

## บทที่ 5

### สรุปผลและข้อเสนอแนะ

#### 5.1 สรุปผลการศึกษา

การศึกษาครั้งนี้เป็นการหาแบบจำลองที่เหมาะสมมากที่สุดในการศึกษาข้อมูลอนุกรมเวลา โดยเลือกใช้เทคนิคในการศึกษา 3 แบบจำลอง ได้แก่ แบบจำลอง ARIMA แบบจำลอง GARCH-M และแบบจำลอง Neural Networks (ANNs) มาเปรียบเทียบความเหมาะสมของการพยากรณ์อัตราแลกเปลี่ยนเงินตราต่างประเทศ ระหว่างเงินบาทกับเงินดอลลาร์สหรัฐฯ โดยใช้ข้อมูลอนุกรมเวลา อัตราแลกเปลี่ยนระหว่างเงินบาทกับเงินดอลลาร์สหรัฐฯรายวัน ตั้งแต่ 5 มกราคม 2547 – 2 พฤษภาคม 2550 เป็นจำนวน 814 วัน ชุดแรกที่นำมาวิเคราะห์ตามแบบจำลองจำนวน 764 วัน และชุดที่สองสำหรับทดสอบความแม่นยำจำนวน 50 วัน เมื่อนำผลการพยากรณ์โดยแบบจำลอง Neural Networks แบบจำลอง ARIMA และแบบจำลอง ARIMA with GARCH-M มาเปรียบเทียบความแม่นยำในการพยากรณ์ แบบจำลอง ARIMA ใช้การวิเคราะห์ของ Box-Jenkins ซึ่งเริ่มจากการทดสอบความนิ่ง (Unit root) ของข้อมูลอนุกรมเวลา ผลการศึกษาพบว่า ข้อมูลมีลักษณะไม่นิ่งที่ระดับ Level แต่เมื่อทำการหาผลต่างอันดับที่ 1 (1<sup>st</sup> Difference) ข้อมูลจะมีลักษณะนิ่ง โดยมีค่า P-lag เท่ากับ 0 แต่ไม่สามารถหารูปแบบ Models ได้ เนื่องจากว่าข้อมูลที่ทำการ Difference ครั้งที่ 1 มีลักษณะเป็นตัวแปรตามเคลื่อนที่แบบสุ่มไร้รูปแบบ (purely random) ส่งผลให้นำไปสร้างรูปแบบ Models ARIMA จากข้อมูลชุดนี้ไม่ได้ เพราะฉะนั้นจึงจำเป็นต้องหาวิธีที่จะทำให้ข้อมูลชุดนี้ Stationary และมีรูปแบบที่แน่นอน วิธีการหนึ่ง คือ การ Difference ครั้งที่ 2 ซึ่งจากผลการทดลองพบว่าได้ข้อมูลอนุกรมเวลา (time series) ที่ Stationary และมีรูปแบบที่แน่นอน

จากนั้นจึงทำการหาแบบจำลอง ARIMA ที่เหมาะสมโดยพยากรณ์ด้วยวิธี Box-Jenkins ซึ่งประกอบด้วย 4 ขั้นตอน ดังนี้ 1) การกำหนดรูปแบบของแบบจำลอง (Identification) โดยคัดเลือกแบบจำลองที่มีความเหมาะสมได้ 4 แบบจำลอง คือ แบบจำลอง ARIMA(0,2,1) แบบจำลอง AR(1)I(2)MA(2) แบบจำลอง ARIMA(12,2,0) แบบจำลอง ARIMA(0,2,2). 2) การประมาณค่าพารามิเตอร์ (Estimation) เป็นการนำแบบจำลองทั้ง 4 แบบจำลองข้างต้นมาประมาณค่าสัมประสิทธิ์ได้ดังตารางที่ 4.4 – 4.7 การตรวจสอบความถูกต้อง (Diagnostic Checking) โดยแบบจำลองทั้ง 4 แบบจำลองยอมรับสมมติฐานค่าความคลาดเคลื่อนการมีคุณสมบัติความเป็น white noise ที่ระดับนัยสำคัญ 1% 4) การพยากรณ์ (Forecasting) เป็นการเลือกแบบจำลองที่มีความ

แม่นยำและเหมาะสมที่สุดจากรูปแบบจำลองทั้งหมด พบว่าแบบจำลองที่มีความเหมาะสมและดีที่สุด คือแบบจำลอง ARIMA(0,2,2) ซึ่งมีสมการแสดงความสัมพันธ์ดังนี้

$$D(\text{Exchange},2) = C + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2}$$

ผลการทดสอบความแม่นยำของการพยากรณ์ เพื่อเป็นทางเลือกพยากรณ์อัตราแลกเปลี่ยนเงินตราต่างประเทศพบว่าค่า ได้ค่า MAPE เท่ากับ 0.130672

จากแบบจำลอง ARIMA ที่ได้ผู้ศึกษาคิดว่ายังไม่เป็นแบบจำลองที่ดีที่สุด จึงนำไปสู่การพยากรณ์โดยใช้แบบจำลอง ARIMA with GARCH-M โดยคัดเลือกแบบจำลองที่ผ่านการตรวจสอบความถูกต้อง (Diagnostic Checking) ที่คาดว่าจะมีความเหมาะสมได้ 2 แบบจำลอง ได้แก่ ARIMA(12,2,0) with GARCH-M(1,1) และ ARIMA(0,2,2) with GARCH-M(1,1) ผลการพยากรณ์พบว่าแบบจำลอง ARIMA(0,2,2) with GARCH-M(1,1) เป็นแบบจำลองที่เหมาะสมของเทคนิคการพยากรณ์โดยใช้แบบจำลอง GARCH-M ซึ่งได้ผลการทดสอบความแม่นยำของการพยากรณ์ เพื่อเป็นทางเลือกพยากรณ์อัตราแลกเปลี่ยนเงินตราต่างประเทศพบว่าค่า ได้ค่า MAPE เท่ากับ 0.130358

เทคนิคที่สาม ศึกษาโดยใช้แบบจำลอง Neural Networks (ANNs) โดยทำการศึกษาทดลอง 3 แบบด้วยกัน ได้แก่ 1. ผลการศึกษาเบื้องต้นด้วย Hidden layer จำนวน 1 ชั้น 2. การทดลองปรับเปลี่ยนจำนวนนิวรอนในชั้น Hidden layer ด้วยวิธี Arbitrary 3. การทดลองปรับเปลี่ยนจำนวนข้อมูลนำเข้า ด้วยวิธี Quadratic Interpolation ได้ผลการศึกษาครั้งนี้ วิธีการทดลองที่ 1 และ 2 ให้ค่า MAPE ของแบบจำลอง (ตารางที่ 4.37) มีค่าน้อยที่สุด จึงสรุปได้ว่าแบบจำลอง Neural Networks ที่เหมาะสมที่สุด มีจำนวนข้อมูลนำเข้าเท่ากับ 10 จำนวนนิวรอนในชั้น hidden layer เท่ากับ 60 และจำนวนรอบของการเรียนรู้เท่ากับ 300 หรือ 400 ซึ่งให้ค่า MAPE เท่ากับ 0.4974

จากการพิจารณาค่า MAPE ที่ดีที่สุดของแต่ละวิธีมาสรุป ผลปรากฏว่าแบบจำลองที่สามารถพยากรณ์อัตราแลกเปลี่ยนเงินตราต่างประเทศ (ระหว่างค่าเงินบาทกับดอลลาร์สหรัฐฯ) ดีที่สุดคือ ARIMA with GARCH-M รองลงมาคือ ARIMA และ Neural Networks ตามลำดับ

## 5.2 อภิปรายผล

ในการศึกษาพบว่าการพยากรณ์ข้อมูลอนุกรมเวลา (Time series Analysis) การใช้แบบจำลอง ARIMA จะมีความได้เปรียบมากกว่าการใช้แบบจำลอง Neural Networks เพราะว่าแบบจำลอง ARIMA นั้นมีพจน์ MA (Moving average) จะมีอิทธิพลคือสามารถนำค่า white noise มาใช้ในการพยากรณ์ได้ ซึ่ง ANNs ไม่มี โดยธรรมชาติของข้อมูลอนุกรมเวลา จะพบว่า ค่าในอนาคตเป็นค่าที่ผันแปรออกจากค่าเฉลี่ย แต่ ANNs จะทำนายที่ค่าเฉลี่ยตลอดทำการพยากรณ์ข้อมูลที่ไม่มียุทธวิธีแบบอย่างข้อมูลอนุกรมเวลาผิดพลาด และอีกสาเหตุหนึ่งเป็นเพราะ ANNs จับรูปแบบการ

เปลี่ยนแปลงของ white noise ไม่ได้ เพราะไม่มีพจน์ MA (Moving average) มาเป็นส่วนหนึ่งในการพยากรณ์ด้วยทำให้จับการเปลี่ยนแปลงของราคาอันเกิดจากอิทธิพลของ white noise ได้ ส่วน GARCH นั้นสามารถดูรูปแบบการเปลี่ยนแปลงของ white noise ได้ดีที่สุดจึงส่งผลให้ผลการพยากรณ์ออกมาดีที่สุด

จากการศึกษายังพบอีกว่า Neural Networks ใช้ได้ดีกับสิ่งที่มีรูปแบบที่แน่นอน แต่ยังหา Function ไปสู่รูปแบบนั้นไม่ได้ แต่สำหรับข้อมูลอนุกรมเวลา (Time series Analysis) ซึ่ง white noise ที่มีรูปแบบไม่แน่นอน จนถึงกับบางทีก็เป็น Random ทำให้ ANNs หารูปแบบไม่เจอ ส่งผลให้สรุปได้ว่า ANNs ก็ดีในระดับหนึ่ง แต่ก็สู้รูปแบบที่มีการนำ white noise มาคำนวณด้วยไม่ได้

### 5.3 ข้อเสนอแนะ

1. ในการศึกษาในขั้นตอนการทดสอบความนิ่งของข้อมูล ผลสรุปคือข้อมูลนิ่งที่ Difference ครั้งที่หนึ่ง แต่ไม่สามารถหารูปแบบ Models ได้ เพราะข้อมูล Difference ครั้งที่หนึ่ง มีลักษณะเป็นตัวแปรตามเคลื่อนที่แบบสุ่มไร้รูปแบบ ดังนั้น จึงได้ใช้ข้อมูล ที่ Difference ครั้งที่สอง ซึ่งผลที่ออกมาคือ สามารถหาแบบจำลองที่เหมาะสมได้ และพยากรณ์ข้อมูลออกมาได้แม่นยำ แต่ในการหารูปแบบจำลองโดยใช้ Difference ครั้งที่สองนี้ ไม่มีหนังสือเล่มไหนรับรองว่าเป็นวิธีที่ถูกต้อง เพราะเป็นวิธีใหม่ที่ไม่เคยมีใครทำมาก่อน จึงได้ข้อสรุปที่ว่าวิธีการนี้อาจเหมาะสมหรือไม่เหมาะสมก็ได้ จะเป็นการดีมากถ้ามีผู้ที่สนใจจะศึกษาวิธีการนี้ต่อไป
2. ในการหาแบบจำลอง Neural Networks นั้นค่าพยากรณ์ที่ได้จะไม่คงที่เมื่อนำข้อมูลมาประมวลผลใหม่ เนื่องจากในขั้นตอนการประมวลผลแต่ละครั้ง Neural Networks จะเกิดกระบวนการเรียนรู้ ซึ่งบางครั้งกระบวนการเรียนรู้ก็ไม่เหมือนกัน ซึ่งส่งผลให้ค่าพยากรณ์ที่ได้ในแต่ละครั้งอาจไม่เหมือนกัน