP_{t-p} + \ldots + a_{28}{}^{p}DO_{t-p} + e_{2t} \end{aligned} \tag{3.66}$$

$$\begin{aligned} INF_t \;=\; & a_{30} + a_{31}{}^{1}GINI_{t-1} + a_{32}{}^{1}GDP_{t-1} + \ldots + a_{38}{}^{1}DO_{t-1} + \ldots + a_{31}{}^{p}GINI_{t-p} \\ & + a_{32}{}^{p}GDP_{t-p} + \ldots + a_{38}{}^{p}DO_{t-p} + e_{3t} \end{aligned} \tag{3.67}$$

$$\begin{aligned} UER_t \;=\; & a_{40} + a_{41}{}^{1}GINI_{t-1} + a_{42}{}^{1}GDP_{t-1} + \ldots + a_{48}{}^{1}DO_{t-1} + \ldots + a_{41}{}^{p}GINI_{t-p} \\ & + a_{42}{}^{p}GDP_{t-p} + \ldots + a_{48}{}^{p}DO_{t-p} + e_{4t} \end{aligned} \tag{3.68}$$

$$\begin{aligned} EDU_t \;=\; & a_{50} + a_{51}{}^{1}GINI_{t-1} + a_{52}{}^{1}GDP_{t-1} + \ldots + a_{58}{}^{1}DO_{t-1} + \ldots + a_{51}{}^{p}GINI_{t-p} \\ & + a_{52}{}^{p}GDP_{t-p} + \ldots + a_{58}{}^{p}DO_{t-p} + e_{5t} \end{aligned} \tag{3.69}$$

$$\begin{aligned} DO_t \;=\; & a_{60} + a_{61}{}^{1}GINI_{t-1} + a_{62}{}^{1}GDP_{t-1} + \ldots + a_{68}{}^{1}DO_{t-1} + \ldots + a_{61}{}^{p}GINI_{t-p} \\ & + a_{62}{}^{p}GDP_{t-p} + \ldots + a_{68}{}^{p}DO_{t-p} + e_{6t} \end{aligned} \tag{3.70}$$

2) เมื่อใช้คุณสมบัติของเมทริกซ์การกระจายปกติที่ไม่เป็นแบบมาตรฐาน จะได้ฟังก์ชันความเป็นไปได้ (Likelihood Function)

$$L(A,\Sigma) \propto |\Sigma|^{-\frac{1}{2}T} \exp\left\{-\frac{1}{2}tr\left[\Sigma^{-1}(Y-XA)'(Y-XA)\right]\right\} \quad (3.71)$$

3) ทำการกำหนดความน่าจะเป็นของการแจกแจงก่อนหน้า

$$p(A,\Sigma) \propto |\Sigma|^{-\frac{M+1}{2}} \quad (3.72)$$

4) จะได้ความน่าจะเป็นของการแจกแจงภายหลังซึ่งถือว่าเป็นค่าการพยากรณ์ตามวิธีการของเบย์เซียน เวคเตอร์ออโต้รีเกรสชั่น

$$p(A,\Sigma|y) \propto |\Sigma|^{-\frac{1}{2}(T+M+1)} \exp\left\{-\frac{1}{2}tr\left[\Sigma^{-1}(Y-XA)'(Y-XA)\right]\right\} \quad (3.73)$$

3.4.5 การวิเคราะห์ปฏิกิริยาตอบสนองต่อความแปรปรวน (Impulse Response Function)

Impulse Response Function เป็นวิธีการที่อาศัยแนวคิด Moving Average เพื่อพิจารณาการเคลื่อนไหวของตัวแปรที่เป็นอนุกรมเวลา โดยแบบจำลอง VAR จะอาศัยคุณสมบัติ Stability ของแบบจำลอง ในการเขียนแบบจำลองให้อยู่ในรูปของ Vector Moving Average (VMA) ดังนี้

$$\begin{bmatrix} y_y \\ z_t \end{bmatrix} = \begin{bmatrix} \overline{y_t} \\ \overline{z_t} \end{bmatrix} + \sum_{i=0}^{\infty} \begin{bmatrix} \phi_{11}(i) & \phi_{12}(i) \\ \phi_{21}(i) & \phi 22(i) \end{bmatrix}^{i} \begin{bmatrix} \varepsilon_{yt-i} \\ \varepsilon_{zt-i} \end{bmatrix} \quad (3.74)$$

หลังจากนั้น ให้ทำการหาตัวคูณ Multiplier ($\phi_{ij}(i)$) ของค่าความผิดพลาด (ε_i) ในแบบจำลอง VMA ในแต่ละช่วงของเวลา และนำตัวคูนนั้นมา Plot กราฟเทียบกับเวลา จะได้ Impulse Response Function และหลังจากที่ได้ Impulse Response Function นั้น จะสามารถทำการวิเคราะห์ความสัมพันธ์ของตัวแปรใดๆ ต่อตัวแปรอีกตัวหนึ่งในแต่ละช่วงเวลา ซึ่งในการศึกษา Impulse Response Function นี้ สามารถบอกทิศทาง และแนวโน้มของการเปลี่ยนแปลง รวมถึงขนาดของผลกระทบในแต่ละช่วงเวลาได้ (สุพรรษา สูญสิ้นภัย, 2551)

3.4.6 การวัดประสิทธิภาพของการพยากรณ์โดยการคำนวณค่า Root Mean Squared Error

ค่า Root Mean Squared Error (RMSE) นั้นจะบอกความเหมาะสม (fit) ของแต่ละตัวแบบที่ใช้ในการพยากรณ์ ดังนั้นตัวแบบใดที่ให้ค่า RMSE ต่ำ จะหมายถึงตัวแบบนั้นเหมาะที่จะใช้ในการพยากรณ์มากกว่าตัวแบบที่ให้ค่า Root Mean Squared Error สูง โดยค่า RMSE สามารถคำนวณได้จากสูตรดังนี้ (Pindyck and Rubinfeld, 1998; Kenny, Meyler, and Quimm, 1998)

$$\text{ค่า Root Mean Squared Error (RMSE)} = \sqrt{\frac{1}{h}\sum_{t=T+1}^{T+h}(\hat{y}_t - y_t)^2} \quad (3.75)$$