

N6

เศรษฐศาสตร์ (Economics)

การทำนายดัชนีหุ้นด้วยการใช้แบบจำลองการเรียนรู้เชิงลึก (Deep Learning) STOCK INDEX PREDICTION USING DEEP LEARNING MODEL

ภูมิชาย จิตชัย^{1*}, โอหม ศรีนิล²

Poomchai Jitchai^{1*}, Ohm Sornil²

^{1,2}คณะสถิติประยุกต์ สถาบันบัณฑิตพัฒนบริหารศาสตร์

^{1,2}Graduate School of Applied Statistics, National Institute of Development Administration

*Corresponding author, E-mail: poomchai.jit@stu.nida.ac.th

บทคัดย่อ

การทำนายทิศทางขึ้นลงหรือการทำนายราคาหุ้นถือว่าเป็นเรื่องที่มีความน่าสนใจและมีความท้าทายในการทำวิจัยสูง ในงานวิจัยชิ้นนี้ได้มีการทำการศึกษาโดยการทดลองใช้ Convolutional Neural Network (CNN) และ Long Short-Term Memory (LSTM) ไปประยุกต์ใช้ในการสร้างแบบจำลองการทำนายราคาปิดดัชนีตลาดหลักทรัพย์แห่งประเทศไทยรวมทั้งสิ้นจำนวน 5 แบบจำลอง มาทำการวิเคราะห์ถดถอย (Regression) เพื่อทำนายราคาปิดของดัชนี SET และ SET50 และเปรียบเทียบว่าแบบจำลองการเรียนรู้เชิงลึก (Deep Learning) ในรูปใดที่ได้กล่าวมานั้นสามารถทำนายราคาปิดของดัชนี SET และ SET50 ได้แม่นยำกว่ากัน โดยการวัดผลใช้รากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (Root Mean Square Error: RMSE) เป็นตัววัด ซึ่งพบว่าแบบจำลอง CNN ที่ใช้ตัวแปรแบบตัวแปรเดียว (Univariate) ให้ผลที่ดีที่สุด

คำสำคัญ: ดัชนีหุ้น แบบจำลองการเรียนรู้เชิงลึก (Deep Learning)

ABSTRACT

Stock market prediction is one of the most interesting area in research field but there is quite a challenge to predict stocks. In this research, we studied about applying Convolutional Neural Network (CNN) and Long short-term memory (LSTM) to predict close of SET index and SET50 index by using 5 difference architecture's models. Moreover, we use Root Mean Square Error (RMSE) to evaluate which model is the most accurate. The result has shown that CNN input with univariate variable is the most accurate model in prediction of both SET index and SET50 index.

Keywords: Stock Index, Deep Learning

บทนำ

ตลาดหุ้นมีบทบาทสำคัญต่อระบบเศรษฐกิจของประเทศเป็นอย่างมากเพราะตลาดหุ้นนั้นทำหน้าที่เป็นแหล่งระดมเงินทุนให้กับบริษัทชั้นนำ ประกอบกับดัชนีของตลาดหุ้นนั้นยังเป็นตัวสะท้อนเศรษฐกิจล่วงหน้า ทั้งยังเป็นหน้าต่างของประเทศ (วรวรรณ ธาราภูมิ, 2562) นอกจากนี้แล้วตลาดหุ้นนั้นยังเป็นแหล่งลงทุนที่สร้างกำไรหรือผลตอบแทนให้กับนักลงทุนในระดับที่ค่อนข้างสูงเฉลี่ยปีละ 8-12% (ณัฐพงษ์ และเสกสรร, ม.ป.ป.) เมื่อเทียบกับอัตราดอกเบี้ยเงินฝากในปัจจุบันนั้นอยู่ในระดับที่ต่ำใกล้เคียง 0% แต่หากนักลงทุนเลือกลงทุนผิดทางตลาดหุ้นก็สามารถทำให้นักลงทุนเสียสูญเสียเงินได้เช่นเดียวกัน

ด้วยการพัฒนาเทคโนโลยีที่ก้าวไกลในปัจจุบัน ประกอบกับความสามารถของคอมพิวเตอร์ที่มีศักยภาพสูงขึ้นอย่างไม่เคยปรากฏมาก่อน ทำให้เราสามารถวิเคราะห์ข้อมูลได้มากขึ้นและด้วยวิธีที่มีการคำนวณที่ซับซ้อนสูงขึ้น หนึ่งในศาสตร์การวิเคราะห์ข้อมูลที่มีพัฒนาและได้รับความนิยมสูงคือศาสตร์ความรู้ด้านการเรียนรู้เชิงลึก (Deep Learning) ซึ่งเป็นศาสตร์สาขาหนึ่งของการเรียนรู้ของเครื่องจักร (Machine Learning) ซึ่งศาสตร์การเรียนรู้เชิงลึก (Deep Learning) นี้สามารถนำมาประยุกต์ใช้ในการทำนายราคาหุ้นเพื่อเพิ่มความแม่นยำและสร้างผลตอบแทนในการลงทุนที่สูงขึ้นให้กับนักลงทุนได้ โดยแบบจำลองการเรียนรู้เชิงลึก (Deep Learning) นั้นจะมีความสามารถที่โดดเด่นกว่าแบบจำลองในอดีตเพราะตัวแบบจำลองการเรียนรู้เชิงลึก (Deep Learning) นั้นมีความสามารถในการเรียนรู้ประสบการณ์จากข้อมูลในอดีตที่มีความซับซ้อนสูง ทำให้แบบจำลองสามารถทำนายผลของข้อมูลออกมาได้อย่างแม่นยำ (Hiransha et al., 2018) ซึ่งแบบจำลองนี้ประกอบไปด้วยนิเวศน์เน็ตเวิร์กแบบคอนโวลูชัน (Convolutional Neural Network) และหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory) เพื่อเพิ่มประสิทธิภาพในผลตอบแทนเฉลี่ยต่อปีที่ได้จากการจำลองการซื้อขายการซื้อขาย (พิศุทธิ์ อ่อนเจริญ, 2561) จึงเป็นที่มาของงานวิจัยชิ้นนี้ที่ต้องการนำองค์ความรู้ด้านการเรียนรู้เชิงลึก (Deep Learning) มาใช้ในการทำนายดัชนีตลาดหลักทรัพย์แห่งประเทศไทย ประกอบกับงานวิจัยสาขานี้ในตลาดหุ้นของประเทศไทยยังมีน้อยจึงทำให้ผู้วิจัยต้องการศึกษาและเติมเต็มช่องว่างนี้

ทบทวนวรรณกรรม

การทำนายราคาหรือดัชนีหุ้นเป็นเรื่องที่หลายคนให้ความสนใจอย่างยาวนานและเป็นเรื่องที่มีความท้าทายสูง Jeon et al. (2018:171-187) ได้เสนอแนวคิดเรื่อง Pattern Graph Tracking-Based Stock Price Prediction Using Big Data โดยพวกเขาได้ทำการศึกษารูปแบบราคา (Price Pattern) ของหุ้นในตลาดหลักทรัพย์ในประเทศเกาหลีใต้ในแต่ละวันเพื่อที่จะหารูปแบบ (Pattern) แล้วนำรูปแบบ (Pattern) นั้นมาใช้ในการทำนายราคาหุ้นโดยพวกเขาได้ใช้วิธี Time Warping ประกอบกับ Stepwise Regression และแบบจำลองโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) ประมวลผลผ่าน Hadoop ภาษา R และ Hive แต่ความแม่นยำของแบบจำลองไม่ได้สูงมากตามที่พวกเขาตั้งเป้าหมายไว้

อีกด้านหนึ่งมีนักวิจัยนำเครื่องมือทางการเรียนรู้ของเครื่องจักร (Machine Learning) และการประมวลผลเชิงลึก (Deep Learning) เข้ามาใช้ในการทำวิจัยด้านการทำนายราคาหุ้นหรือดัชนีของตลาดหลักทรัพย์ Yetis, Kaplan, and Jamshidi (2014, pp. 718-722) ได้นำเสนอผลงานเรื่อง Stock Market Prediction by Using Artificial Neural Network โดยพวกเขาได้พยายามที่จะสร้างโมเดลในการทำนายราคาหุ้นใน NASDAQ พวกเขาเลือกใช้แบบจำลองโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) และเลือกตัวแปรที่นำมาทำนายคือ ราคาเปิด ราคาสูงสุด ราคาต่ำสุด ราคาปิด และปริมาณการซื้อขายในหนึ่งวันเพื่อที่จะทำนายราคาปิดของหุ้นในวันถัดไป นอกจากนี้ยังมีงานวิจัยของ Selvin et al. (2017: 1643-1647) ได้เสนอผลงานเรื่อง Stock Price Prediction Using LSTM RNN AND CNN-Sliding Window Model โดยพวกเขาได้ทดสอบเปรียบเทียบการใช้ Recurrent Neural Network (RNN) Convolutional Neural Network (CNN) Long Short-Term Memory (LSTM) ในการทำนายราคาหุ้น ซึ่งพบว่า CNN สามารถทำนายผลได้แม่นยำมากที่สุด ในทางเดียวกัน Hiransha et al. (2018, pp. 1351-1362) ได้เสนอผลงานในเรื่อง NSE Stock Market Prediction Using Deep-Learning Models โดยใช้ขนาดหน้าต่าง (Window Size) คือจำนวนวันย้อนหลังที่ใช้ในการทำนาย 200 วัน เพื่อทำนายราคาหุ้นในอีก 10 วันข้างหน้า พบว่า CNN นั้นให้ผลการทำนายที่มีความแม่นยำสูงสุดจากการวัดด้วยค่าเฉลี่ยความผิดพลาดร้อยละสัมบูรณ์ (Mean Absolute Percent Error: MAPE) เมื่อเทียบกับแบบจำลองอื่น ๆ ไม่ว่าจะเป็น RNN, LSTM รวมทั้ง Multilayer Perceptron (MLP) และในปี 2020 ก็ได้มีงานวิจัยที่ออกมาสนับสนุนในลักษณะเดียวกันว่า CNN นั้นมีความแม่นยำในการทำนายมากที่สุดคืองานของ Mehtab, Sen, and Dasgupta (2020) ได้ทดลองใช้ CNN และ LSTM ซึ่งประกอบไปด้วย 7 แบบจำลองในการทำนายราคาเปิดของตลาดหุ้น NSE ประเทศอินเดีย โดยทดลองใช้ขนาดหน้าต่าง (Window Size) ประกอบไปด้วย 5 วัน และ 10 วัน ผลปรากฏว่า CNN ในขนาดหน้าต่าง (Window Size) เท่ากับ 5 วันให้ผลการทำนายที่แม่นยำมากกว่า LSTM รวมทั้งยังงานวิจัยที่ได้มีการนำ CNN ไปทดลองใช้ในแง่ต่าง ๆ ไม่ว่าจะเป็นงานของ Mehtab and Sen (2020) พวกเขาได้ทดลองใช้ CNN แบบตัวแปรเดียว (Univariate) กับ CNN หลายตัวแปร (Multivariate) พบว่าการใช้ CNN หลายตัวแปร (Multivariate) นั้นให้ผลที่แม่นยำมากกว่าทั้งการใช้แบบจำลอง CNN แบบตัวแปรเดียว (Univariate) รวมทั้ง Support Vector Machines (SVM) ด้วย

นอกจากนี้ยังมีงานวิจัยในด้านการทำนายราคาหุ้นในการใช้เทคนิคอื่น ๆ อีกไม่ว่าจะเป็นในส่วนการนำการประมวลผลภาษาธรรมชาติ (NLP) เข้ามาในงานวิจัยของ Mehtab and Sen (2019) ได้นำแบบจำลอง LSTM เข้ามาใช้ในการทำนายราคาดัชนี NIFTY50 รวมกับการใช้การวิเคราะห์ความรู้สึก (Sentiment Analysis) กับข้อความในทวิตเตอร์ (Twitter) พบว่า ผลการทำนายมีความแม่นยำมากกว่าการใช้การวิเคราะห์การถดถอย (Regression) ทำนายอย่างเดียว ทั้งนี้ยังมีงานของ Niu et al. (2020) เสนองานวิจัยที่จะทำนายราคาหุ้นผ่านการใช้แบบจำลองการเรียนรู้เชิงลึก (Deep Learning) โดยพวกเขาได้ทำแบบจำลองในการทำนายราคาหุ้นขึ้นมาโดยมีการใช้การเลือกตัวแปร (Feature Selection) 2 ขั้นตอนคือการใช้ RRelief อัลกอริทึมและการใช้แบบจำลอง Multi Objective Wrapper Based หลังจากที่ได้ทำการเลือก

ตัวแปร (Features) แล้วจะเอาเข้าไปสอน (Train) แบบจำลองการเรียนรู้เชิงลึก (Deep Learning) ซึ่งประกอบไปด้วย 3 ชั้นคือ Convolutional LSTM LSTM และ Gated Recurrent Unit (GRU) และเมื่อได้การทำนายออกมาก็จะนำผลการทำนายนั้นไปเข้าในแบบจำลองที่ปรับค่าความคลาดเคลื่อน (Error Correction) อีกครั้งก่อนที่จะได้ผลการทำนายออกมา โดยพวกเขาได้ทำการทดสอบแบบจำลองนี้กับการทำนายดัชนีเอสแอนด์พีไอ (SZCI) ที่เป็นดัชนีของตลาดหลักทรัพย์ที่เซินเจิ้น ดัชนีของตลาดหลักทรัพย์เซี่ยงไฮ้ ประเทศจีนและดัชนีดาวโจนส์ (Dow Jones) ประเทศสหรัฐอเมริกา โดยผลการทำนายที่ออกมานั้นมีค่า Mean Absolute Error (MAE) ที่ดีกว่าแบบจำลองตั้งต้น (Baseline) มาก

ในภาพรวมจะเห็นได้ว่าแนวทางวิจัยด้านการทำนายราคาหรือดัชนีนั้นเริ่มมีการปรับเปลี่ยนจากการวิเคราะห์รูปแบบราคา (Price Pattern) อย่างเดียวมาใช้เครื่องมือในการสร้างแบบจำลองการเรียนรู้ของเครื่องจักร (Machine Learning) และการเรียนรู้เชิงลึก (Deep Learning) ซึ่งในงานวิจัยโดยรวมนั้นจะเห็นว่าผลงานวิจัยส่วนมากจะชี้ไปในทิศทางเดียวกันว่าการนำแบบจำลองการเรียนรู้เชิงลึก (Deep Learning) แบบ CNN มาใช้ในการทำนายราคาหุ้นนั้นจะไปผลลัพธ์หรือความแม่นยำมากกว่าการใช้การเรียนรู้ของเครื่องจักร (Machine Learning) และการเรียนรู้เชิงลึก (Deep Learning) แบบอื่น ๆ

วัตถุประสงค์ของการวิจัย

1. เพื่อศึกษาการนำเทคนิคการเรียนรู้เชิงลึก (Deep Learning) แบบ Convolutional Neural Network (CNN) และ Long Short-Term Memory (LSTM) มาใช้ในการทำนายข้อมูลอนุกรมเวลาผ่านข้อมูลดัชนีตลาดหลักทรัพย์แห่งประเทศไทยซึ่งประกอบไปด้วยดัชนี SET และ SET50
2. เพื่อศึกษาเปรียบเทียบความแม่นยำในการทำนายราคาปิดของดัชนี SET และ SET50 ผ่านแบบจำลอง Convolutional Neural Network (CNN) และ Long Short-Term Memory (LSTM) โดยการทำการวิเคราะห์ถดถอย (Regression)

วิธีดำเนินการวิจัย

ในการศึกษาวิจัยครั้งนี้จะมุ่งเน้นในการศึกษาการนำการเรียนรู้เชิงลึก (Deep Learning) แบบ Convolutional Neural Network (CNN) และ Long Short-Term memory (LSTM) ไปประยุกต์ใช้ในการสร้างแบบจำลองการทำนายราคาปิดของดัชนีตลาดหลักทรัพย์แห่งประเทศไทยซึ่งประกอบไปด้วย 2 ดัชนี คือ SET และ SET50

การเก็บรวบรวมข้อมูล

ในส่วนของคุณข้อมูลในงานวิจัยชิ้นนี้ประกอบด้วย 2 ชุดข้อมูลคือ ดัชนี SET และ SET50 ซึ่งถูกเก็บรวบรวมมาเป็นแบบข้อมูลทุติยภูมิจาก 2 แหล่งข้อมูลดังนี้ www.siamchart.com และโปรแกรม SETSMART ประกอบไปด้วยราคา ราคาเปิด ราคาสูงสุด ราคาต่ำสุด ราคาปิด และปริมาณการซื้อขาย เป็นข้อมูลแบบ

รายวัน และช่วงระยะเวลาของข้อมูลดัชนีที่ได้นำมาใช้ในงานวิจัยชิ้นนี้คือ ตั้งแต่วันที่ 4 มกราคม 2010 ถึงวันที่ 30 ธันวาคม 2020 จำนวนทั้งสิ้น 2,684 แถว

การเตรียมข้อมูล

การสร้างแบบจำลองด้วยการใช้การเรียนรู้เชิงลึก (Deep Learning) นั้นมีความได้เปรียบกว่าการใช้แบบจำลองอื่น ๆ ที่สามารถทำงานได้ดีในข้อมูลดิบที่เป็นอนุกรมเวลา (Time Series) โดยไม่ต้องมีการทำการเตรียมข้อมูล (Cañizo et al., 2019, pp. 246-260) ประกอบกับตัวแบบจำลองที่ใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) นั้นมีความต้านทานต่อค่าผิดปกติ (Outlier) ดังนั้นในการทำวิจัยครั้งนี้จะไม่มีการตัดค่าผิดปกติ (Outlier) ของข้อมูลออก

ในส่วนของการระบุข้อมูล (Label) สำหรับแบบจำลองการเรียนรู้เชิงลึก (Deep Learning) จะมีการระบุข้อมูล (Label) เป็นราคาปิดในวันถัดไปของดัชนี

การแบ่งข้อมูลเพื่อสอนและทดสอบ (Train & Test)

การแบ่งข้อมูลในการสอนและทดสอบ (Train & Test) ของชุดข้อมูลทั้งดัชนี SET และ SET50 จะถูกแบ่งด้วยวิธีการแบบนำออก (Hold Out) คือการแบ่งข้อมูลออกเป็น 2 ส่วน ส่วนแรกคือชุดข้อมูลสำหรับการสอนแบบจำลอง (Train Set) จะประกอบไปด้วยข้อมูลระหว่างปี 2010 ถึงปี 2018 และส่วนที่สองคือชุดข้อมูลสำหรับการทดสอบแบบจำลอง (Test Set) จะประกอบไปด้วยข้อมูลในช่วงปี 2019 และปี 2020

แบบจำลองการเรียนรู้เชิงลึก (Deep Learning)

Convolutional Neural Network หรือ CNN นั้นเป็นการเรียนรู้เชิงลึก (Deep Learning) ที่นิยมนำมาใช้ในการสร้างโมเดลด้านงานคอมพิวเตอร์วิทัศน์ (Computer Vision) ประกอบไปด้วยส่วนประกอบที่สำคัญ 2 ส่วน คือ Convolutional Layer และ Max Pooling Layer ซึ่ง Convolutional Layer นั้นใช้ในการอ่านข้อมูลที่เข้ามาตัวอย่างเช่น รูปภาพ และใช้เคอร์เนล (Kernel) ในการอ่านข้อมูลเล็ก ๆ ในรูปภาพตามขนาดของเคอร์เนล (Kernel) ที่ถูกกำหนดไว้จนทั่วทั้งรูปภาพ โดยแต่ละครั้งที่เคอร์เนล (Kernel) เคลื่อนไปจะมีการใช้การกรอง (Filter) เพื่อรวม (Map) ข้อมูลออกมาใหม่โดยเป็นตัวแทนของข้อมูลที่รับเข้ามา (Input) ส่วน Max Pooling เป็นส่วนช่วยในการดึงองค์ประกอบที่สำคัญของข้อมูลออกมา (Mehtab & Sen, 2020) ซึ่งนอกจากจะได้องค์ประกอบที่สำคัญแล้วยังทำให้ขนาดของข้อมูลที่รับเข้ามา (Input) เล็กลงอีกด้วยเพื่อที่พร้อมจะเอาไปประมวลผลต่อในขั้นตอนถัด ๆ ไป ในทางกลับกันงานด้านอนุกรมเวลาเองก็สามารถนำ CNN มาใช้ในการสร้างโมเดลได้เช่นกันโดยการใช้ Convolutional 1D

Long Short-Term Memory (LSTM) นั้นถูกออกแบบมาให้มีความสามารถในการอ่านข้อมูลที่เป็นอนุกรมซึ่งมีความเหมาะสมกับการนำมาใช้ในงานด้านการประมวลผลภาษาธรรมชาติ (Natural Language Processing: NLP) และอนุกรมเวลา โดยโครงสร้างของ LSTM จะประกอบไปด้วยเซลล์และประตู (Gate) ซึ่งตัวประตู (Gate) ทำหน้าที่ในการรับข้อมูลจากอนุกรมก่อนหน้าเข้ามาประมวลผลแล้วเลือกที่จะละเลยหรือทิ้งข้อมูลที่ไม่มีความสำคัญรวมทั้งทำหน้าที่ในการจดจำเฉพาะแต่สิ่งที่สำคัญไว้

ในงานวิจัยชิ้นนี้ได้นำรูปแบบโครงสร้างของการเรียนรู้เชิงลึก (Deep Learning) จากงานวิจัยเรื่อง Analysis and Forecasting of Financial Time Series Using CNN and LSTM-Based Deep Learning Models ของ Mehtab et al. (2020) มาเป็นตัวแบบในการสร้างแบบจำลองเพื่อใช้ทำนายราคาปิดของดัชนี SET และ SET50 ซึ่งแบบจำลองในงานวิจัยชิ้นนี้ประกอบไปด้วย 5 แบบจำลองคือ

1. แบบจำลอง CNN โดยการใช้ตัวแปรแบบตัวแปรเดียว (Univariate) คือราคาปิด 5 วันก่อนหน้า ซึ่งมีโครงสร้างแบบจำลองตามภาพที่ 1 ก. มีการรับข้อมูลเข้ามาเป็น (5,1) แล้วทำ Convolutional 1D และ Max Pooling อย่างละ 1 รอบแล้วนำข้อมูลผ่านไปทำการปรับเรียบ (Flatten) และผ่านชั้นการติดต่อแบบสมบูรณ์ (Dense) จำนวน 2 รอบจึงเป็นผลลัพธ์ของการทำนาย


2. แบบจำลอง CNN โดยใช้ตัวแปรแบบหลายตัวแปร (Multivariate) ประกอบไปด้วย ราคาเปิด ราคาสูงสุด ราคาต่ำสุด ราคาปิด และปริมาณการซื้อขาย ย้อนหลัง 10 วันก่อนหน้าซึ่งมีโครงสร้างแบบจำลองตามภาพที่ 1 ข. มีการรับข้อมูลเข้ามาเป็น (10,5) แล้วผ่านการทำ Convolutional 1D จำนวน 3 รอบ ผ่านชั้น Max Pooling จำนวน 2 รอบแล้วนำข้อมูลผ่านไปทำการปรับเรียบ (Flatten) และผ่านชั้นการติดต่อแบบสมบูรณ์ (Dense) จำนวน 2 รอบแล้วจึงเป็นผลลัพธ์ของการทำนาย

3. แบบจำลอง LSTM โดยการใช้ตัวแปรแบบตัวแปรเดียว (Univariate) คือราคาปิด 5 วันก่อนหน้า มีโครงสร้างแบบจำลองตามภาพที่ 2 ก. มีการรับข้อมูลเข้ามาเป็น (5,1) ผ่านการทำ LSTM จำนวน 1 รอบแล้วนำข้อมูลไปผ่านทำการปรับเรียบ (Flatten) และผ่านชั้นการติดต่อแบบสมบูรณ์ (Dense) 2 รอบแล้วจึงเป็นผลลัพธ์ของการทำนาย


4. แบบจำลอง LSTM แบบ Encoder-Decoder โดยการใช้ตัวแปรแบบตัวแปรเดียว (Univariate) คือราคาปิด 10 วันก่อนหน้าซึ่งมีโครงสร้างแบบจำลองตามภาพที่ 2 ข. มีการรับข้อมูลเข้ามาเป็น (10,1) แล้วผ่านการทำ LSTM จำนวน 2 รอบ โดยระหว่าง 2 รอบนั้นข้อมูลจะมีการไหลผ่านชั้น Repeat Vector หลังจากนั้นแล้วนำข้อมูลผ่านไปชั้นการติดต่อแบบสมบูรณ์แบบ Time Distributed Dense 2 รอบแล้วจึงเป็นผลลัพธ์ของการทำนาย

5. แบบจำลอง LSTM แบบ Encoder-Decoder โดยใช้ตัวแปรแบบหลายตัวแปร (Multivariate) ซึ่งประกอบไปด้วย ราคาเปิด ราคาสูงสุด ราคาต่ำสุด ราคาปิด และปริมาณการซื้อขาย ย้อนหลัง 10 วันก่อนหน้า มีโครงสร้างแบบจำลองตามภาพที่ 2 ค. มีการรับข้อมูลเข้ามาเป็น (10,5) โดยข้อมูลจะมีการวิ่งผ่านโครงสร้างของ LSTM แบบเดียวกับแบบจำลองก่อนหน้าแล้วจึงเป็นผลลัพธ์ของการทำนาย

โดยแบบจำลองทั้ง 5 ที่ได้กล่าวมานั้นมีการใช้ฟังก์ชันกระตุ้น (Activation Function) คือ ReLU และใช้ตัวเพิ่มประสิทธิภาพ (Optimizer) คือ Adam โดยสอน (Train) ทุก ๆ แบบจำลองผ่าน Epoch 20 ครั้งเพื่อปรับค่าน้ำหนัก




ภาพที่ 1 ก.




ภาพที่ 1 ข.


ภาพที่ 1: โครงสร้างแบบจำลอง Convolutional Neural Network (CNN)



ภาพที่ 2 ก.



ภาพที่ 2 ข.



ภาพที่ 2 ค.

ภาพที่ 2: โครงสร้างแบบจำลอง Long Short-Term Memory (LSTM)

การประเมินผลของแบบจำลอง

การประเมินผลของแบบจำลองจะวัดจากค่ารากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (Root Mean Square Error: RMSE) ซึ่งจะมีการวัดใน 2 รูปแบบคือการวัดค่า RMSE จากผลการทำนายทั้งหมดและการวัดค่า RMSE แยกตามวันในสัปดาห์ตามแบบงานวิจัยของ Mehtab, Sen, and Dasgupta (2020) โดยจะมีการวัดค่า RMSE ทั้งหมด 10 ครั้งในแต่ละแบบจำลองแล้วหาค่าเฉลี่ย ค่าต่ำสุด ค่าสูงสุด และส่วน

เบี่ยงเบนมาตรฐานออกมา ซึ่งหากค่า RMSE มีค่ามากจะหมายความว่าแบบจำลองมีค่าความคลาดเคลื่อน (Error) มาก



ผลการวิจัยและอภิปรายผล

จากการศึกษาเรื่องการเรียนรู้เชิงลึก (Deep Learning) ที่นำไปใช้ในการทำนายดัชนีตลาดหลักทรัพย์ โดยผลการศึกษาก็จะแบ่งออกเป็น 2 ส่วนคือ ดัชนี SET และ SET50 ค่าที่ได้จะเป็นค่าเฉลี่ย ค่าต่ำสุด ค่าสูงสุด และส่วนเบี่ยงเบนมาตรฐานของ RMSE ที่ได้ทำการทำนายผ่านแบบจำลองจำนวน 10 ครั้งในทุก ๆ แบบจำลอง

แบบจำลองที่ 1 CNN ที่ใช้ตัวแปรแบบตัวแปรเดียว (Univariate) คือราคาปิด 5 วันก่อนหน้าในการทำนายราคาปิดของดัชนี SET และ SET50 ในวันถัดมา จากตารางที่ 1 มีค่า RMSE เฉลี่ยอยู่ที่ 0.029 และ 0.032 ตามลำดับ โดยการทำนายในส่วนหนึ่งของวันในหนึ่งสัปดาห์ประกอบไปด้วย วันจันทร์ วันอังคาร วันพุธ วันพฤหัสบดี และวันศุกร์ จากภาพที่ 3 ดัชนี SET มีค่า RMSE เฉลี่ยดังนี้ 0.029 0.028 0.029 0.027 และ 0.034 ตามลำดับ และดัชนี SET50 มีค่า RMSE เฉลี่ยดังนี้รายวันดังนี้ 0.032 0.031 0.032 0.029 และ 0.037 ตามลำดับ

ตารางที่ 1: ค่า RMSE ที่ได้จากการทำนาย โดยแบบจำลอง CNN ที่ใช้ตัวแปรแบบตัวแปรเดียว (Univariate) คือราคาปิด 5 วันก่อนหน้า

CNN Univariate												
RMSE	SET						SET50					
	All	Monday	Tuesday	Wednesday	Thursday	Friday	All	Monday	Tuesday	Wednesday	Thursday	Friday
Mean	0.029	0.029	0.028	0.029	0.027	0.034	0.032	0.032	0.031	0.032	0.029	0.037
Min	0.028	0.027	0.027	0.027	0.026	0.032	0.030	0.029	0.028	0.029	0.026	0.035
Max	0.032	0.031	0.031	0.032	0.030	0.036	0.036	0.035	0.036	0.036	0.034	0.041
SD	0.002	0.002	0.002	0.002	0.002	0.001	0.002	0.002	0.003	0.003	0.003	0.002





ภาพที่ 3: ค่า RMSE เฉลี่ยรายวันที่ได้จากการทำนาย โดยแบบจำลอง CNN ที่ใช้ตัวแปรแบบตัวแปรเดียว (Univariate) คือราคาปิด 5 วันก่อนหน้า

แบบจำลองที่ 2 CNN ที่ใช้ตัวแปรแบบหลายตัวแปร (Multivariate) ย้อนหลัง 10 วันก่อนหน้าในการทำนายราคาปิดของดัชนี SET และ SET50 ในวันถัดมา จากตารางที่ 2 มีค่า RMSE เฉลี่ยอยู่ที่ 0.085 และ

0.133 ตามลำดับ โดยการทำนายในส่วนของวันในหนึ่งสัปดาห์ประกอบไปด้วย วันจันทร์ วันอังคาร วันพุธ วันพฤหัสบดี และวันศุกร์ จากภาพที่ 4 ดัชนี SET มีค่า RMSE เฉลี่ยดังนี้ 0.085 0.084 0.082 0.089 และ 0.083 ตามลำดับ และดัชนี SET50 มีค่า RMSE เฉลี่ยรายวันดังนี้ 0.131 0.132 0.132 0.138 และ 0.129 ตามลำดับ

ตารางที่ 2: ค่า RMSE ที่ได้จากการทำนายผ่านแบบจำลอง CNN ที่ใช้ตัวแปรแบบหลายตัวแปร (Multivariate) ย้อนหลัง 10 วันก่อนหน้า

RMSE	CNN Multivariate											
	SET						SET50					
	All	Monday	Tuesday	Wednesday	Thursday	Friday	All	Monday	Tuesday	Wednesday	Thursday	Friday
Mean	0.085	0.085	0.084	0.082	0.089	0.083	0.133	0.131	0.132	0.132	0.138	0.129
Min	0.062	0.062	0.061	0.058	0.066	0.060	0.099	0.098	0.098	0.097	0.104	0.096
Max	0.170	0.171	0.170	0.169	0.174	0.168	0.164	0.163	0.163	0.163	0.169	0.159
SD	0.031	0.031	0.031	0.031	0.031	0.031	0.020	0.021	0.021	0.020	0.021	0.020





ภาพที่ 4: ค่า RMSE เฉลี่ยรายวันที่ได้จากการทำนายผ่านแบบจำลอง CNN ที่ใช้ตัวแปรหลายตัวแปร (Multivariate) ย้อนหลัง 10 วันก่อนหน้า

แบบจำลองที่ 3 LSTM โดยการใช้ตัวแปรแบบตัวแปรเดียว (Univariate) คือราคาปิด 5 วันก่อนหน้า ในการทำนายราคาปิดของดัชนี SET และ SET50 ในวันถัดมา จากตารางที่ 3 มีค่า RMSE เฉลี่ยอยู่ที่ 0.072 และ 0.063 ตามลำดับ โดยการทำนายในส่วนของวันในหนึ่งสัปดาห์ประกอบไปด้วย วันจันทร์ วันอังคาร วันพุธ วันพฤหัสบดี และวันศุกร์ จากภาพที่ 5 ดัชนี SET มีค่า RMSE เฉลี่ยดังนี้ 0.073 0.070 0.073 0.072 และ 0.075 ตามลำดับ และดัชนี SET50 มีค่า RMSE เฉลี่ยรายวันดังนี้ 0.064 0.060 0.064 0.062 และ 0.067 ตามลำดับ

ตารางที่ 3: ค่า RMSE ที่ได้จากการทำนายผ่านแบบจำลอง LSTM โดยการใช้ตัวแปรแบบตัวแปรเดียว (Univariate) คือราคาปิด 5 วันก่อนหน้า

RMSE	LSTM Univariate											
	SET						SET50					
	All	Monday	Tuesday	Wednesday	Thursday	Friday	All	Monday	Tuesday	Wednesday	Thursday	Friday
Mean	0.072	0.073	0.070	0.073	0.072	0.075	0.063	0.064	0.060	0.064	0.062	0.067
Min	0.038	0.037	0.034	0.038	0.037	0.041	0.039	0.039	0.035	0.040	0.038	0.043
Max	0.184	0.185	0.183	0.183	0.182	0.186	0.096	0.097	0.093	0.096	0.094	0.099
SD	0.056	0.057	0.057	0.056	0.056	0.056	0.021	0.021	0.021	0.020	0.021	0.021





ภาพที่ 5: ค่า RMSE เฉลี่ยรายวันที่ได้จากการทำนายผ่านแบบจำลอง LSTM โดยการใช้ตัวแปรแบบตัวแปรเดียว(Univariate) คือราคาปิด 5 วันก่อนหน้า

แบบจำลองที่ 4 LSTM แบบ Encoder-Decoder โดยการใช้ตัวแปรแบบตัวแปรเดียว (Univariate) คือราคาปิด 10 วันก่อนหน้าในการทำนายราคาปิดของดัชนี SET และ SET50 ในวันถัดมา จากตารางที่ 4 มีค่า RMSE เฉลี่ยอยู่ที่ 0.238 และ 0.274 ตามลำดับ โดยการทำนายในส่วนหนึ่งของวันในหนึ่งสัปดาห์ประกอบไปด้วย วันจันทร์ วันอังคาร วันพุธ วันพฤหัสบดี และวันศุกร์ จากภาพที่ 6 ดัชนี SET มีค่า RMSE เฉลี่ยดังนี้ 0.239 0.237 0.238 0.239 และ 0.237 ตามลำดับ และดัชนี SET50 มีค่า RMSE เฉลี่ยรายวันดังนี้ 0.276 0.273 0.275 0.274 และ 0.273 ตามลำดับ

ตารางที่ 4: ค่า RMSE ที่ได้จากการทำนายผ่านแบบจำลอง LSTM แบบ Encoder-decoder โดยการใช้ตัวแปรแบบเดียว (Univariate) คือราคาปิด 10 วันก่อนหน้า

Encoder-Decoder LSTM Univariate												
RMSE	SET						SET50					
	All	Monday	Tuesday	Wednesday	Thursday	Friday	All	Monday	Tuesday	Wednesday	Thursday	Friday
Mean	0.238	0.239	0.237	0.238	0.239	0.237	0.274	0.276	0.273	0.275	0.274	0.273
Min	0.203	0.204	0.203	0.204	0.204	0.203	0.239	0.241	0.238	0.240	0.239	0.237
Max	0.283	0.284	0.282	0.283	0.283	0.281	0.301	0.304	0.300	0.302	0.302	0.300
SD	0.028	0.028	0.029	0.028	0.028	0.028	0.023	0.023	0.024	0.023	0.023	0.023





ภาพที่ 6: ค่า RMSE เฉลี่ยรายวันที่ได้จากการทำนายผ่านแบบจำลอง LSTM แบบ Encoder-Decoder โดยการใช้ตัวแปรแบบเดียว (Univariate) คือราคาปิด 10 วันก่อนหน้า

แบบจำลองที่ 5 LSTM แบบ Encoder-Decoder ที่ใช้ตัวแปรแบบหลายตัวแปร (Multivariate) ย้อนหลัง 10 วันก่อนหน้าในการทำนายราคาปิดของดัชนี SET และ SET50 ในวันถัดมา จากตารางที่ 5 มีค่า

RMSE เฉลี่ยอยู่ที่ 0.263 และ 0.280 ตามลำดับ โดยการทำนายในส่วนหนึ่งของวันในหนึ่งสัปดาห์ประกอบไปด้วย วันจันทร์ วันอังคาร วันพุธ วันพฤหัสบดี และวันศุกร์ จากภาพที่ 7 ดัชนี SET มีค่า RMSE เฉลี่ยดังนี้ 0.262 0.266 0.262 0.268 และ 0.255 ตามลำดับ และดัชนี SET50 มีค่า RMSE เฉลี่ยรายวันดังนี้ 0.280 0.283 0.279 0.286 และ 0.271 ตามลำดับ

ตารางที่ 5: ค่า RMSE ที่ได้จากการทำนายผ่านแบบจำลอง LSTM แบบ Encoder-Decoder โดยใช้ตัวแปรแบบหลายตัวแปร (Multivariate) ย้อนหลัง 10 วันก่อนหน้า

Encoder-Decoder LSTM Multivariate												
RMSE	SET						SET50					
	All	Monday	Tuesday	Wednesday	Thursday	Friday	All	Monday	Tuesday	Wednesday	Thursday	Friday
Mean	0.263	0.262	0.266	0.262	0.268	0.255	0.280	0.280	0.283	0.279	0.286	0.271
Min	0.202	0.201	0.205	0.202	0.207	0.195	0.261	0.261	0.264	0.261	0.268	0.252
Max	0.315	0.313	0.319	0.313	0.320	0.306	0.311	0.310	0.314	0.310	0.318	0.302
SD	0.047	0.047	0.048	0.047	0.047	0.046	0.017	0.017	0.018	0.017	0.017	0.017



ภาพที่ 7: ค่า RMSE เฉลี่ยรายวันที่ได้จากการทำนายผ่านแบบจำลอง LSTM แบบ Encoder-decoder โดยใช้ตัวแปรหลายตัวแปร (Multivariate) ของราคาปิด 10 วันก่อนหน้า

สรุป

ในการทำวิจัยครั้งนี้ได้มีการแบ่งข้อมูลการสอน (Train) ออกเป็นช่วงต้นปี 2010 ถึงสิ้นปี 2018 และข้อมูลทดสอบ (Test) อยู่ในช่วงต้นปี 2019 ถึงสิ้นปี 2020 พร้อมกันนี้ยังใช้ข้อมูลดัชนีตลาดหลักทรัพย์แห่งประเทศไทย 2 ดัชนีซึ่งประกอบไปด้วย SET และ SET50

พบว่าการทำวิเคราะห์การถดถอย (Regression) เพื่อทำนายราคาปิดของดัชนี SET และ SET50 แบบจำลองที่ให้ความแม่นยำสูงสุดคือ CNN ที่ใช้ตัวแปรแบบตัวแปรเดียว (Univariate) คือราคาปิด 5 วันก่อนหน้าในการทำนายราคาปิดของทั้งดัชนี SET และ SET50 ในวันถัดมา โดยมีค่า RMSE เฉลี่ยน้อยที่สุดเมื่อเปรียบเทียบกับแบบจำลองอื่น ๆ คือ มีค่า RMSE เฉลี่ยที่ 0.029 และ 0.032 ตามลำดับ

สุดท้ายนี้หากมีการนำงานวิจัยไปต่อยอดกับงานวิจัยในอนาคตอาจมีการนำแบบจำลองด้านการเรียนรู้เชิงลึก (Deep Learning) ไปใช้ในการทำนายการขึ้นลงของราคาดัชนีรวมถึงราคาหุ้นในตลาดหลักทรัพย์

เอกสารอ้างอิง

- ณัฐพงษ์ อภินันท์กุล และเสกสรร โตวิวัฒน์. (ม.ป.ป.). *ห้องเรียนนักลงทุน*. สืบค้นเมื่อ 20 มกราคม 2564, จาก SET:<https://www.set.or.th/set/education/knowledgedetail.do?contentId=6416&type=article>
- พิศุทธิ์ อ่อนเจริญ. (2561). *การทำนายแนวโน้มของตลาดหุ้นด้วยแบบจำลองการเรียนรู้เชิงลึกที่เพิ่มประสิทธิภาพพร้อมกับข้อมูลเชิงตัวเลขและข้อมูลเชิงตัวอักษร*. ปรินญาวิทยาศาสตร์มหาบัณฑิต สาขาวิชาวิทยาศาสตร์คอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์, จุฬาลงกรณ์มหาวิทยาลัย.
- วรรณณ ธาราภูมิ. (2562). *บลจ.บัวหลวงแนะนำรัฐบาลใหม่หนุนตลาดทุน*. สืบค้นเมื่อ 20 มกราคม 2564, จากฐานเศรษฐกิจ: <https://www.thansettakij.com/content/402170>
- Canizo, M., Triguero, I., Conde, A., & Onieva, E. (2019). Multi-head CNN-RNN for multi-time series anomaly detection: An industrial case study. *Neurocomputing*, 363, 246-260.
- Hiransha, M., Gopalakrishnan, E. A., Menon, V., & Soman, K. (2018). NSE Stock Market Prediction Using Deep-Learning Models. *Procedia Computer Science*, 132, 1351-1362.
- Jeon, S., Hong, B., & Chang, V. (2018). Pattern graph tracking-based stock price prediction using big data. *Future Gener. Comput. Syst.*, 80, 171-187.
- Mehtab, S. & Sen, J. (2019). *A Robust Predictive Model for Stock Price Prediction Using Deep Learning and Natural Language Processing*. Retrieved January 16, 2021, from <http://dx.doi.org/10.2139/ssrn.3502624>
- Mehtab, S. & Sen, J. (2020). *Stock Price Prediction Using Convolutional Neural Networks on a Multivariate Timeseries*. Retrieved January 2, 2021, from <https://arxiv.org/abs/2001.09769>
- Mehtab, S., Sen, J., & Dasgupta, S. (2020). *Robust Analysis and Forecasting of Financial Time Series Using CNN and LSTM-Based Deep Learning Models*. Retrieved December 28, 2020, from <https://arxiv.org/abs/2011.08011>
- Niu, T., Wang, J., Lu, H., Yang, W., & Du, P. (2020). Developing a Deep Learning Framework with Two-Stage Feature Selection for Multivariate Financial Time Series Forecasting. *Expert Syst. Appl.*, 148, 113237.
- Selvin, S., Vinayakumar, R., Gopalakrishnan, E. A., Menon, V. K., & Soman, K. P. (2017). Stock price prediction using LSTM, RNN and CNN-sliding window model. 2017



International Conference on Advances in Computing, Communications and Informatics (ICACCI) (pp. 1643-1647). Udupi: IEEE.

Yetis, Y., Kaplan, H., & Jamshidi, M. (2014). Stock market prediction by using artificial neural network. *2014 World Automation Congress (WAC)* (pp. 718-722). Waikoloa: IEEE.

ผลกระทบของสกุลเงินดิจิทัลต่อความผันผวนของอัตราแลกเปลี่ยนเงินบาทไทยและเงินตราสกุลหลัก

THE EFFECTS OF CRYPTOCURRENCIES TO THE VOLATILITY OF THE THAI BAHT EXCHANGE RATE AND MAJOR CURRENCIES

สรวิวัฒน์ วิศาลาภรณ์
Sorawat Wisalaporn

คณะเศรษฐศาสตร์ มหาวิทยาลัยเกษตรศาสตร์
Faculty of Economics, Kasetsart University

*Corresponding author, E-mail: sorawat.w@ku.th

บทคัดย่อ

งานวิจัยนี้จัดทำขึ้นเพื่อศึกษาความสัมพันธ์ของสกุลเงินดิจิทัล (บิตคอยน์และอีเธอร์เรียม) ที่มีต่อความผันผวนของเงินตราสกุลบาทไทยต่อเงินตราสกุลหลักสองสกุล ได้แก่ ดอลลาร์สหรัฐและเงินสกุลหยวนของสาธารณรัฐประชาชนจีน โดยใช้ตัวแบบ GARCH (Generalized Autoregressive Conditional Heteroskedasticity) ในการศึกษาความเกี่ยวข้องข้างต้นโดยใช้ข้อมูลรายวันในช่วง ปลายปี พ.ศ. 2558 ถึงต้นปี พ.ศ. 2564

ผลการศึกษาชี้ว่า บิตคอยน์มีผลต่อความผันผวนของอัตราแลกเปลี่ยนสกุลเงินบาทต่อทั้งดอลลาร์สหรัฐอเมริกและหยวนอย่างมีนัยสำคัญทางสถิติ แต่ยังไม่พบว่าอีเธอร์เรียมมีผลต่อความผันผวนของบาทต่อเงินตราสกุลหลักทั้งสองสกุลอย่างมีนัยสำคัญทางสถิติ

คำสำคัญ: สกุลเงินดิจิทัล อัตราแลกเปลี่ยน GARCH เงินตราสกุลหลัก

ABSTRACT

This research conducted to study the relationship of cryptocurrencies (Bitcoin and Ethereum) on the volatility of the Thai Baht currency to two major currencies: the US dollar and the Chinese Yuan. The GARCH model (Generalized Autoregressive Conditional Heteroskedasticity) model was utilized in the above relevance study using daily data from late 2015 to early 2021.

The results of the study indicated that Bitcoin has a statistically significant effect on the volatility of the Thai Baht exchange rate to both the US dollar and the Chinese Yuan. However, Ethereum has not yet been found to have a statistically significant effect on the volatility of the Baht to the two major currencies.

Keywords: Cryptocurrencies, GARCH, Exchange Rate, Major Currencies

บทนำ

ความก้าวหน้าทางเทคโนโลยีทำให้มีการสร้างเงินตราดิจิทัลขึ้นมาในระบบโดยเริ่มจากบิตคอยน์ (Bitcoin) เมื่อปี ค.ศ.2009 (Frankenfeld, 2021) กลุ่มบุคคลที่ใช้ชื่อแทนกลุ่มว่า ซาโตชิ นาคาโมโตะ (Satoshi Nakamoto) เป็นผู้สร้างสกุลเงินนี้ โดยสกุลเงินนี้มีรูปแบบทางอิเล็กทรอนิกส์เท่านั้น (Electronic Form) และมีการแลกเปลี่ยนในระบบเครือข่ายแบบเท่าเทียมกัน (Peer to Peer Network) รวมถึงเป็นสถาปัตยกรรมที่เปิดเผยโค้ดคำสั่งคอมพิวเตอร์ (Open Source)

ปัจจุบันบิตคอยน์ (Bitcoin) ได้รับความนิยมสูงสุด เนื่องจากการออกแบบที่ชาญฉลาด ตามมาด้วยอีเธอร์เรียม (Ethereum) ที่ได้รับความนิยมรองลงมาจากบิตคอยน์ และเนื่องจากคนทั่ว ๆ ไปที่มีความรู้ทางด้านคอมพิวเตอร์มากพอ ก็จะสามารถสร้างสกุลเงินดิจิทัลใหม่ ๆ ได้ โดยอาศัยการเขียนโค้ดคำสั่งและเครือข่ายคอมพิวเตอร์เท่านั้น ทำให้มีการสร้างเงินตราดิจิทัลนับพัน ๆ สกุลขึ้นมาในขณะนี้

ในงานวิจัยที่เกี่ยวข้องกับการศึกษาความสัมพันธ์ระหว่างสกุลเงินทั่ว ๆ ไป (Fiat Money) และสกุลเงินดิจิทัล (Digital Currencies หรือ Cryptocurrency) นั้น เริ่มมีการศึกษาอย่างแพร่หลายมากขึ้น จากความรู้เท่าที่ผู้วิจัยทราบ งานศึกษาส่วนใหญ่จะเป็นการศึกษาผลกระทบของปัจจัยอื่น ๆ ที่มีต่อสกุลเงินดิจิทัลหรือไม่ก็จะเป็นการศึกษาความสัมพันธ์ระหว่างสกุลเงินดิจิทัลกับสกุลเงินทั่วไป โดยเฉพาะถ้าพิจารณาในกลุ่มการศึกษาปัจจัยที่มีผลกระทบต่อความผันผวนอัตราแลกเปลี่ยนเงินบาทไทยแล้ว จะพบว่า ปัจจัยที่มีผลต่อความผันผวนมักจะเป็นปัจจัยทางสินทรัพย์ (Assets) และปัจจัยทางเศรษฐกิจเป็นหลักโดยมักไม่ได้รับรวมเงินสกุลดิจิทัลเข้าไป โดยทั่วไป การเปลี่ยนแปลงของอัตราแลกเปลี่ยนจะส่งผลกระทบต่อเศรษฐกิจไทยผ่านทางการนำเข้าและการส่งออกซึ่งการแข่งค่าของอัตราแลกเปลี่ยนจะทำให้ดุลการค้าของประเทศแย่ลง ในทางกลับกัน การอ่อนค่าของอัตราแลกเปลี่ยนจะทำให้ดุลการค้าของประเทศดีขึ้น อันจะนำไปสู่การเพิ่มขึ้นของผลิตภัณฑ์มวลรวมของประเทศ นอกจากนี้ งานของ Morina et al. (2020) ชี้ว่าความผันผวนของอัตราแลกเปลี่ยนที่ต่ำจะเอื้อต่อการเติบโตของระบบเศรษฐกิจ ซึ่งเราอาจนำแนวคิดดังกล่าวมาปรับใช้กับการพัฒนาเศรษฐกิจไทยได้ ถ้าเรามีองค์ความรู้ที่เกี่ยวข้องกับความผันผวนของอัตราแลกเปลี่ยนในระดับที่เหมาะสม จากข้อมูลข้างต้น เพื่อที่จะเพิ่มเติมองค์ความรู้เกี่ยวกับความผันผวนของอัตราแลกเปลี่ยนสกุลเงินบาทไทย ผู้วิจัยจึงเริ่มตั้งคำถามว่าเงินสกุลดิจิทัลหลัก (บิตคอยน์ และอีเธอร์เรียม) จะส่งผลกระทบต่อความผันผวนหรือความเสี่ยงของอัตราแลกเปลี่ยนเงินบาทต่อเงินตราสกุลหลักสองสกุล (บาท/ดอลลาร์สหรัฐ และ บาท/หยวนของจีน) หรือไม่?

ดังนั้น ผู้วิจัยจึงจัดทำงานวิจัยชิ้นนี้เพื่อศึกษาผลกระทบของสกุลเงินดิจิทัลสองสกุลหลักที่มีต่อความผันผวนของบาทไทยต่อเงินตราสกุลหลัก ซึ่งก็คือเงินดอลลาร์สหรัฐและเงินหยวนของจีนโดยข้อมูลรายวันย้อนหลังจากปลายปี พ.ศ. 2558 ถึงต้นปี พ.ศ. 2564 มาใช้ในการศึกษาผ่านตัวแบบ GARCH (Generalized Autoregressive Conditional Heteroskedasticity)

บททวนวรรณกรรม

งานวิจัยนี้ ผู้ศึกษาได้ตรวจสอบเอกสารและงานวิจัยที่เป็นพื้นฐานความรู้ในการวิจัย โดยแบ่งเป็นประเด็นต่าง ๆ ดังต่อไปนี้

การศึกษาความสัมพันธ์ระหว่างสกุลเงินทั่วไปและสกุลเงินดิจิทัล

Erdas & Caglar (2018) ได้ศึกษาความสัมพันธ์ระหว่างบิตคอยน์ อัตราแลกเปลี่ยนและสินค้าโภคภัณฑ์ (Commodities) ด้วยเทคนิคการทดสอบแบบ Hatemi-J Asymmetric Causality ผลการศึกษาพบความสัมพันธ์ราคาบิตคอยน์กับดัชนีตลาดหุ้น เช่น S&P 500 ส่วนความสัมพันธ์ระหว่างบิตคอยน์กับสินค้าโภคภัณฑ์อื่น ๆ ยังไม่พบหลักฐานชัดเจน (เช่น ราคาน้ำมัน สกุลเงินดอลลาร์สหรัฐและราคาทองคำ เป็นต้น) แต่อย่างไรก็ตามผู้วิจัยตั้งสมมติฐานว่าบิตคอยน์จะมีความสามารถในการอธิบายสินค้าโภคภัณฑ์ได้ โดยระดับนัยสำคัญทางสถิติที่สูงขึ้นเนื่องจากการขยายตัวในการยอมรับการใช้งานสกุลเงินดิจิทัลในหลาย ๆ ประเทศอันจะนำไปสู่ความน่าเชื่อถือของการใช้สกุลเงินประเภทนี้ต่อไปในอนาคต

Corelli (2018) ได้ทำการศึกษาความสัมพันธ์ของสกุลเงินดิจิทัลกับเงินตราที่เป็นที่รู้จักหลาย ๆ สกุลเงินทั่วโลก ผลการศึกษาชี้ว่า เงินตราสกุลดิจิทัลมีความสัมพันธ์กับเงินตราในหลาย ๆ สกุลเงินโดยเฉพาะอย่างยิ่งเงินตราในแถบเอเชียโดยเฉพาะอย่างยิ่ง ดอลลาร์ไต้หวันและเงินบาทไทย

การศึกษาปัจจัยกำหนดอัตราแลกเปลี่ยนหรือความผันผวนสกุลเงินดิจิทัล

โสภณ ถนอมเพชรสง่า และวรรณพี บานชื่นจิตร (2561) ได้วิเคราะห์ปัจจัยที่มีผลต่อราคาของบิตคอยน์และอีเธอร์เรียม โดยตัวแปรอิสระจะเป็นดัชนีหลักทรัพย์ต่างประเทศ ราคาทองคำ ราคาน้ำมันและราคาทองคำ เป็นต้น แต่สิ่งที่น่าสนใจคืองานวิจัยนี้ พบว่า ราคาของบิตคอยน์มีความสัมพันธ์กับปริมาณการค้นหาคำว่า “Bitcoin” ใน Google ส่วนปัจจัยที่มีผลต่อราคาอีเธอร์เรียม คือ ปริมาณเงินระดมทุนและปริมาณการทำธุรกรรมของสกุลเงินอีเธอร์เรียมเอง เช่นเดียวกับงานของ พัทธราลัย เขียวทอง และสุมาลี รามัญญ (2563) ที่ศึกษาผลกระทบของปัจจัยที่มีผลต่อการกำหนดราคาบิตคอยน์โดยใช้เทคนิคต่างจากงานของ โสภณ และวรรณพี รวมถึงมีการใช้สกุลเงินดิจิทัลอื่น ๆ เป็นตัวแปรอธิบายด้วย

พงศกร พัวพัฒน์กุล (2560) ศึกษาโดยใช้แบบจำลอง Multivariate GARCH (MGARCH) โดยดูว่าปัจจัยที่เกี่ยวข้องกับธุรกรรมมีผลกระทบกันอย่างไร ความผันผวนของสกุลเงินบิตคอยน์ โดยมีการศึกษาผ่านการเพิ่มตัวแปรในสมการค่าเฉลี่ยแบบมีเงื่อนไข (Conditional Mean Equations) และสมการความผันผวนแบบมีเงื่อนไข (Conditional Variance Equation) ผลการวิจัยชี้ว่า ตัวแปรเชิงธุรกรรมมีผลกับราคาบิตคอยน์ในขณะที่ไม่พบความผันผวนของบิตคอยน์กับตัวแปรเชิงธุรกรรมอื่น ๆ มีความสัมพันธ์กัน

Katsiampa (2017) ได้เปรียบเทียบตัวแบบตระกูล GARCH ในหลาย ๆ รูปแบบเพื่อรูปแบบที่เหมาะสมที่สุดในการวิเคราะห์ความผันผวนบิตคอยน์ ผู้วิจัยพบว่า ตัวแบบ AR-CGARCH มีความเหมาะสมในการอธิบายความผันผวนของบิตคอยน์ มากที่สุดทั้งในระยะสั้นและระยะยาว (Shot Run and Long Run)

Graveland (2018) ได้ใช้ตัวแบบ GARCH ในการเปรียบเทียบความผันผวนของบิตคอยน์ ตลอดจนสินทรัพย์ (Asset) ที่สำคัญ ๆ เช่น เงินหยวนของจีน เป็นต้น โดยผู้วิจัยเปรียบเทียบความผันผวนของสินทรัพย์

ที่น่าสนใจแล้วพบว่า บิตคอยน์มีความผันผวนที่ต่างจากสินทรัพย์อื่น ๆ มีการทดสอบความเกี่ยวข้องระหว่างสินทรัพย์ โดยใช้สัมประสิทธิ์สหสัมพันธ์ (Correlations) พื้นฐานแล้ว สรุปว่า บิตคอยน์ไม่มีความสัมพันธ์กับสินทรัพย์ทั่ว ๆ ไปมากนัก เว้นแต่กับค่าเงินหยวนของจีนในรูปของดอลลาร์สหรัฐ แต่อย่างไรก็ดี ผู้วิจัยไม่ได้พิจารณาความสัมพันธ์ระหว่างสินทรัพย์โดยการเพิ่มเติมตัวแปรอิสระลงในสมการความผันผวนแบบมีเงื่อนไข (Conditional Variance Equation) ซึ่งงานวิจัยในระยะหลังจะนิยมใช้ ซึ่งทำให้ทิศทางของผลที่ได้ค่อนข้างสวนทางกับงานของ Carrick (2016) ที่พบความสัมพันธ์ของบิตคอยน์กับเงินหลาย ๆ สกุลของตลาดเกิดใหม่ (Emerging Markets)

การศึกษางานศึกษาเกี่ยวกับความผันผวนของค่าเงินบาทและปัจจัยอื่น ๆ

สุภาณี หาญพัฒนานุสรณ์ (2519) ได้ใช้ตัวแบบ DCC-GARCH ในการศึกษาความสัมพันธ์ของอัตราแลกเปลี่ยนและความผันผวนในประเทศไทย อินโดนีเซีย มาเลเซีย และสิงคโปร์ ในด้านการศึกษาความสัมพันธ์ของความผันผวนของอัตราแลกเปลี่ยนในกลุ่มประเทศข้างต้น ผลวิจัยชี้ว่า ความผันผวนของอัตราแลกเปลี่ยนของกลุ่มประเทศเหล่านั้นมีความสัมพันธ์กัน ในขณะที่บางงานศึกษาก็เน้นการศึกษาความผันผวนของค่าเงินบาทและหลักทรัพย์ในประเทศ เช่น งานของ จริยภรณ์ ไชสิงห์ทอง และธงชัย อินตรา (2561) ซึ่งผลการศึกษาได้พบความสัมพันธ์ระหว่างความผันผวนของตัวแปรข้างต้นผ่านตัวแบบ GARCH เป็นที่น่าสังเกตว่าทั้งสองงานข้างต้นนี้ไม่ได้รวมเงินสกุลดิจิทัลเข้าไปเป็นตัวแปรในระบบวิเคราะห์

วัตถุประสงค์ของการวิจัย

เพื่อศึกษาผลกระทบของสกุลเงินดิจิทัลต่อความผันผวนของเงินสกุลบาทไทยต่อเงินตราสกุลหลัก

ขอบเขตของการวิจัย

สกุลเงินดิจิทัลใช้สองสกุลหลัก คือ บิตคอยน์ และอีเธอร์เรียม และเงินสกุลหลัก ใช้สองสกุลคือเงินดอลลาร์สหรัฐ และเงินหยวนของจีน

วิธีดำเนินการวิจัย

การเก็บรวบรวมข้อมูล

งานศึกษานี้ใช้การวิเคราะห์ข้อมูลทุติยภูมิ (Secondary data) ช่วงเวลา พ.ศ. 2558 - พ.ศ. 2564 จากแหล่งหลัก ๆ 2 ที่คือ ฐานข้อมูลของ Bisnews และกระทรวงพาณิชย์ โดยตัวแปรภายในที่เราจะศึกษาความผันผวน ได้แก่ อัตราแลกเปลี่ยนเงินบาทไทยต่อดอลลาร์สหรัฐและหยวนของจีน เนื่องจากมูลค่าการส่งออกและนำเข้าของประเทศไทยที่มีต่อสหรัฐอเมริกาและจีนนั้น คิดเป็นอันดับหนึ่งและอันดับสองตามลำดับจากข้อมูลการค้าระหว่างประเทศ (กระทรวงพาณิชย์, 2564) ส่วนตัวแปรควบคุมนั้นจะใช้ราคาทองคำในประเทศ (ราคาซื้อ) และตัวแปรหุ่น (Dummy Variable) แทนการเกิดการระบาดของ COVID-19 ส่วนสกุลเงิน

$$h_t = \gamma + \vartheta \varepsilon_{t-1}^2 + \theta h_{t-1} + \beta_1 BTC_t + \beta_2 ETH_t + \sum_{i=3}^4 \beta_i Regulate_{it}$$

โดยกำหนดให้

- s_t คือ ค่าคาดหวังแบบมีเงื่อนไข ณ เวลา t (เวลาเป็นรายวัน) ในที่นี้คือ บาท/ดอลลาร์สหรัฐ และ บาท/หยวน ที่แปลงรูปจากขั้นตอนแรกของการวิเคราะห์ข้อมูลแล้ว ซึ่งในการศึกษานี้จะมีทั้งสิ้น 2 ชุดสมการ
- h_t คือ ความผันผวนแบบมีเงื่อนไขของ ณ เวลา t ของอัตราแลกเปลี่ยน บาท/ดอลลาร์สหรัฐ และ บาท/หยวนของเงิน ที่แปลงรูปข้อมูลแล้วในแต่ละชุดสมการ
- μ และ γ คือ ค่าคงที่ในสมการค่าคาดหวังแบบมีเงื่อนไข และสมการความผันผวนแบบมีเงื่อนไขตามลำดับ โดยเงื่อนไขของตัวแบบ GARCH กำหนดให้ $\gamma \geq 0$ เพื่อไม่ให้ค่าความผันผวนแบบมีเงื่อนไขติดลบ
- ε_t คือ ค่าคลาดเคลื่อนของสมการค่าคาดหวังแบบมีเงื่อนไข ณ เวลา t
- BTC_t คือ ค่าของสกุลเงินบิตคอยน์ ณ เวลา t ที่ปรับข้อมูลแล้ว
- ETH_t คือ ค่าของสกุลเงินอีเธอร์เรียม ณ เวลา t ที่ปรับข้อมูลแล้ว
- $Regulate_{it}$ คือ ตัวแปรควบคุมที่ i ($i = 3, 4$) ซึ่งในที่นี้จะได้แก่ ราคาทองคำรายวันในประเทศ (ราคาซื้อ) ณ เวลา t ที่ปรับข้อมูลแล้ว และ ตัวแปรหุ่นแทนการแพร่ระบาดของ COVID-19
- ϑ คือ ค่าสัมประสิทธิ์ของ ε_{t-1}^2
- θ คือ ค่าสัมประสิทธิ์ของ h_{t-1} โดยกำหนดให้ $\gamma, \vartheta, \theta \geq 0$ เพื่อไม่ให้ค่าความผันผวนติดลบ และ $0 \leq \vartheta + \theta < 1$ เพื่อความมีเสถียรภาพของตัวแบบ
- $\beta_1 \beta_2$ คือ ค่าสัมประสิทธิ์ของตัวแปรค่าของสกุลเงินบิตคอยน์ และ ค่าของสกุลเงินอีเธอร์เรียม ตามลำดับ ณ เวลา t ที่ปรับรูปแล้วในสมการความผันผวนแบบมีเงื่อนไข
- $\beta_3 \beta_4$ คือ ค่าสัมประสิทธิ์ของตัวแปรควบคุมของ ราคาทองคำรายวันในประเทศ (ราคาซื้อ) และ ตัวแปรหุ่นแทนการแพร่ระบาดของ COVID-19 ตามลำดับ

ผลการวิจัยและอภิปรายผล

การตรวจสอบค่าสถิติพื้นฐานกับความเหมาะสมในการใช้ตัวแบบ GARCH

ในการตรวจค่าสถิติพื้นฐานและการแจกแจงของตัวแปรหลักในการวิเคราะห์ทั้ง 2 ตัว (บาท/ดอลลาร์สหรัฐ และบาท/หยวน) จะสรุปผลได้ตามตารางที่ 1 โดยเมื่อพิจารณาค่า Kurtosis พบว่า มีค่าสูงกว่า 3 ในทุก ๆ ตัวแปร แสดงว่า ตัวแปรมีไค้งการแจกแจงแบบแหลมสูง (Leptokurtic) ส่วนการทดสอบว่า ตัวแปรมีการแจกแจงปกติหรือไม่จะใช้ Jarque-Bera Test ในการทดสอบ ซึ่งค่าสถิติชี้ว่าเราสามารถปฏิเสธสมมติฐานว่างที่ว่าตัวแปรมีการแจกแจงแบบปกติได้ในระดับนัยสำคัญ 0.01 ของทั้งสองตัวแปร แสดงว่าตัวแปรทั้งคู่มีการแจกแจงที่ไม่ปกติ

ตารางที่ 1: ค่าสถิติพื้นฐานและการแจกแจงของตัวแปร

	BAHT/USD	BAHT/YUAN
Mean	-0.0000836	-0.00013
Median	-0.000154	-0.0001
Maximum	0.012934	0.013127
Minimum	-0.013674	-0.022819
Std. Dev.	0.00289	0.0028
Skewness	0.022265	-0.512055
Kurtosis	4.939449	7.728092
Jarque-Bera	216.2414	1344.735
Probability	0.00***	0.00***

หมายเหตุ: ***, **, * หมายถึง มีนัยสำคัญทางสถิติ ณ ระดับนัยสำคัญ 0.01 , 0.05 และ 0.1 ตามลำดับ

ที่มา: จากการคำนวณโดยโปรแกรมคอมพิวเตอร์

ส่วนต่อมาคือการทดสอบ Heteroskedasticity โดยใช้ตัวทดสอบ ARCH-LM test และการทดสอบความนิ่ง (Stationarity) ของตัวแปร ด้วย Augmented Dickey Fuller Test (ADF) ได้ผลสรุปดังตารางที่ 2 ซึ่ง Augmented Dickey Fuller Test (ADF) นั้นมีสมมติฐานว่างว่าตัวแปรมีความนิ่ง (Non-Stationary) จากค่าสถิติทดสอบ เราสามารถปฏิเสธสมมติฐานว่างที่ระดับนัยสำคัญ 0.01 กล่าวคือตัวแปรทั้งสองตัวมีความนิ่งอย่างมีนัยสำคัญ สำหรับการทดสอบ ARCH Effects โดยใช้ ARCH-LM Test ซึ่งมีสมมติฐานว่างคือค่าคลาดเคลื่อนไม่มี ARCH Effects ได้ถูกปฏิเสธที่ระดับนัยสำคัญที่ 0.01 เช่นกัน แสดงว่า ตัวแปรอัตราแลกเปลี่ยนทั้งคู่นั้นต่างมีความเหมาะสมที่จะใช้ตัวแบบ GARCH ในการวิเคราะห์ความผันผวนตามจุดมุ่งหมายหมายของงานวิจัยนี้

ตารางที่ 2: ค่าสถิติจากการทดสอบ Augmented Dickey Fuller test (ADF) และ ARCH-LM test

	ADF		ARCH effects
	coefficient	t-ratio	LM
BAHT/USD	-0.913014	-33.99773***	20.62615***
BAHT/YUAN	-0.848878	-31.89653***	9.741214***

หมายเหตุ: ***, **, * หมายถึง มีนัยสำคัญทางสถิติ ณ ระดับนัยสำคัญ 0.01 , 0.05 และ 0.1 ตามลำดับ

ที่มา: จากการคำนวณโดยโปรแกรมคอมพิวเตอร์

วิจารณ์ผลจากตัวแบบที่ใช้ในการวิเคราะห์ข้อมูลความผันผวน GARCH (1,1)

ผลจากตัวแบบ GARCH (1,1) และค่าสถิติที่เกี่ยวข้องได้สรุปตามตารางที่ 3 โดยเราจะวิจารณ์สมการความผันผวนแบบมีเงื่อนไขเป็นหลัก ซึ่งจะพบว่าสัมประสิทธิ์หลักของตัวแบบ GARCH (1,1) ในนั้นมีนัยสำคัญทางสถิติในระดับ 0.01 ทุก ๆ ตัว สำหรับการพิจารณาความถูกต้องของตัวแบบนั้น ค่า $\gamma, \vartheta, \theta \geq 0$ เพื่อไม่ให้ค่าความผันผวนแบบมีเงื่อนไข (h_t) ติดลบ และค่าสัมประสิทธิ์ $\gamma, \vartheta, \theta$ ของเงินบาทต่อทั้งสองสกุลต่างก็สอดคล้องกับเงื่อนไขข้างต้น ในส่วนที่ข้อกำหนดที่ว่า $0 \leq \vartheta + \theta < 1$ เพื่อที่ค่าของ h_t จะมีเสถียรภาพ (Stability) นั้น เราจะเห็นว่าค่าสัมประสิทธิ์ ϑ, θ ของเงินบาทต่อเงินตราทั้งสองสกุลหลักก็สอดคล้องกับเงื่อนไขดังกล่าวเช่นเดียวกัน ซึ่งค่า ϑ จะแสดงถึงผลกระทบของข่าวสารใหม่ (Recent News : ARCH Effects) ส่วน θ จะแสดงถึงผลจากข่าวที่เกิดขึ้นแล้ว (Old News : GARCH Effects) ส่วนค่าของ $\vartheta + \theta$ จะแสดงถึงว่าผลของ Shock ที่เกิดขึ้นจะแสดงถึงเวลานานเพียงใดกว่าที่ผลจะจางหายไป โดยยิ่งค่า $\vartheta + \theta$ ยิ่งสูงเข้าใกล้ 1 มากเท่าไร จะยิ่งต้องใช้เวลานานกว่าที่ผลจาก Shock จางไป (Long Memory) ซึ่งทั้งสองตัวแบบมีค่า 0.8 โดยประมาณ

ส่วนประเด็นหลักในงานศึกษาชิ้นนี้ คือ ผลของบิตคอยน์และอีเธอร์เรียมที่มีต่อความผันผวนของอัตราแลกเปลี่ยน บาท/ดอลลาร์สหรัฐ และ บาท/หยวนของจีน จะพิจารณาผ่านสัมประสิทธิ์ของตัวแปร BTC และ ETH ตามลำดับ โดยสรุปแล้ว เงินสกุลบิตคอยน์มีผลต่อความผันผวน บาท/ดอลลาร์สหรัฐ และ บาท/หยวนอย่างมีระดับนัยสำคัญทางสถิติที่ระดับ 0.01 และความสัมพันธ์เป็นลบ ในขณะที่ไม่พบว่า เงินสกุลอีเธอร์เรียมมีผลต่อความผันผวนของเงินบาทต่อดอลลาร์สหรัฐและหยวน อย่างมีนัยสำคัญ ซึ่งอาจไม่น่าแปลกใจมากนัก เพราะ Market Capitalization ของทั้งตลาดสกุลเงินดิจิทัลนั้น บิตคอยน์คิดเป็นประมาณ 70 เปอร์เซ็นต์ ส่วนอันดับสองคือ อีเธอร์เรียมคิดเป็นประมาณ 12 เปอร์เซ็นต์ และเงินสกุลเงินดิจิทัลที่เหลืออีกพัน ๆ สกุลเงินคิดเป็นประมาณ 18 เปอร์เซ็นต์ (Coinmarketcap, 2021) ข้อมูลดังกล่าวชี้ว่า สกุลเงินดิจิทัลอันดับหนึ่งและอันดับสองนั้นมีความแตกต่างกันอย่างมาก และการที่สกุลเงินดิจิทัลในขณะนี้มียานานนับพัน ๆ สกุลเงิน เนื่องจากคนทั่ว ๆ ไปที่มีความรู้ทางด้านคอมพิวเตอร์มากพอ ก็จะสามารถสร้างสกุลเงินดิจิทัลใหม่ ๆ ได้ โดยอาศัยการเขียนโค้ดคำสั่งและเครือข่ายคอมพิวเตอร์เท่านั้น เนื่องจากโค้ดการสร้างสกุลเงินดิจิทัลเป็นที่เปิดเผยสำหรับสาธารณะ (Open Source)

ตารางที่ 3: ผลจากการวิเคราะห์และค่าสถิติจากตัวแบบ GARCH(1,1) โดยมีตัวแปรบิตคอยน์และอีเธอร์เรียม

	BAHT/USD	BAHT/YUAN
Conditional Mean Equation		
μ	-0.0000856 (0.0000755)	-0.000166** (0.0000701)
Conditional Variance Equation		
γ	0.00000135*** (0.000000273)	0.00000112*** (0.00000018)
ϑ	0.139709*** (0.026253)	0.095748*** (0.015012)
θ	0.678745*** (0.051629)	0.746113*** (0.030366)
$\vartheta+\theta$	0.818454	0.841861
BTC	-0.00000984*** (0.00000299)	-0.0000079*** (0.0000022)
ETH	0.000002 (0.00000193)	0.00000114 (0.00000132)
Gold Price	0.000061*** (0.0000176)	0.0000981*** (0.0000164)
COVID-19	0.00000102*** (0.000000253)	0.00000026* (0.000000156)
Llik	6166.291	6223.392
AIC	-8.931532	-9.014346
SIC	-8.901196	-8.984011
HQC	-8.920183	-9.002998

หมายเหตุ: ***, **, * หมายถึง มีนัยสำคัญทางสถิติ ณ ระดับนัยสำคัญ 0.01 , 0.05 และ 0.1 ตามลำดับ

ที่มา: จากการคำนวณโดยโปรแกรมคอมพิวเตอร์

สรุป

ผลจากการศึกษาเรื่อง “ผลกระทบของสกุลเงินดิจิทัลต่อความผันผวนของอัตราแลกเปลี่ยนเงินบาทไทยและเงินตราสกุลหลัก” สามารถสรุปผลการวิจัยได้ดังนี้

ประการแรก ผลการศึกษาชี้ว่าบิตคอยน์มีผลต่อความผันผวนของอัตราแลกเปลี่ยนบาทต่อเงินตราสองสกุลหลักในทิศทางเดียวกันอย่างมีนัยสำคัญทางสถิติ ส่วนอีเธอร์เรียมก็มีทิศทางความสัมพันธ์ต่อความผันผวนของอัตราแลกเปลี่ยนบาทต่อเงินตราสองสกุลหลักในทิศทางที่เหมือนกัน แต่อย่างไรก็ดี ความสัมพันธ์ดังกล่าวมีระดับนัยสำคัญทางสถิติที่ไม่สูงมากพอที่จะสรุปว่าอีเธอร์เรียมมีผลต่อความผันผวนของอัตราแลกเปลี่ยนเงินบาทไทยอย่างชัดเจน แต่ในทัศนะของผู้วิจัยคาดว่า ในอนาคตอาจมีความเป็นไปได้ที่อีเธอร์เรียมจะมีอิทธิพลต่อความผันผวนของเงินบาทอย่างมีนัยสำคัญทางสถิติได้เนื่องจากความนิยมที่เพิ่มขึ้นของอีเธอร์เรียมเมื่อเทียบกับเงินตราสกุลดิจิทัลอื่น ๆ

ประการสุดท้ายคือสำหรับผู้ที่มีกิจกรรมที่เกี่ยวข้องกับธุรกรรมที่ต้องแลกเปลี่ยนเงินตราระหว่างประเทศ ไม่ว่าจะเป็นเงินบาทต่อดอลลาร์สหรัฐ หรือ เงินบาทต่อเงินหยวน มีแนวโน้มจะพบว่า ความเสี่ยงต่ออัตราแลกเปลี่ยนของเงินสกุลบาทนั้นลดน้อยลงภายใต้เงื่อนไขว่าอัตราแลกเปลี่ยนของบิตคอยน์ยังคงมีแนวโน้มการปรับตัวสูงขึ้นต่อไป

ข้อเสนอแนะ

เนื่องจากสกุลเงินบิตคอยน์นั้นมีอุปทานจำกัด ในขณะนี้บิตคอยน์ได้ถูกขุดขึ้นมาแล้วประมาณ 89 เปอร์เซ็นต์จากจำนวนทั้งหมดที่กำหนดไว้ในโค้ดคอมพิวเตอร์ แสดงว่ามีเพียง 11 เปอร์เซ็นต์ ที่เหลือให้มีการขุดได้ (Buybitcoinworldwide, 2021) ซึ่งถ้าบิตคอยน์ถูกขุดขึ้นมาจนหมดจะเกิดอะไรขึ้นได้บ้างคงเป็นคำถามที่เต็มไปด้วยความน่าเป็นของคำตอบที่หลากหลาย แต่อย่างไรก็ตาม ผู้วิจัยคาดการณ์ว่าถ้าเหตุการณ์ดังกล่าวเกิดขึ้น มูลค่าของบิตคอยน์อาจยิ่งพุ่งสูงขึ้นอย่างมากเนื่องจากอุปสงค์ที่เพิ่มขึ้นแต่อุปทานคงที่ หรือไม่ก็อาจปรับตัวลงอย่างรุนแรง ถ้ามีการแก้ไขโค้ดคอมพิวเตอร์เพื่อขยายอุปทานของบิตคอยน์ออกไปอีกอันอาจจะทำให้ผู้ถือครองบิตคอยน์เกิดความไม่มั่นใจได้ และไม่ว่าเหตุการณ์จะออกมาทิศทางใด ความผันผวนของอัตราแลกเปลี่ยนสกุลเงินบาทก็น่าจะได้รับผลกระทบไม่มากนักน้อย ดังนั้น ผู้ที่เกี่ยวข้องกับการแลกเปลี่ยนเงินบาท หรือสกุลเงินดิจิทัลก็พึงตระหนักกับสิ่งที่อาจจะเกิดขึ้นในตลาดอัตราแลกเปลี่ยนด้วย

เอกสารอ้างอิง

กระทรวงพาณิชย์. (2564). *มูลค่าการนำเข้าส่งออก*. สืบค้นเมื่อ 30 มีนาคม 2564, จาก <https://www.moc.go.th/>

- จริยภรณ์ ไช้สิงห์ทอง และธงชัย อินตรา. (2561). การประยุกต์ใช้แบบจำลองไบวาร์รีเอทการ์ช ในการศึกษาความสัมพันธ์ของความผันผวนระหว่างอัตราแลกเปลี่ยนกับดัชนีหลักทรัพย์กลุ่มพลังงาน และกลุ่มธนาคารในตลาดหลักทรัพย์แห่งประเทศไทย. ปรินญาเศรษฐศาสตร์บัณฑิต, มหาวิทยาลัยนเรศวร.
- โสภิน ถนนมเพ็ชรสง่า และวรรณรพี บานชื่นวิจิตร. (2561). ปัจจัยที่มีผลต่อราคาสกุลเงินดิจิทัล (Cryptocurrencies). สืบค้นเมื่อ 27 มีนาคม 2564, จาก [http://utccmbaonline.com/ijbr/doc/\(Edit\)Id896-13-12-2018_16:01:56.pdf](http://utccmbaonline.com/ijbr/doc/(Edit)Id896-13-12-2018_16:01:56.pdf)
- สุภาณี หาญพัฒน์นุสรณ์. (2019). การวิเคราะห์ความสัมพันธ์และความผันผวนระหว่างตลาดแลกเปลี่ยนเงินตราต่างประเทศและตลาดหลักทรัพย์ของไทยและประเทศกลุ่มอาเซียนที่ทำการศึกษา. *Kasetsart Journal of Social Sciences*, 40, 262–269.
- พงศกร พัวพัฒน์กุล. (2560). การวิเคราะห์ปัจจัยที่ส่งผลกระทบต่อความผันผวนของราคา Bitcoin. การค้นคว้าอิสระวิทยาศาสตร์มหาบัณฑิต, มหาวิทยาลัยกรุงเทพ.
- พัชรพลชัย เขียวทอง และสุมาลี รามัญญ. (2563). กรณีศึกษาราคา Bitcoin ที่มีผลกระทบต่อคำนวณการเสียภาษีโดยใช้แบบจำลอง ARIMA ของนักลงทุนเงินสกุลดิจิทัลในประเทศไทย. *วารสารวิจัยมหาวิทยาลัยเวสเทิร์น มนุษยศาสตร์และสังคมศาสตร์*, 6(1), 103-111.
- Bollerslev, T. (1986). Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics*, 31(3), 307-327.
- Buybitcoinworldwide. (2021). *How Many Bitcoins Are There?*. Retrieved April 9, 2021, from <https://www.buybitcoinworldwide.com/how-many-bitcoins-are-there/>
- Carrick, J. (2016). Bitcoin as a Complement to Emerging Market Currencies. *Emerging Markets Finance and Trade*, 52(10), 2321-2334.
- Coinmarketcap. (2021). *Percentage of Total Market Capitalization (Dominance)*. Retrieved April 10, 2021, from <https://coinmarketcap.com/>
- Corelli, A. (2018). Cryptocurrencies and Exchange Rates: A Relationship and Causality Analysis. *Risks*, 6(4), 1-11.
- Engle, R. F. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*, 50(4), 987-1007.
- Erdas, M. L., & Caglar, A. E. (2018). Analysis of the Relationships between Bitcoin and Exchange Rate, Commodities and Global Indexes by Asymmetric Causality Test. *Eastern Journal of European Studies*, 9, 27-45.
- Frankenfeld, J. (2021). What is Bitcoin?. Retrieved April 3, 2021, from <https://www.investopedia.com/terms/b/bitcoin.asp>



- Graveland, N. (2018). *Bitcoin, Gold and the Chinese Yuan A Comparison of Volatility and Correlations*. Master of Science in Finance, Tilburg University.
- Katsiampa, P. (2017). Volatility Estimation for Bitcoin: A Comparison of GARCH Models. *Economics Letters*, 158, 3-6.
- Morina, F., Hysa, E., Ergün, U., Panait, M., & Voica, M. C. (2020). The Effect of Exchange Rate Volatility on Economic Growth: Case of the CEE Countries. *Journal of Risk and Financial Management*, 13(8), 1-13.

ผลจากมาตรการกระตุ้นเศรษฐกิจอันเนื่องมาจากการแพร่ระบาดของ COVID-19 ที่มีต่อความผันผวนของตลาดหลักทรัพย์แห่งประเทศไทยและดัชนีของบางอุตสาหกรรม: กรณีศึกษา มาตรการ คนละครึ่ง ซ้อปดีมีคืน และบัตรสวัสดิการแห่งรัฐ

THE EFFECT OF THE ECONOMIC STIMULUS MEASURES DUE TO COVID-19 OUTBREAK ON THE VOLATILITY OF THE STOCK EXCHANGE OF THAILAND AND SOME SECTORAL INDICES: A CASE STUDY OF HALF-HALF CO-PAYMENT, SHOP DEE MEE KUEN, AND STATE WELFARE CARD MEASURES

สรวัฒน์ วิศาลภรณ์

Sorawat Wisalaporn

คณะเศรษฐศาสตร์ มหาวิทยาลัยเกษตรศาสตร์

Faculty of Economics, Kasetsart University

*Corresponding author, E-mail: sorawat.w@ku.th

บทคัดย่อ

งานศึกษาชิ้นนี้จัดทำขึ้นเพื่อศึกษาผลกระทบจากมาตรการกระตุ้นเศรษฐกิจสามมาตรการที่ดำเนินการในช่วงปลายปี พ.ศ. 2563 อันเนื่องจากการแพร่ระบาดของ COVID-19 อันได้แก่มาตรการ คนละครึ่ง ซ้อปดีมีคืน และบัตรสวัสดิการแห่งรัฐ ที่มีต่อความผันผวนของตลาดหลักทรัพย์แห่งประเทศไทยโดยรวม และดัชนีของบางอุตสาหกรรมที่น่าสนใจ โดยใช้แบบจำลอง GARCH (Generalized Autoregressive Conditional Heteroskedasticity)

ผลการศึกษาสรุปได้ว่า มาตรการกระตุ้นเศรษฐกิจข้างต้นทำให้ความผันผวนของตลาดหลักทรัพย์แห่งประเทศไทยและดัชนีของบางอุตสาหกรรมเพิ่มขึ้นอย่างมีนัยสำคัญทางสถิติ แสดงว่าผลของมาตรการไม่เพียงแต่จะมีผลทางตรงในการกระตุ้นการใช้จ่ายของประชาชนกลุ่มเป้าหมายในระบบเศรษฐกิจเท่านั้น แต่ยังมีความเสี่ยงในการลงทุนในตลาดหลักทรัพย์ในภาพรวมตลอดจนดัชนีของบางอุตสาหกรรมเพิ่มขึ้นด้วยในอีกทางหนึ่ง

คำสำคัญ: การศึกษาความผันผวน ตลาดหลักทรัพย์แห่งประเทศไทย มาตรการ GARCH

ABSTRACT

This research was aimed to study the impact of the three economic stimulus measures, implemented in the fourth quarter of 2020, due to the COVID-19 outbreak (Half-half

co-payment, Shop Dee Mee Kuen, and the state welfare card measures) on the volatility of the stock exchange of Thailand as a whole and four interesting sectoral indices by utilizing GARCH model (Generalized autoregressive conditional heteroskedasticity).

The results of the study indicated that these stimulus economic measures significantly increased the volatility of the stock exchange of Thailand and the four sectoral indices. It implied that the effect of the measures not only has a direct effect on stimulating the expenditure of the target agents in the economy, but also has an effect on the investment risk in the Thai stock market in the overall.

Keywords: GARCH, Measures, The Stock Exchange of Thailand, Volatility Study

บทนำ

ตั้งแต่มีการแพร่ระบาดของ COVID-19 ที่มีการรายงานอย่างเป็นทางการในปลายปี พ.ศ. 2562 เศรษฐกิจไทยและเศรษฐกิจโลกต่างเผชิญภาวะหดตัวจนมาถึงปัจจุบัน รัฐบาลในแต่ละประเทศต่างมีการดำเนินมาตรการเพื่อรับมือกับการแพร่ระบาดของโรคดังกล่าวใน 3 ด้านหลัก ๆ อันได้แก่ มาตรการทางสาธารณสุข มาตรการทางสังคม และมาตรการทางเศรษฐกิจ สำหรับประเทศไทยมาตรการของรัฐบาลภายใต้การนำของ พลเอกประยุทธ์ จันทร์โอชา นั้นมีหลาย ๆ มาตรการ แต่มาตรการที่โดดเด่นของรัฐบาลที่ควรกล่าวถึง ก็คือ มาตรการกระตุ้นเศรษฐกิจในช่วงปลายปี พ.ศ. 2563 อันได้แก่ คนละครึ่ง ช้อปดีมีคืน และบัตรสวัสดิการแห่งรัฐ มีการประมาณการว่าจะครอบคลุมกลุ่มเป้าหมาย 28 ล้านคน โดยกลุ่มเข้าร่วมในแต่ละมาตรการจะไม่ใช่ซ้อนกันเนื่องจากประชาชน 1 คน จะสามารถเข้าร่วมในมาตรการใด ๆ ได้เพียงมาตรการเดียวเท่านั้น (สำนักงานเศรษฐกิจการคลัง, 2563) โดยทั้งสามมาตรการมีภาพรวมดังนี้

มาตรการช้อปดีมีคืนจะเน้นประชาชนที่อยู่ในฐานภาษีและจะลดหย่อนภาษีในการยื่นแบบการเสียภาษีในปี พ.ศ.2564 สำหรับค่าซื้อสินค้าหรือบริการตามที่จ่ายจริงไม่เกิน 30,000 บาท สำหรับมาตรการบัตรสวัสดิการแห่งรัฐจะใช้ได้กับผู้ที่ถือบัตรสวัสดิการของรัฐ โดยรัฐบาลจะให้เงินในการซื้อสินค้าเพิ่มอีกคนละ 500 บาท ในช่วงระหว่างเดือนตุลาคมถึงธันวาคมของปี พ.ศ.2563 ส่วนมาตรการสุดท้าย คือ มาตรการคนละครึ่ง นั้นจะเน้นผู้ที่ไม่อยู่ใน 2 มาตรการแรกและมีอายุ 18 ปีขึ้นไป โดยรัฐบาลจะออกค่าใช้จ่ายสมทบให้ 50% แต่ไม่เกิน 150 บาทต่อคนต่อวัน สูงสุดไม่เกิน 3,000 บาทต่อคน ผ่านทางแอปพลิเคชัน “เป๋าตัง”

มาตรการข้างต้นมีจุดมุ่งหมายหลักในการกระตุ้นเศรษฐกิจผ่านทางการเพิ่มกำลังซื้อของประชาชน กลุ่มเป้าหมายโดยมีการประมาณการใช้จ่ายภายใต้โครงการ 192,000 ล้านบาท จากการประมาณการของ สศค.

อย่างไรก็ตาม ผู้วิจัยตั้งสมมติฐานว่ามีความเป็นไปได้ที่มาตรการข้างต้นไม่เพียงแต่จะมีผลในการกระตุ้นเศรษฐกิจตามการคาดการณ์ของรัฐบาลแต่เพียงอย่างเดียว อาจเป็นไปได้ที่ผลกระทบอีกประการหนึ่งจากมาตรการคือ ผลต่อความผันผวนของตลาดหลักทรัพย์ในประเทศเนื่องจากกิจกรรมทางเศรษฐกิจที่มี

แนวโน้มจะสูงขึ้นจากการใช้จ่ายของประชาชนไทยในช่วงดังกล่าวโดยเฉพาะอย่างยิ่งการใช้จ่ายของรัฐบาลในช่วงเศรษฐกิจหดตัวน่าจะส่งผลที่สูงในระดับหนึ่ง

การศึกษาจะพิจารณาดัชนีตลาดหลักทรัพย์ในภาพรวมและดัชนีของสี่อุตสาหกรรมที่น่าสนใจ อันได้แก่ อุตสาหกรรมอาหารและเครื่องดื่ม (Food and Beverage: SET.FOOD) อุตสาหกรรมท่องเที่ยวและสันทนาการ (Tourism & Leisure: SET.TOUR) อุตสาหกรรมธนาคาร(Bank: SET.BANK) และอุตสาหกรรมขนส่งและโลจิสติกส์ (Transportation & Logistics: SET.TRANS) ซึ่งการที่ผู้วิจัยเลือกศึกษาสี่อุตสาหกรรมสำคัญที่เกี่ยวข้องกับการดำเนินชีวิตประจำวันเหล่านี้ เนื่องจากภายใต้การแพร่ระบาดของ COVID-19 ทำให้ประชาชนจำเป็นต้องใช้วิถีการดำเนินชีวิตแบบ “นิว นอร์มอล” (New Normal) อันนำไปสู่ผลกระทบและการเปลี่ยนแปลงของหน่วยธุรกิจให้อุตสาหกรรมเหล่านี้หลาย ๆ มิติ อาทิ

- ผู้ประกอบกิจการธุรกิจร้านอาหารเผชิญกับภาวะหดตัว เนื่องจากผู้บริโภคหลีกเลี่ยงการรับประทานอาหารนอกบ้าน ในขณะที่ผู้ผลิตอาหารสำเร็จรูปและอาหารกระป๋องได้รับผลกระทบทางบวกจากการแพร่ระบาดของ COVID-19 ที่ทำให้ครัวเรือนมีการกักตุนอาหารเพิ่มขึ้น (ศูนย์วิจัยธนาคารออมสิน, 2563)
- สำหรับหน่วยธุรกิจในอุตสาหกรรมท่องเที่ยวและสันทนาการนั้นก็เผชิญภาวะที่นักท่องเที่ยวลดลงส่งผลให้มีการปรับรูปแบบการดำเนินธุรกิจที่เน้นการนำเทคโนโลยีสมัยใหม่มาใช้ รวมถึงการบริการที่ให้ความสำคัญด้านสุขภาพและอนามัยเพื่อความปลอดภัยและลดความวิตกกังวลในกลุ่มผู้ใช้บริการ (พุทธชาด ลุนคำ, 2564)
- ผู้ประกอบกิจการในอุตสาหกรรมขนส่งและโลจิสติกส์ มีทั้งที่ได้รับทั้งผลกระทบทางบวกและทางลบจากการเปลี่ยนรูปแบบการดำเนินชีวิตของประชาชน เช่น ธุรกิจที่เกี่ยวกับการขนส่งสินค้าอาหารและ โลจิสติกส์มีการขยายตัว (มติชนออนไลน์, 2563) ในขณะที่ธุรกิจขนส่งสาธารณะที่ถดถอยลงเนื่องจากการลดการเดินทางของบุคคลทั่วไปรวมถึงรูปแบบการทำงานที่บ้าน (Work from Home) ในช่วงที่มีการระบาดของ COVID-19 (ศูนย์วิจัยกสิกรไทย, 2563)
- สำหรับอุตสาหกรรมธนาคารในปี พ.ศ.2563 นั้น ผลการดำเนินการของธุรกิจธนาคารในภาพรวมนั้นแยกลงเมื่อเปรียบเทียบกับปีก่อนหน้า อันจะเห็นได้จากกำไรสุทธิและการปล่อยสินเชื่อที่ลดลง ตลอดจนแนวโน้มหนี้เสียที่เพิ่มขึ้น ซึ่งสะท้อนภาพด้านการเงินของหน่วยธุรกิจในระบบเศรษฐกิจไทยโดยรวมที่ถดถอยในช่วงการระบาดของ COVID-19 (ศูนย์วิจัยธนาคารออมสิน, 2563)

จากผลกระทบและการปรับตัวของหน่วยธุรกิจในสี่อุตสาหกรรมที่มีความแตกต่างกัน ทำให้ผู้วิจัยเกิดความสนใจว่ามาตรการกระตุ้นเศรษฐกิจผ่านทางการเพิ่มกำลังซื้อของประชาชนกลุ่มเป้าหมายของสามมาตรการที่เราสนใจศึกษานั้น จะส่งผลกระทบต่อความผันผวนของดัชนีสี่อุตสาหกรรมนี้ตลอดจนดัชนีตลาดหลักทรัพย์โดยรวมหรือไม่และเป็นไปในทิศทางใด

ข้อมูลดัชนีตลาดหลักทรัพย์ในภาพรวมและดัชนีสี่อุตสาหกรรมที่ใช้ในงานศึกษานี้จะมีการแปลงข้อมูล (Transform Data) ผ่านสูตร $\ln\left(\frac{g_t}{g_{t-1}}\right)$ เมื่อ g_t เป็นข้อมูลระดับ (Level) หลังจากที่มีการปรับข้อมูลแล้ว (Filter and Adjust) จึงใช้แบบจำลอง GARCH เพื่อดูผลกระทบของมาตรการที่เราสนใจกับความผันผวนของตลาดหลักทรัพย์และดัชนีอุตสาหกรรมย่อยต่อไป

ทบทวนวรรณกรรม

งานวิจัยนี้ ผู้ศึกษาได้ตรวจสอบเอกสารและงานวิจัยที่เป็นพื้นฐานความรู้ในการวิจัยโดยแบ่งเป็นประเด็นต่างๆ ดังต่อไปนี้

การศึกษาปัจจัยที่มีผลต่อดัชนีตลาดหลักทรัพย์

ตรีเพชร พุทธแดง (2559) ศึกษาผลกระทบของนโยบายการเงินและนโยบายการคลังต่อดัชนีราคาหลักทรัพย์ใน 5 ประเทศ ได้แก่ ไทย มาเลเซีย อินโดนีเซีย ฟิลิปปินส์และสิงคโปร์ โดยใช้แบบจำลอง Vector Autoregressive (VAR) โดยมีตัวแปรเป็นดัชนีตลาดหลักทรัพย์ใน 5 ประเทศข้างต้น ส่วนตัวแปรทางนโยบายการเงินและนโยบายคลังเป็นตัวแปรต้น (Independent Variables) ใช้ข้อมูลรายไตรมาส ระหว่าง ค.ศ. 2000 ถึง 2015 การศึกษาชี้ว่านโยบายการเงินเป็นตัวแปรที่อธิบายการเปลี่ยนแปลงดัชนีราคาหลักทรัพย์ทุก ๆ ประเทศอย่างมีนัยสำคัญ ในขณะที่นโยบายการคลังไม่สามารถอธิบายดัชนีตลาดหลักทรัพย์ได้อย่างมีนัยสำคัญ แต่ยังคงมีอิทธิพลต่อภาคเศรษฐกิจของแต่ละประเทศนอกจากนี้ดัชนีราคาหลักทรัพย์ในอดีตจะส่งผลกระทบต่อดัชนีราคาหลักทรัพย์ในปัจจุบันด้วยอีกทางหนึ่ง

ศรัญพร คงแก้ว (2548) ได้ศึกษาผลกระทบของนโยบายการเงินที่มีผลต่อดัชนีราคาหลักทรัพย์ โดยสมการถดถอยเชิงพหุ (Multiple Regression) โดยใช้ตัวแปรหุ่นแทนช่วงเวลาก่อนและหลังการดำเนินนโยบายภายใต้เป้าหมายกรอบปริมาณเงินและกรอบอัตราเงินเฟ้อ ผลการวิจัยชี้ให้เห็นว่า นโยบายการเงินภายใต้เป้าหมายกรอบเงินเฟ้อจะมีความสามารถในการอธิบายดัชนีตลาดหลักทรัพย์ได้ดีกว่าการดำเนินนโยบายการเงินภายใต้เป้าหมายกรอบปริมาณเงิน

การศึกษาปัจจัยที่มีผลต่อความผันผวนของดัชนีตลาดหลักทรัพย์

Baker et al. (2019) ผู้วิจัยได้สร้างดัชนีความผันผวนของตลาดหุ้น (An Equity Market Volatility Index: EMV) จากหนังสือพิมพ์ 11 หนังสือพิมพ์หลัก ๆ ของสหรัฐอเมริกา ผลวิจัยชี้ว่า ความถี่ของคำในหนังสือพิมพ์มีผลต่อความผันผวนของตลาดหลักทรัพย์ สำหรับเชิงนโยบายผู้วิจัยพบว่า ข่าวทางด้านนโยบายการค้า (Trade Policy News) ได้ทวีความสำคัญมากขึ้นต่อความผันผวนของตลาดหุ้นหลังจากที่นายดอนัลด์ ทรัมป์ (Mr. Donald Trump) ได้รับเลือกตั้งเป็นประธานาธิบดีของสหรัฐอเมริกาในปี ค.ศ. 2016

Zare et al. (2013) ได้ศึกษาความผันผวนของตลาดหลักทรัพย์ใน 5 ประเทศ ได้แก่ มาเลเซีย อินโดนีเซีย สิงคโปร์ ฟิลิปปินส์ และไทย โดยใช้ตัวแบบหลัก ๆ คือ ตัวแบบสลับของมาร์คอฟแบบ 2 ช่วง (A Two-State Markov-Switching Model) การศึกษาแบบนอนพาราเมตริก (The Non-Parametric Approach) และ Pooled Mean Gro Estimation Model (PMG) งานวิจัยนี้ชี้ว่านโยบายการเงินแบบหดตัว (Contractionary Monetary Policy) โดยใช้อัตราดอกเบี้ยเป็นเครื่องมือจะมีผลกระทบในระยะยาว (Long-Run Effect) ต่อความผันผวนของตลาดหลักทรัพย์ในช่วงของตลาดหุ้นแบบหมี (Bear Market) มากกว่าตลาดหุ้นในแบบกระทิง (Bull Market)

Thakolsri et al. (2015) ได้ศึกษาความผันผวนตลาดหลักทรัพย์ไทยในด้านความไม่สมมาตรของข่าวสารข้อมูล (Asymmetric Quality of Information) และผลจากการศึกษาได้ชี้ว่าข่าวร้ายจะมีผลต่อความผันผวนตลาดหลักทรัพย์มากกว่าข่าวดี

เท่าที่มีการตรวจสอบเอกสารและจากความรู้ที่ผู้วิจัยมีในปัจจุบัน ผู้วิจัยไม่พบการประเมินผลกระทบของมาตรการในช่วง COVID-19 เลย แต่มักจะพบงานที่เกี่ยวข้องกับผลกระทบของ COVID-19 กับความผันผวนของตลาดหลักทรัพย์อยู่บ้างดังนี้

Yousef (2020) ศึกษาผลของ COVID -19 กับตลาดหุ้นของประเทศ G7 (แคนาดา ฝรั่งเศส เยอรมนี อิตาลี ญี่ปุ่น สหราชอาณาจักร และสหรัฐอเมริกา) โดยตัวแบบ GARCH และ GJR-GARCH เขาพบว่าความผันผวนของตลาดหลักทรัพย์ของกลุ่มประเทศข้างต้นสูงขึ้นเนื่องจาก COVID-19 ในขณะที่ Panyagometh (2020) ศึกษาผลของ COVID-19 ต่อความผันผวนของตลาดหลักทรัพย์ไทยโดยใช้ข้อมูลรายบริษัทใน SET50 ในการศึกษา ผลการศึกษาสรุปว่า ความผันผวนตลาดหลักทรัพย์ไทยรายบริษัทเพิ่มมากขึ้นจากการระบาดของ COVID-19 ซึ่งไปในทิศทางเดียวกับการศึกษาของ Yousef

วัตถุประสงค์ของการวิจัย

เพื่อศึกษาผลกระทบของมาตรการกระตุ้นเศรษฐกิจ সামာตรการในช่วงการระบาดของ COVID-19 โดยจะศึกษาผลจากสามมาตรการ ได้แก่ คนละครึ่ง ซ้อปดีมีคืน และ บัตรสวัสดิการแห่งรัฐ ที่มีต่อความผันผวนของตลาดหลักทรัพย์แห่งประเทศไทยในภาพรวมและ 4 ดัชนีอุตสาหกรรมย่อยที่น่าสนใจ

วิธีดำเนินการวิจัย

การเก็บรวบรวมข้อมูล

งานวิจัยนี้ใช้การเก็บข้อมูลทุติยภูมิ (Secondary Data) จาก 3 แหล่งหลัก ๆ คือ ฐานข้อมูลของ Bisnews ตลาดหลักทรัพย์แห่งประเทศไทย และ กระทรวงสาธารณสุข ข้อมูลทั้งหมดเป็นข้อมูลรายวัน เริ่มจาก ต้นปี พ.ศ. 2558 ถึงต้นปี พ.ศ. 2564 ซึ่งจะไม่รวมวันที่ตลาดไม่มีการซื้อขายเช่นวันหยุดปลายสัปดาห์ และวันหยุดพิเศษต่าง ๆ โดยข้อมูลที่ใช้เป็นตัวแปรในระบบได้แก่ ดัชนีตลาดหลักทรัพย์โดยรวม (SET) ตลอดจนถึงดัชนีในอุตสาหกรรมย่อย ประกอบด้วย อุตสาหกรรมอาหารและเครื่องดื่ม (SET.FOOD) อุตสาหกรรมท่องเที่ยวและสันทนาการ (SET.TOUR) อุตสาหกรรมธนาคาร (SET.BANK) และอุตสาหกรรมขนส่งและโลจิสติกส์ (SET.TRANS) ส่วนตัวแปรอธิบาย คือ ตัวแปรแทนสามมาตรการรัฐซึ่งจะใช้ตัวแปรหุ่น (Dummy Variables) แทนช่วงที่มีการดำเนินมาตรการ ในส่วนสุดท้ายคือ กลุ่มตัวแปรควบคุมในระบบ ได้แก่ ราคาทองคำในประเทศ (ราคาซื้อ) อัตราแลกเปลี่ยน (บาท/ดอลลาร์สหรัฐ) และตัวแปรหุ่นแทนช่วงเกิดการแพร่ระบาดของ COVID-19

การวิเคราะห์ข้อมูล

การวิเคราะห์ข้อมูลจะแบ่งเป็น 3 ขั้นตอน ได้แก่

ขั้นตอนแรก การตรวจสอบความถูกต้องและทำความสะอาดข้อมูล (Inspect and Clean Data) จะเริ่มจากการปรับข้อมูล (Filter and Adjust) เป็นการตรวจสอบและแก้ไขถ้ามีความผิดปกติเกิดขึ้นกับข้อมูล หลังจากนั้นจึงจะทำการแปลงรูปข้อมูลทุก ๆ ตัว โดยใช้สูตร $\ln\left(\frac{g_t}{g_{t-1}}\right)$ เมื่อ g_t เป็นข้อมูลระดับ (Level) เว้นแต่ ตัวแปรที่เป็นตัวแทนการดำเนินนโยบาย และตัวแทนการแพร่ระบาดของ COVID-19

ขั้นตอนที่สอง การวิเคราะห์ข้อมูลเบื้องต้น จะเป็นการตรวจสอบค่าสถิติพื้นฐานโดยทั่ว ๆ ไป พร้อมพิจารณารูปแบบการแจกแจงของตัวแปร รวมถึงทดสอบสมมติฐานเบื้องต้นว่าตัวแปรตามในระบบมีความเหมาะสมที่จะใช้ในตัวแบบ GARCH หรือไม่โดยใช้

- ค่า Kurtosis และ การทดสอบ Jarque-Bera Test เพื่อตรวจสอบการแจกแจงของตัวแปร
- Augmented Dickey and Fuller Test (ADF) เพื่อการตรวจสอบความนิ่งของข้อมูล (Stationary)
- ARCH LM Test จะเป็นทดสอบว่าค่าคลาดเคลื่อน (Error Term) ว่ามีผลของ ARCH Effect หรือไม่ ซึ่งถ้าข้อมูลไม่มี ARCH Effect แล้ว จะใช้ตัวแบบ GARCH มาวิเคราะห์ไม่ได้

ขั้นตอนที่สาม การวิเคราะห์โดยตัวแบบ GARCH และตรวจสอบค่าสัมประสิทธิ์ที่ประมาณค่าได้ว่าตรงตามข้อกำหนดของตัวแบบ GARCH ในการประมาณค่าสัมประสิทธิ์หรือไม่ ซึ่งโดยหลัก ๆ แล้วตัวแบบจะต้องมีเสถียรภาพ (Stability) กล่าวคือ ค่าของตัวแปรจะไม่วิ่งเข้าหาค่าบวกหรือลบอนันต์ (Positive or Negative Infinity) อย่างไม่มีที่สิ้นสุดในระยะยาว และค่าความแปรปรวนแบบมีเงื่อนไข (Conditional Variance) จะต้องมากกว่าหรือเท่ากับศูนย์

ตัวแบบที่ใช้ในการวิเคราะห์ข้อมูล GARCH (1,1)

Hill et al. (2011) ได้อธิบายว่า ตัวแบบ GARCH ได้พัฒนาจากตัวแบบ ARCH (Autoregressive Conditional Heteroskedasticity) โดย Bollerslev (1986) เสนอตัวแบบ GARCH ที่มีข้อเด่นเหนือกว่าตัวแบบ ARCH ในหลาย ๆ ประการ โดยอาศัยแนวคิดตัวแบบของ Bollerslev งานวิจัยนี้ได้ประยุกต์ใช้ตัวแบบ GARCH (1,1) ซึ่งจะแบ่งเป็นสองส่วน ส่วนแรกคือ สมการค่าคาดหวังแบบมีเงื่อนไข (Conditional Mean Equation) และส่วนที่สอง คือ สมการความผันผวนแบบมีเงื่อนไข (Conditional Variance Equation) ดังต่อไปนี้

สมการค่าคาดหวังแบบมีเงื่อนไข (Conditional Mean Equation)

$$p_t = \mu + \varepsilon_t$$

สมการความผันผวนแบบมีเงื่อนไข (Conditional Variance Equation)

$$h_t = \omega + \alpha \varepsilon_{t-1}^2 + \beta h_{t-1} + \tau_1 Measures_t + \sum_{i=2}^4 \tau_i Control_{it}$$

โดยกำหนดให้

p_t	คือ	ค่าคาดหวังแบบมีเงื่อนไข เมื่อเวลา t (เวลาเป็นรายวัน) ในที่นี้คือ ค่าดัชนีตลาดหลักทรัพย์ และดัชนีอุตสาหกรรมที่น่าสนใจ 4 อุตสาหกรรมที่แปลงรูปจากขั้นตอนแรกของการวิเคราะห์ข้อมูลแล้ว ซึ่งในการศึกษานี้จะมีทั้งสิ้น 5 ชุดสมการ
h_t	คือ	ความผันผวนแบบมีเงื่อนไขของตัวแปรที่เราสนใจ เมื่อเวลา t
μ และ ω	คือ	ค่าคงที่ในสมการค่าคาดหวังแบบมีเงื่อนไข และสมการความผันผวนแบบมีเงื่อนไข ตามลำดับ โดยเงื่อนไขของตัวแบบ GARCH กำหนดให้ $\omega \geq 0$ เพื่อให้ค่าความผันผวนแบบมีเงื่อนไขมีค่ามากกว่าหรือเท่ากับศูนย์
ε_t	คือ	ค่าคลาดเคลื่อนของสมการค่าคาดหวังแบบมีเงื่อนไข เมื่อเวลา t
$Measures_t$	คือ	ตัวแปรหุ่นแสดงช่วงเวลาตั้งแต่วันเริ่มต้นจนถึงวันสุดท้ายที่มีการดำเนินการ (คนละครั้ง ข้อปติมีคีน และบัตรสวัสดิการแห่งรัฐ)
$Control_{it}$	คือ	ตัวแปรควบคุมที่ i ($i = 2, 3, 4$) ซึ่งในที่นี้จะได้แก่ ราคาทองคำรายวันในประเทศ (ราคาซื้อ) อัตราแลกเปลี่ยนของสกุลเงินบาทต่อเงินดอลลาร์สหรัฐที่ปรับข้อมูลแล้ว และตัวแปรหุ่นแทนการแพร่ระบาดของ COVID-19
α	คือ	ค่าสัมประสิทธิ์ของ ARCH Term (ε_{t-1}^2) ของสมการความผันผวนแบบมีเงื่อนไข
β	คือ	ค่าสัมประสิทธิ์ของ GARCH Term (h_{t-1}) ของสมการความผันผวนแบบมีเงื่อนไข โดยกำหนดให้ $\omega, \alpha, \beta \geq 0$ เพื่อไม่ให้ค่าความผันผวนติดลบ และ $0 \leq \alpha + \beta < 1$ เพื่อความมีเสถียรภาพของตัวแบบ
τ_1	คือ	ค่าสัมประสิทธิ์ของตัวแปรหุ่นแสดงช่วงเวลาที่มีการดำเนินการที่เราสนใจในสมการความผันผวนแบบมีเงื่อนไข
$\tau_2 \tau_3 \tau_4$	คือ	ค่าสัมประสิทธิ์ของตัวแปรควบคุมของ ราคาทองคำรายวันในประเทศ (ราคาซื้อ) อัตราแลกเปลี่ยนของสกุลเงินบาทต่อเงินดอลลาร์สหรัฐที่ปรับข้อมูลแล้ว และ ตัวแปรหุ่นแทนการแพร่ระบาดของ COVID-19 ตามลำดับ

ผลการวิจัยและอภิปรายผล

การตรวจสอบค่าสถิติพื้นฐานกับความเหมาะสมในการใช้ตัวแบบ GARCH

ในข้อมูลจากตารางที่ 1 ที่แสดงค่าสถิติพื้นฐานและการแจกแจงของตัวแปรหลักในการวิเคราะห์ทั้ง 5 ตัว โดยค่าสถิติชี้ว่าตัวแปรส่วนใหญ่มีค่า Skewness ติดลบแสดงว่า โค้งการแจกแจงจะมีลักษณะเบ้ซ้าย (Negative Skewed) เมื่อพิจารณาค่า Kurtosis พบว่ามีค่าสูงกว่า 3 ในทุก ๆ ตัวแปร แสดงว่าตัวแปรมีโค้งการแจกแจงแบบแหลมสูง (Leptokurtic) ส่วน Jarque-Bera Test นั้นมีสมมติฐานว่างว่าตัวแปรมีการแจก

แจกแจงซึ่งตัวแปรดัชนีตลาดหลักทรัพย์และอุตสาหกรรมทุก ๆ ตัวสามารถปฏิเสธสมมติฐานว่างที่ระดับนัยสำคัญ 0.01 แสดงว่าตัวแปรทุก ๆ ตัวไม่ได้มีการแจกแจงแบบปกติ

ตารางที่ 1: ค่าสถิติพื้นฐานและการแจกแจงของตัวแปร

	SET	SET.FOOD	SET.BANK	SET.TRANS	SET.TOUR
Mean	0.0000432	0.0000775	-0.000227	-0.0000182	-0.0000196
Median	0.000306	0.00033	-0.00034	0.000133	-0.00025
Maximum	0.077539	0.061123	0.115104	0.231183	0.079677
Minimum	-0.115682	-0.128436	-0.117321	-0.232674	-0.095672
Std. Dev.	0.010244	0.011162	0.014099	0.022367	0.013674
Skewness	-1.838971	-1.766064	-0.382859	0.225895	-0.233785
Kurtosis	28.33813	21.25772	16.4877	44.646	9.083623
Jarque-Bera	41818.51	22060.45	11642.26	110652.6	2374.906
Probability	0.00***	0.00***	0.00***	0.00***	0.00***

หมายเหตุ: ***, **, * หมายถึง มีนัยสำคัญทางสถิติ ณ ระดับนัยสำคัญ 0.01 , 0.05 และ 0.1 ตามลำดับ

ที่มา: จากการคำนวณโดยโปรแกรมคอมพิวเตอร์

ในส่วนต่อมาคือการทดสอบ ความนิ่ง (Stationarity) ของตัวแปรซึ่งทดสอบด้วย Augmented Dickey Fuller Test (ADF) และ Heteroskedasticity โดย ใช้การทดสอบ ARCH-LM test ได้ค่าสถิติโดยสรุปดังตารางที่ 2 ดังต่อไปนี้

ตารางที่ 2: ค่าสถิติจากการทดสอบ Augmented Dickey Fuller test (ADF) และ ARCH-LM test

	ADF		ARCH Effects
	coefficient	t-ratio	LM
SET	-0.965564	-14.8556***	25.64512***
SET.FOOD	-1.03989	-41.07573***	7.756617***
SET.BANK	-0.794618	-14.70125***	19.0525***
SET.TRANS	-0.972207	-11.30731***	59.89692***
SET.TOUR	-0.988842	-39.67868***	14.83679***

หมายเหตุ: ***, **, * หมายถึง มีนัยสำคัญทางสถิติ ณ ระดับนัยสำคัญ 0.01 , 0.05 และ 0.1 ตามลำดับ

ที่มา: จากการคำนวณโดยโปรแกรมคอมพิวเตอร์

ในการใช้การทดสอบ Augmented Dickey Fuller test (ADF) โดยมีสมมติฐานว่างคือ ตัวแปรมีความไม่นิ่ง (Non-Stationary) เราสรุปว่าตัวแปรทุก ๆ ตัวมีความนิ่งเนื่องจากเราสามารถปฏิเสธสมมติฐานว่างได้ที่ระดับนัยสำคัญที่ 0.01 ยิ่งไปกว่านั้นในการทดสอบ ARCH Effects โดยใช้ ARCH-LM Test ซึ่งมีสมมติฐานว่างว่าไม่มี ARCH Effects ได้ถูกปฏิเสธที่ระดับนัยสำคัญที่ 0.01 เช่นกัน แสดงว่าตัวแปรทุก ๆ ตัวมีความนิ่งและมี ARCH Effects จากค่าสถิติและการทดสอบจากสองตารางที่ผ่านมา ทำให้แปรภายในทุก ๆ ตัวมีความเหมาะสมที่จะใช้ตัวแบบ GARCH ในการวิเคราะห์ความผันผวน

วิจารณ์ผลจากตัวแบบที่ใช้ในการวิเคราะห์ข้อมูลความผันผวน GARCH (1,1)

ผลจากตัวแบบ GARCH (1,1) ค่าสถิติที่เกี่ยวข้องได้สรุปตามตารางที่ 3 ในภาพรวมตัวแปรส่วนใหญ่มีระดับนัยสำคัญทางสถิติที่สูง และการระบาดของ COVID-19 มีทิศทางในการเพิ่มความผันผวนแก่ตลาด ซึ่งมีแนวโน้มตามงานวิจัยอื่น ๆ ในส่วนถัดไปเราจะเน้นสมการความผันผวนแบบมีเงื่อนไข (Conditional Variance Equation) เป็นหลัก เนื่องจากการวิเคราะห์ความผันผวนแบบมีเงื่อนไขเป็นวัตถุประสงค์หลักในงานศึกษานี้

ในประเด็นการตรวจสอบความถูกต้องของตัวแบบนั้น ค่า $\omega, \alpha, \beta \geq 0$ เพื่อเป็นหลักประกันว่าค่าความผันผวน (h_t) จะไม่ติดลบ ซึ่งทุกตัวแบบต่างสอดคล้องกับเงื่อนไขข้างต้นและค่าสัมประสิทธิ์ของตัวแบบ ω, α, β ต่างผ่านการทดสอบที่ระดับนัยสำคัญ 0.01 ทุกตัว ส่วนค่า $0 \leq \alpha + \beta < 1$ เพื่อที่ค่าของ h_t มีเสถียรภาพ (Stability) นั้นก็ต่างสอดคล้องกับเงื่อนไขเช่นเดียวกัน โดยค่า α จะแสดงถึงผลจากค่าคลาดเคลื่อนในอดีตยกกำลังสอง (ε_{t-1}^2) จากสมการค่าคาดหวังแบบมีเงื่อนไข ส่วน β จะแสดงถึงผลจากค่าความผันผวนแบบมีเงื่อนไขถอยไปหนึ่งช่วงเวลา (h_{t-1}) และจะเห็นได้ว่าค่า $\alpha + \beta$ นั้นมีความแตกต่างกันในแต่ละตัวแบบทั้งในภาพรวมของตลาดหลักทรัพย์และในอุตสาหกรรมย่อย ซึ่งว่าความผันผวน (Volatility) ของดัชนีตลาดหลักทรัพย์ทุก ๆ ตัวเปลี่ยนไปตามเวลา และผลจากความยาวจาก Shock ในระบบจะยาวไม่เท่ากัน โดยที่ยังค่า $\alpha + \beta$ ยิ่งมีค่าสูงมากเท่าไรก็จะต้องใช้เวลานานกว่าที่ผลกระทบจาก Shock จะจางหายไป โดยอุตสาหกรรมท่องเที่ยวและสันทนาการจะใช้เวลานานที่สุดกว่าที่ผลของ Shock ในระบบจะหายไป (Long Memory) เมื่อเทียบกับอุตสาหกรรมอื่น ๆ

ในประเด็นสุดท้ายซึ่งเป็นเป้าประสงค์หลักในการศึกษา คือผลของ มาตรการกระตุ้นเศรษฐกิจในช่วงปลายปี พ.ศ. 2563 อันได้แก่ คนละครึ่ง ข้อปดมีคืน และบัตรสวัสดิการแห่งรัฐ ที่มีต่อความผันผวนของตลาดหลักทรัพย์นั้น ค่าสัมประสิทธิ์ของ Measures ในทุก ๆ ตัวแปรตามเป็นบวกและมีระดับนัยสำคัญทางสถิติที่ระดับ 0.01 แทบจะทุกตัวแบบชี้ว่า สามมาตรการดังกล่าว มีผลต่อความผันผวนของตลาดหลักทรัพย์และดัชนีอุตสาหกรรมอย่างมีนัยสำคัญทางสถิติ โดยทำให้ความผันผวนของตลาดและดัชนีอุตสาหกรรมย่อยมีมากขึ้น ซึ่งสอดคล้องกับสมมติฐานที่ตั้งไว้ แสดงว่า ผลของมาตรการไม่เพียงแต่จะมีผลทางตรงในการกระตุ้นการใช้จ่ายของประชาชนกลุ่มเป้าหมายในระบบเศรษฐกิจเพียงอย่างเดียว แต่ยังมีผลทำให้ความเสี่ยงในการลงทุนในตลาดหลักทรัพย์ในภาพรวมตลอดจนบางอุตสาหกรรมย่อยเพิ่มขึ้นด้วยในอีกทางหนึ่ง

ตารางที่ 3: ผลจากการวิเคราะห์และค่าสถิติจากตัวแบบ GARCH (1,1) โดยมีตัวแปรมาตรการ (Measures)

	SET	SET.FOOD	SET.BANK	SET.TRANS	SET.TOUR
Conditional Mean Equation					
μ	0.000351*** (0.000245)	0.0000798*** (0.000219)	-0.000112*** (0.000255)	0.000271*** (0.000319)	0.00000117*** (0.000299)
Conditional Variance Equation					
ω	0.000025*** (0.0000014)	0.00000472*** (0.000000939)	0.00000184*** (0.000000286)	0.0000156*** (0.00000175)	0.0000027*** (0.000000678)
α	0.155855*** (0.000849)	0.077358*** (0.010623)	0.05255*** (0.006416)	0.133952*** (0.014274)	0.031429*** (0.005784)
β	0.56909*** (0.011208)	0.864905*** (0.019832)	0.928261*** (0.006596)	0.776661*** (0.01646)	0.949724*** (0.007939)
$\alpha + \beta$	0.724945	0.942263	0.980811	0.910613	0.981153
Measures	0.0000194*** (0.00000567)	0.0000134*** (0.00000382)	0.0000177*** (0.00000475)	0.000172*** (0.0000409)	0.00000788** (0.00000357)
Gold Price	0.00202*** (0.000117)	0.000587*** (0.000155)	0.000976*** (0.000125)	0.00233*** (0.00044)	0.000285** (0.000134)
Exchange Rate	0.004935*** (0.000213)	0.002128*** (0.00028)	0.000479* (0.000264)	0.004531*** (0.000859)	0.001938*** (0.000322)
COVID-19	0.0000103*** (0.00000136)	0.00000417* (0.0000024)	0.00000609*** (0.0000021)	0.0000856*** (0.0000172)	0.00000488** (0.00000222)
Llik	5033.451	4981.805	4710.03	4285.025	4554.966
AIC	-6.564926	-6.497459	-6.142429	-5.587231	-5.939864
SIC	-6.537056	-6.469589	-6.114559	-5.55936	-5.911994
HQC	-6.554554	-6.487087	-6.132057	-5.576858	-5.929492

หมายเหตุ: ***, **, * หมายถึง มีนัยสำคัญทางสถิติ ณ ระดับนัยสำคัญ 0.01 , 0.05 และ 0.1 ตามลำดับ

ที่มา: จากการคำนวณโดยโปรแกรมคอมพิวเตอร์

สรุป

ผลจากการศึกษาวิจัยเรื่อง “ผลจากมาตรการกระตุ้นเศรษฐกิจอันเนื่องมาจากการแพร่ระบาดของ COVID-19 ที่มีต่อความผันผวนของตลาดหลักทรัพย์แห่งประเทศไทยและดัชนีของบางอุตสาหกรรม : กรณีศึกษามาตรการ คนละครึ่ง ซ้อปดีมีคืน และบัตรสวัสดิการแห่งรัฐ” สามารถสรุปผลการวิจัยได้ดังนี้

ค่าสัมประสิทธิ์ของตัวแปรมาตรการมีค่าเป็นบวกและมีระดับนัยสำคัญทางสถิติที่สูงแสดงว่ามาตรการของรัฐทั้ง 3 มาตรการทำให้ความผันผวนของตลาดหลักทรัพย์ในภาพรวมและดัชนีของอุตสาหกรรมเพิ่มขึ้นอย่างมีนัยสำคัญ ดังนั้น มาตรการกระตุ้นเศรษฐกิจในช่วงเวลาที่มีการระบาดของ COVID-19 มีแนวโน้มที่ไม่เพียงจะทำให้เกิดการกระตุ้นการใช้จ่ายในระบบเศรษฐกิจเพียงอย่างเดียว แต่การที่กิจกรรมของเศรษฐกิจที่เพิ่มสูงขึ้นยังได้นำไปสู่กิจกรรมที่เพิ่มสูงขึ้นในการลงทุนในตลาดหลักทรัพย์และในท้ายที่สุดก็ทำให้ความผันผวนหรือความเสี่ยงในการลงทุนในตลาดหลักทรัพย์สูงขึ้นไปด้วย

ข้อเสนอแนะ

จากผลดังกล่าวเราอาจจะใช้ในการแนะนำภาครัฐและเอกชนที่เกี่ยวข้องกับตลาดหลักทรัพย์ดังต่อไปนี้สำหรับผู้ลงทุนในตลาดหลักทรัพย์ก็ควรมีกลยุทธ์การลงทุนที่เหมาะสมในการจัดการกับความเสี่ยงที่เพิ่มขึ้นซึ่งเป็นผลอีกด้านหนึ่งของมาตรการกระตุ้นเศรษฐกิจของรัฐบาล สำหรับภาครัฐนั้นเมื่อมีการออกมาตรการกระตุ้นเศรษฐกิจในลักษณะนี้ ภาครัฐเองอาจมีมาตรการเสริมบางประการเพื่อที่จะลดความเสี่ยงในการลงทุนในตลาดหลักทรัพย์ประกอบกันด้วยเพื่อจะทำให้ประสิทธิภาพของนโยบายกระตุ้นเศรษฐกิจเพิ่มขึ้น โดยการลดผลกระทบทางลบในการดำเนินมาตรการให้น้อยที่สุด ท้ายที่สุดนี้ รัฐบาลควรคำนวณผลได้ผลเสียในการดำเนินนโยบายอย่างรัดกุมโดยเฉพาะเราอาจต้องเผชิญภาวะการแพร่ระบาดของ COVID-19 เป็นเวลานานพอสมควรก่อนที่จะปัญหาการระบาดของ COVID-19 จะได้รับการคลี่คลายอย่างแท้จริง

เอกสารอ้างอิง

- ตรีเพชร พุทธแดง. (2559). ผลกระทบของนโยบายการเงิน และนโยบายการคลังต่อดัชนีราคาหลักทรัพย์ กรณีศึกษาประเทศไทย ประเทศมาเลเซีย ประเทศอินโดนีเซีย ประเทศฟิลิปปินส์ และประเทศสิงคโปร์. วิทยานิพนธ์วิทยาศาสตรมหาบัณฑิต, สาขาวิชาการเงิน, มหาวิทยาลัยกรุงเทพ.
- พุทธรชชาติ ลุนคำ. (2564). ธุรกิจท่องเที่ยวและโรงแรมหลัง COVID-19. สืบค้นเมื่อ 13 พฤษภาคม 2564, จาก <https://www.krungsri.com/th/research/research-intelligence/ri-future-of-tourism-21>
- มติชนออนไลน์. (2563). ธุรกิจ 'โลจิสติกส์' เพื่อฟื้นฟู ในยุค 'โควิด' ระบาด. สืบค้นเมื่อ 13 พฤษภาคม 2564, จาก https://www.maticchon.co.th/news-monitor/news_2129870
- ศูนย์วิจัยกสิกรไทย. (2563). New Normal...ความท้าทายใหม่ของธุรกิจขนส่งสาธารณะ แท็กซี่...รับผลกระทบหนักสุด!. สืบค้นเมื่อ 13 พฤษภาคม 2564, จาก <https://kasikornresearch.com/th/analysis/k-social-media/Pages/Transport-NewNorm-FB2205.aspx>
- ศูนย์วิจัยธนาคารออมสิน. (2563). ภาวะอุตสาหกรรมรายสาขา. สืบค้นเมื่อ 13 พฤษภาคม 2564, จาก <https://www.gsbresearch.or.th/gsb/category/economics/industrial-economics/industry-update/>



- ศรัญพร คงแก้ว. (2548). *ผลกระทบของนโยบายการเงินที่มีต่อดัชนีราคาตลาดหลักทรัพย์แห่งประเทศไทย*. กรุงเทพฯ, มหาวิทยาลัยเกษตรศาสตร์.
- สำนักงานเศรษฐกิจการคลัง (สศค.). (2563). *ประเมินมาตรการกระตุ้นเศรษฐกิจ*. สืบค้นเมื่อ 3 มีนาคม 2564, จาก <http://www.fpo.go.th/main>
- Baker, S. R., Bloom, N., Davis, S. J., & Kost, K.J. (2019). *Policy News and Stock Market Volatility*. NBER Working Papers 25720, National Bureau of Economic Research, Inc.
- Bollerslev, T. (1986). Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics*, 31(3), 307-327.
- Hill, R. C. Griffiths, W. E., & Lim, G. C. (2011). *Principles of Econometrics*. Publisher: Wiley; 4th edition.
- Panyagometh, K. (2020). The Effects of Pandemic Event on the Stock Exchange of Thailand. *Economies*, MDPI, *Open Access Journal*, 8(4).
- Thakolsri, S., Sethapramote, Y., & Jiranyakul, K. (2015). *Asymmetric Volatility of The Thai Stock Market: Evidence From High-Frequency Data*. MPRA paper 67181, University Library of Munich, Germany.
- Yousef, I. (2020). Spillover of COVID-19: Impact on Stock Market Volatility. *International Journal of Psychosocial Rehabilitation*, 24(6), 18069-18081.
- Zare, R., Azali, M., & Habibullah, M. S. (2013). Monetary Policy and Stock Market Volatility in the ASEAN5: Asymmetries over Bull and Bear Markets. *Procedia Economics and Finance*, 7, 18-27.