

การวิเคราะห์เปรียบเทียบระหว่างตัวแบบหน่วยความจำระยะสั้นระยะยาวและป่าสุ่ม สำหรับการทำนายราคาปิดหุ้น GULF

Comparative Analysis of Long Short-Term Memory and Random Forest

Models for GULF Stock Closing Price Prediction

คณิน พงษ์ธนาวงศ์, ณรงค์ฤทธิ์ แก้วบรรจักษ์*

Kanin Pongtanavong, Narongrit Kaewbanjak*

คณะวิทยาศาสตร์ ศรีราชา มหาวิทยาลัยเกษตรศาสตร์ วิทยาเขตศรีราชา ประเทศไทย

Faculty of Science at Sriracha, Kasetsart University, Sriracha Campus, Thailand

บทคัดย่อ

ในการศึกษานี้ผู้วิจัยได้ทำการศึกษาเปรียบเทียบประสิทธิภาพของตัวแบบป่าสุ่ม และตัวแบบหน่วยความจำระยะสั้นระยะยาว (Long Short-Term Memory: LSTM) ในการทำนายราคาปิดของหุ้น GULF ซึ่งลักษณะราคาหุ้นอยู่ในแนวโน้มขาขึ้นระยะยาว โดยใช้ข้อมูลราคาปิดและราคาเปิดตั้งแต่วันที่ 21 มีนาคม พ.ศ. 2561 ถึง 31 ธันวาคม พ.ศ. 2565 ร่วมกับตัวชี้วัดเชิงเทคนิคได้แก่ EMA TEMA และ WMA ซึ่งได้ทำการศึกษาเปรียบเทียบทั้งหมด 3 กรณีศึกษา ประกอบไปด้วย กรณีแรกการใช้ตัวแบบป่าสุ่มที่มีการหาค่าพารามิเตอร์ที่เหมาะสม กรณีที่ 2 การใช้ตัวแบบ LSTM ที่มีการหาค่าพารามิเตอร์ที่เหมาะสม และกรณีสุดท้ายซึ่งจะคล้ายกับกรณีที่ 2 แต่จะทำการปรับค่าฟังก์ชันกระตุ้นจากฟังก์ชัน Hyperbolic Tangent (Tanh) เป็นฟังก์ชัน Exponential Linear Unit (ELU) โดยทำการเปรียบเทียบประสิทธิภาพของตัวแบบทั้งสามกรณีด้วยค่าความคลาดเคลื่อนและกราฟแสดงค่าทำนาย ผลการศึกษา พบว่า ตัวแบบป่าสุ่มนั้น มีประสิทธิภาพในการทำนายราคาปิดของหุ้น GULF น้อยที่สุด และตัวแบบ LSTM ที่ได้มีการปรับค่าฟังก์ชันกระตุ้นเป็นฟังก์ชัน ELU ในกรณีที่ 3 นั้นมีประสิทธิภาพมากที่สุดจากทั้งสามกรณี

คำสำคัญ: การทำนายราคาปิดของหุ้น, การเรียนรู้ของเครื่อง, การเรียนรู้เชิงลึก, ตัวแบบป่าสุ่ม, ตัวแบบหน่วยความจำระยะสั้นระยะยาว

ABSTRACT

In this study, we conducted a comparative analysis of the performance of a Random Forest model and a Long Short-term Memory model (LSTM) in predicting the closing price of GULF stock, which has an Uptrend characteristic. The data used in this study included closing and opening prices from March 21, 2018, to December 31, 2022, along with technical indicators such as EMA, TEMA, and WMA. Three comparative studies were conducted: the first case utilized a Random Forest model with optimal parameters, the second one utilized an LSTM model with optimal parameters, and the third case was similar to the second one but with a modification in the activation function from Hyperbolic Tangent function (Tanh) to Exponential Linear Unit function (ELU). The performance of these three models was evaluated based on the error values and the predicted value graphs. Our findings indicate that the Random Forest model had the lowest performance for GULF stock closing price prediction among the three cases. Conversely, the modified LSTM model with the ELU activation function in the third case demonstrated the highest performance among the three cases.

KEYWORDS: Stock Closing Price Prediction, Machine Learning, Deep Learning, Random Forest Model, Long Short-Term Memory Model

*Corresponding Author:

Received: 17/06/2023; Revised: 27/02/2024; Accepted: 19/06/2024

1. บทนำ

หุ้นเป็นสินทรัพย์ประเภทหนึ่งที่เกิดการออกให้แก่ผู้ถือ เพื่อระดมเงินทุนไปต่อยอด หรือลงทุนในการขยายกิจการ โดยที่ผู้ถือจะมีส่วนได้ส่วนเสีย หรือมีสิทธิในสินทรัพย์ และรายได้ของบริษัท รวมทั้งมีโอกาสได้รับเงินปันผลซึ่งขึ้นอยู่กับผลประกอบการของบริษัทในแต่ละไตรมาส หรือแต่ละปี ในประเทศไทยนั้นได้มีการจัดตั้งตลาดหลักทรัพย์แห่งประเทศไทยขึ้นตามพระราชบัญญัติตลาดหลักทรัพย์แห่งประเทศไทย พ.ศ. 2517 โดยมีวัตถุประสงค์ให้เป็นตลาดรองเพื่อการระดมทุนในการพัฒนาประเทศ พัฒนาการลงทุน และเป็นศูนย์กลางการซื้อขายหลักทรัพย์

สินทรัพย์ประเภทหุ้นเป็นสินทรัพย์ที่มีความผันผวนไปตามสภาวะเศรษฐกิจโลก ซึ่งในปัจจุบันที่สภาวะเศรษฐกิจโลกอยู่ระหว่างการฟื้นตัวจากเหตุการณ์ต่าง ๆ ในระยะเวลาไม่กี่ปีที่ผ่านมาไม่ว่าจะเป็น การแพร่ระบาดของเชื้อไวรัสโคโรนา 2019 ที่มีการแพร่ระบาดไปทั่วโลก สถานการณ์ความตึงเครียดระหว่างสาธารณรัฐประชาชนยูเครนและสหพันธรัฐรัสเซีย การปรับขึ้นอัตราดอกเบี้ยเพื่อแก้เงินเฟ้อของธนาคารกลางสหรัฐอเมริกา ค่าเงินบาทที่ผันผวน อีกทั้งยังมีปัจจัยภายในประเทศ เช่น นโยบายของภาครัฐ ปัจจัยเหล่านี้ล้วนส่งผลต่อสภาวะเศรษฐกิจและตลาดหุ้นไทย จึงส่งผลให้มีนักลงทุนมากมายที่ต้องการแสวงหาผลกำไรภายใต้สภาวะความผันผวนเช่นนี้เพิ่มขึ้นจำนวนมาก และพยายามที่จะทำนายหรือพยากรณ์ราคาหุ้นทั้งในเชิงเทคนิค และการทำนายโดยใช้ตัวแบบต่าง ๆ เพื่อให้สามารถวางแผนเตรียมการรับมือป้องกันหรือวางแผนเพื่อให้สามารถสร้างกำไรได้จากการลงทุน แต่อย่างไรก็ตามการทำนายราคาของหุ้นให้มีความแม่นยำสูงนั้นเป็นความท้าทายอย่างมาก วิธีที่ได้รับความนิยมและถูกนำมาใช้ในการทำนายราคาของหุ้นกันอย่างแพร่หลายคือ การเรียนรู้ของเครื่อง (Machine Learning : ML) และการเรียนรู้เชิงลึก (Deep Learning : DL) โดยตัวแบบที่นิยมนำมาใช้งาน อาทิเช่น ตัวแบบป่าสุ่ม (Random Forest Model : RF) ที่พัฒนามาจากตัวแบบต้นไม้ตัดสินใจ (Decision Tree Model : DT) โดย Breiman (2001) และตัวแบบหน่วยความจำระยะสั้นระยะยาว (Long Short-Term Memory Model : LSTM) ที่พัฒนามาจากโครงข่ายประสาทเทียมแบบวนกลับ (Recurrent Neural Network : RNN) โดย Hochreiter & Schmidhuber (1997)

นอกจากนี้ยังมีงานวิจัยมากมายที่ได้ศึกษาการสร้างตัวแบบเพื่อใช้ในการทำนายทั้งดัชนีของตลาดหลักทรัพย์และราคาหุ้นรายตัว โดยเริ่มจากการใช้เพียงข้อมูลพื้นฐานในอดีตไปจนถึงการใช้ตัวชี้วัดเชิงเทคนิคร่วมด้วย อาทิเช่น Hum Nath Bhandari et al. (2022) ได้ศึกษาการใช้ตัวแบบหน่วยความจำระยะสั้นระยะยาวในการทำนายราคาปิดในวันถัดไปของดัชนี S&P 500 โดยใช้ตัวแปรนำเข้าจำนวน 9 ตัวที่มีการนำมารวมกันอย่างลงตัวจากข้อมูลพื้นฐานของตลาด ข้อมูลเศรษฐศาสตร์มหภาค และตัวชี้วัดเชิงเทคนิคเพื่อจับพฤติกรรมของตลาดหลักทรัพย์ และสร้างตัวแบบหน่วยความจำระยะสั้นระยะยาวแบบชั้นเดียวและหลายชั้นโดยใช้ตัวแปรนำเข้าที่ถูกละเลือกไว้ ผลการศึกษาแสดงให้เห็นว่าตัวแบบหน่วยความจำระยะสั้นระยะยาวแบบชั้นเดียวมีผลการทำนายที่แม่นยำกว่าตัวแบบหน่วยความจำระยะสั้นระยะยาวแบบหลายชั้น Manuel R. Vargas et al. (2017) ได้นำหลักการเรียนรู้เชิงลึกไปประยุกต์ใช้สำหรับการทำนายทิศทาง การเคลื่อนไหวของราคาหุ้นรายวันโดยใช้ตัวชี้วัดเชิงเทคนิคร่วมกับบทความข่าวการเงินเป็นตัวแปรนำเข้า ผลการศึกษาพบว่าบทความข่าวการเงินนั้นมีส่วนสำคัญที่ทำให้ผลลัพธ์มีเสถียรภาพมากขึ้นเมื่อเปรียบเทียบกับกรณีที่ใช้ตัวชี้วัดเชิงเทคนิคเป็นตัวแปรนำเข้าเพียงอย่างเดียว และมีผลลัพธ์สอดคล้องกันเมื่อเปรียบเทียบกับชุดของตัวชี้วัดเชิงเทคนิคที่แตกต่างกัน Mehar Vijh et al. (2019) ได้ศึกษาการทำนายราคาปิดในวันถัดไปของหุ้นจาก 5 บริษัทที่อยู่ในกลุ่มอุตสาหกรรมที่แตกต่างกันโดยใช้โครงข่ายประสาทเทียม และตัวแบบป่าสุ่ม จากผลการศึกษา พบว่า ในการประยุกต์ใช้โครงข่ายประสาทเทียมนั้น ให้ผลการทำนายที่ดีกว่าเมื่อเปรียบเทียบกับการประยุกต์ใช้ตัวแบบป่าสุ่ม ไม่เพียงเท่านั้นยังมีการนำการเรียนรู้ของเครื่อง มาใช้กับสกุลเงินดิจิทัล (Cryptocurrency) เช่น การศึกษาของ Huang et al. (2019) ได้ศึกษาความสามารถในการทำนายผลตอบแทนของบิตคอยน์ ด้วยการสร้างตัวแบบต้นไม้ตัดสินใจเพื่อจำแนกข้อมูลสำหรับการทำนายผลตอบแทนโดยใช้ตัวชี้วัดเชิงเทคนิค 124 ตัว ผลการศึกษาแสดงให้เห็นว่าการใช้ข้อมูลขนาดใหญ่และการวิเคราะห์เชิงเทคนิคสามารถช่วยทำนายผลตอบแทนของบิตคอยน์ซึ่งไม่ได้ขับเคลื่อนด้วยปัจจัยพื้นฐานได้ ในประเทศไทยเองก็มีงานวิจัยด้านนี้เช่นเดียวกัน อาทิเช่น การศึกษาของ Kaewmaha & Punyachaporn (2021) ได้ศึกษาการคาดการณ์

ผลตอบแทนในขนาดของตราสารทุนหุ้นสามัญโดยการ
ใช้การเรียนรู้ของเครื่อง จากผลการศึกษา พบว่า ตัวแบบ
การเรียนรู้ของเครื่องที่สามารถทำนายผลตอบแทนได้
แม่นยำที่สุดก็คือตัวแบบป่าสุ่มซึ่งมีความคลาดเคลื่อน
ต่ำที่สุดในทุกช่วงของการคาดการณ์ผลตอบแทน (ราย 1
วัน 1 เดือน และ 3 เดือน)

จากแนวคิดที่ได้กล่าวมาข้างต้น ในงานวิจัยนี้
ผู้วิจัยจึงสนใจศึกษาประสิทธิภาพในการทำนายราคาปิด
ของหุ้นในตลาดหุ้นไทย โดยการใช้ตัวแบบป่าสุ่มและตัว
แบบหน่วยความจำระยะสั้นระยะยาว เพื่อทำนาย
พฤติกรรมราคาเคลื่อนไหวของราคาปิดของหุ้นในเวลา
ถัดไปที่มีการผันแปรในลักษณะขึ้นหรือลงตามเวลา ซึ่ง
กรณีที่จะถูกนำมาเปรียบเทียบกับนั้นได้แก่ กรณีแรก การใช้
ตัวแบบป่าสุ่มที่มีการหาค่าพารามิเตอร์ที่เหมาะสมโดยการ
ใช้ Randomized Search CV จากไลบรารี Sci-kit learn
กรณีที่สองการใช้ตัวแบบหน่วยความจำระยะสั้นระยะยาวที่
มีการหาค่าพารามิเตอร์ที่เหมาะสมโดยใช้ Bayesian
Optimization จากไลบรารี Keras Tuner และกรณีที่สาม
จะคล้ายกับกรณีที่สองแต่ผู้วิจัยจะทำการปรับค่าฟังก์ชัน
กระตุ้น (Activation Function) จากฟังก์ชัน Tanh เป็น
ฟังก์ชัน ELU ซึ่งเหมาะกับข้อมูลที่มี Noise และสามารถ
แก้ปัญหา Vanishing Gradient ตลอดจนสามารถทำงาน
ได้ดีกับข้อมูลใหม่ที่ไม่เคยเห็นมาก่อน สำหรับข้อมูลที่ใช้
ในการศึกษานั้นเป็นชุดข้อมูลพื้นฐานในอดีตของหุ้น ซึ่ง
ประกอบด้วย ราคาเปิดและราคาปิด ตั้งแต่วันที่ 21
มีนาคม พ.ศ. 2561 ถึง 31 ธันวาคม พ.ศ. 2565 ร่วมกับ
ตัวชี้วัดเชิงเทคนิคได้แก่ EMA TEMA และ WMA โดย
เลือกกรณีศึกษาสำหรับหุ้น GULF ซึ่งเป็นหุ้นที่น่าสนใจ
เนื่องจากราคาอยู่ในแนวโน้มขาขึ้นระยะยาว หรือ Uptrend
นับตั้งแต่เริ่มทำการซื้อขายในตลาดหลักทรัพย์แห่งประเทศไทย โดยทำจุดสูงสุดใหม่ (New High) อยู่
บ่อยครั้ง

2. ความรู้พื้นฐาน

การเรียนรู้ของเครื่อง (กอบเกียรติ สระอุบล, 2565) เป็นศาสตร์อีกแขนงหนึ่งที่ใช้สำหรับสร้างการ
เรียนรู้ให้กับเครื่อง โดยอาศัยวิธีการทางคณิตศาสตร์และ
สถิติในการสร้างตัวแบบจากข้อมูลที่มีอยู่เพื่อใช้ในการ
ทำนายผลและตัดสินใจ ทั้งนี้ การเรียนรู้ของเครื่องถือเป็น
ส่วนหนึ่งของการสร้างปัญญาประดิษฐ์และยังต้องนำ
ความรู้ด้านวิทยาการข้อมูลมาเป็นพื้นฐานในการคำนวณ

อีกด้วย โดยแบ่งประเภทของการเรียนรู้ออกเป็นสอง
ประเภทหลัก คือ การเรียนรู้แบบมีผู้สอน (Supervised
Learning) เป็นการเรียนรู้จากลักษณะของข้อมูลตัวอย่างที่
มีการระบุผลที่ต้องการหรือประเภทไว้ แล้วนำไปทำนาย
ข้อมูลอื่นที่ไม่ทราบคำตอบมาก่อน ซึ่งการเรียนรู้แบบมี
ผู้สอนแบ่งออกเป็น 2 ประเภท คือ การจำแนกประเภท
(Classification) และ การวิเคราะห์การถดถอย
(Regression) ในส่วนของการเรียนรู้ของเครื่องอีกประเภท
หนึ่งคือ การเรียนรู้แบบไม่มีผู้สอน (Unsupervised
Learning) เป็นการสร้างตัวแบบที่เหมาะสมกับข้อมูลเพื่อ
วิเคราะห์และจัดกลุ่มข้อมูล ตัวแบบประเภทนี้ถูกใช้ในการ
ค้นหารูปแบบที่ซ่อนอยู่ในข้อมูล หรือการจัดกลุ่มข้อมูล
ข้อมูลโดยระบบจะประมวลผลเอง ซึ่งที่ผู้ใช้งานไม่ต้อง
แทรกแซงการทำงานของระบบ

การเรียนรู้เชิงลึก (กอบเกียรติ สระอุบล, 2565)
เป็นศาสตร์แขนงย่อยซึ่งอยู่ในการเรียนรู้ของเครื่องอีก
ชั้นหนึ่ง ที่มีเป้าหมายเช่นเดียวกับการเรียนรู้ของเครื่อง
คือทำให้คอมพิวเตอร์เกิดการเรียนรู้แล้วนำความรู้ที่
ใช้งาน แต่การเรียนรู้เชิงลึกนั้นจะใช้วิธีหรือเทคนิค
โครงข่ายประสาทเทียม (Artificial Neural Network) ซึ่ง
มีความลึกหลายชั้นที่จำลองการทำงานของเซลล์ประสาท
ในสมองมนุษย์ โดยตัวอย่างที่เด่นชัดของการประยุกต์ใช้
การเรียนรู้เชิงลึก เช่น การจำแนกภาพ การตรวจจับวัตถุ
และการรู้จำใบหน้า

ตัวแบบป่าสุ่มเป็นการเรียนรู้แบบรวมกลุ่ม
(Ensemble Learning) ซึ่งถูกพัฒนามาจากตัวแบบต้นไม้
ตัดสินใจโดย Breiman (2001) สามารถใช้งานได้ทั้ง
สำหรับการจำแนกประเภทและการวิเคราะห์การถดถอย
หลักการทำงานของตัวแบบป่าสุ่มคือจะทำการสร้างตัว
แบบต้นไม้ตัดสินใจหลาย ๆ ต้น โดยสร้างจากการสุ่ม
ข้อมูลตัวอย่างแบบเลือกแล้วใส่กลับ และสุ่มตัวแปรเพื่อ
นำมาสร้างเป็นตัวแบบต้นไม้ตัดสินใจที่มีลักษณะแตกต่างกัน
ในแต่ละต้น โดยให้ต้นไม้ตัดสินใจแต่ละต้นทำนาย
ผลลัพธ์แล้วนำไปหาผลลัพธ์สุดท้าย หากเป็นการจำแนก
ประเภทจะแสดงผลลัพธ์สุดท้ายเป็นค่าที่ได้รับการทำนาย
มากที่สุดจากต้นไม้ตัดสินใจทั้งหมด ถ้าในกรณีที่เป็นการ
วิเคราะห์การถดถอยจะแสดงผลลัพธ์สุดท้ายเป็นค่าเฉลี่ย
ของผลลัพธ์จากต้นไม้ตัดสินใจทั้งหมด

โครงข่ายประสาทเทียมเป็นขั้นตอนวิธีสำหรับ
ประมวลผลสารสนเทศโดยการคำนวณแบบคอนเนคชัน
นิสต์ (Connectionist) เพื่อจำลองการทำงานของระบบ

โครงข่ายประสาทในสมองของมนุษย์ โดยนำหลักการมาจากระบบประสาทจริงทางชีววิทยา (Biological Neuron) ที่ประกอบด้วยเซลล์ประสาทหรือนิวรอน (Neurons) และจุดประสานประสาท (Synapses) ทำหน้าที่เชื่อมต่อเซลล์ประสาทหนึ่งกับเซลล์ประสาทอื่น ซึ่งภายในโครงข่ายประสาทเทียมจะประกอบไปด้วยชั้นนำเข้า (input layer) ชั้นซ่อน (hidden layer) และชั้นส่งออก (output layer)

โครงข่ายประสาทเทียมแบบวนกลับ (ล่อ บัญ เภษม, 2564) เป็นโครงข่ายประสาทที่มีการเก็บสถานะก่อนหน้าเพื่อนำไปประมวลผลสำหรับข้อมูลลำดับถัดไป โดยโครงข่ายประสาทเทียมแบบวนกลับนั้นมีลักษณะคล้ายกับโครงข่ายประสาทเทียมแบบปกติ แต่จะมีการส่งต่อข้อมูลชั้นซ่อนของช่วงเวลาก่อนหน้าไปเป็นข้อมูลนำเข้าของช่วงเวลาถัดไปเพิ่มเติมขึ้นมา ซึ่งเหมาะสำหรับข้อมูลที่มีความสัมพันธ์ในลักษณะของลำดับ (Sequence) เช่น ข้อมูลชนิดอนุกรมเวลา (Time-series)

ตัวแบบหน่วยความจำระยะสั้นระยะยาวถูกนำเสนอโดย Hochreiter & Schmidhuber (1997) เป็นโครงข่ายประสาทเทียมแบบวนกลับที่มีการปรับปรุงเพิ่มเติมเพื่อแก้ปัญหาการสูญหายของเกรเดียนต์ โดยการนำเอาหน่วยประตูสัญญาณ (Gated Unit) มาใช้เพื่อให้โครงข่ายประสาทเทียมมีความรวดเร็วมากขึ้นและใช้หน่วยความจำน้อยลง โดยประกอบไปด้วย ประตูสัญญาณฟอรัเก็ต (forget gate) ประตูสัญญาณนำเข้า (input gate) และ ประตูสัญญาณส่งออก (output gate) ซึ่งทำให้ตัวแบบหน่วยความจำระยะสั้นระยะยาวนั้นแตกต่างจากโครงข่ายประสาทเทียมแบบวนกลับจากการที่สามารถจดจำข้อมูลในอดีตได้ดีกว่า

ตัวชี้วัดเชิงเทคนิค (Technical indicator) (Pardeshi & Kale, 2021) คือการคำนวณด้วยวิธีการทางสถิติ โดยใช้ข้อมูลพื้นฐานเช่น ราคา หรือปริมาณการซื้อขายเพื่อนำมาใช้ในการหาสัญญาณของการซื้อขายหรือทำนายแนวโน้มราคาในอนาคต หนึ่งในตัวชี้วัดเชิงเทคนิคที่ได้รับความนิยมคือ ค่าเฉลี่ยเคลื่อนที่ (Moving Average: MA) ซึ่งถูกนำมาใช้เพื่อระบุลักษณะแนวโน้มของตลาด โดยมีหลายรูปแบบดังนี้

ค่าเฉลี่ยเคลื่อนที่อย่างง่าย (Simple Moving Average: SMA) (Hansun, 2013) เป็นค่าเฉลี่ยเคลื่อนที่ที่สามารถคำนวณได้ง่ายที่สุดซึ่งมีสูตรดังนี้

$$SMA_t = \frac{P_t + P_{t-1} + \dots + P_{t-(n-1)}}{n} \quad (1)$$

โดยที่ P_t คือ ราคาปิดของหุ้น ณ วันที่ t

n คือ จำนวนข้อมูลที่ใช้ในการคำนวณ

ค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนัก (Weighted Moving Average: WMA) (Hansun, 2013) ถูกพัฒนาจากค่าเฉลี่ยเคลื่อนที่อย่างง่าย โดยจะมีการถ่วงน้ำหนักเพื่อให้ความสำคัญกับข้อมูลที่ใหม่ที่สุดที่ใช้ในการคำนวณมากกว่าข้อมูลเก่าซึ่งมีสูตรดังนี้

$$WMA_t = \frac{nP_t + (n-1)P_{t-1} + \dots + P_{t-(n+1)}}{n + (n-1) + \dots + 1} \quad (2)$$

โดยที่ P_t คือ ราคาปิดของหุ้น ณ วันที่ t

n คือ จำนวนข้อมูลที่ใช้ในการคำนวณ

ค่าเฉลี่ยเคลื่อนที่แบบเอกซ์โพเนนเชียล (Exponential Moving Average: EMA) (Hansun, 2013) เป็นรูปแบบหนึ่งของค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนัก แต่น้ำหนักของข้อมูลเก่าจะมีการลดลงแบบเอกซ์โพเนนเชียลเพื่อไม่ให้ค่าลดลงจนถึง 0 ซึ่งมีสูตรดังนี้

$$EMA_t = \alpha P_t + (1 - \alpha) EMA_{t-1}; t > 1 \quad (3)$$

เมื่อ $EMA_t = P_t$

โดยที่ P_t คือ ราคาปิดของหุ้น ณ วันที่ t

α คือ ค่าคงตัวการปรับเรียบ (smoothing constant) ซึ่งกำหนดให้ $\alpha = 2 / (n + 1)$

ค่าเฉลี่ยเคลื่อนที่แบบเอกซ์โพเนนเชียลสามเท่า (Triple Exponential Moving Average: TEMA) (Mulloy, 1994) เป็นตัวชี้วัดที่พัฒนามาจากค่าเฉลี่ยเคลื่อนที่แบบเอกซ์โพเนนเชียล โดยการใช้วิธีการปรับให้เรียบ 3 ชั้นเพื่อลดความล่าช้า และเพิ่มการตอบสนองต่อราคาที่เปลี่ยนแปลงไป ซึ่งมีสูตรดังนี้

$$TEMA_t = 3EMA1 - 3EMA2 + EMA3 \quad (4)$$

โดยที่ $EMA1$ คือ EMA ของราคาปิดของหุ้น

$EMA2$ คือ EMA ของ $EMA1$

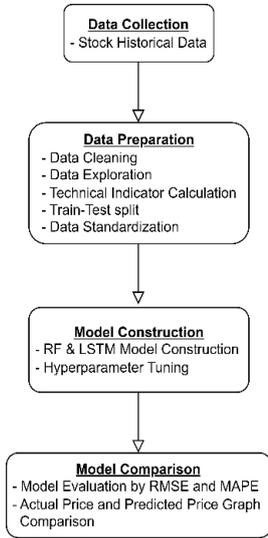
$EMA3$ คือ EMA ของ $EMA2$

3. วิธีดำเนินงานวิจัย

งานวิจัยนี้มีขั้นตอนการดำเนินงานประกอบด้วย 4 ขั้นตอนคือ การเก็บรวบรวมข้อมูล การเตรียมข้อมูล การสร้างตัวแบบ และการเปรียบเทียบความเหมาะสมของตัวแบบดังแผนภาพในรูปที่ 1

3.1 การเก็บรวบรวมข้อมูล

ในงานวิจัยนี้ได้รวบรวมชุดข้อมูลจากเว็บไซต์ investing.com ซึ่งประกอบไปด้วยข้อมูลราคาเปิด ราคาปิด ราคาสูงสุด และราคาต่ำสุดรายวันของหุ้น GULF ตั้งแต่วันที่ 21 มีนาคม พ.ศ. 2561 ถึง วันที่ 30 ธันวาคม พ.ศ. 2565 ซึ่งมีจำนวนข้อมูลทั้งหมด 1160 ค่า โดยกราฟราคาปิดของหุ้น GULF สามารถแสดงได้ดังรูปที่ 2



รูปที่ 1 แผนภาพขั้นตอนการดำเนินงานวิจัย

3.2 การเตรียมข้อมูล

ในการเตรียมข้อมูลก่อนที่จะนำไปใช้สำหรับการสร้างตัวแบบนั้น เมื่อได้รับข้อมูลมาแล้วจะต้องทำการจัดเรียงข้อมูลใหม่ เนื่องจากชุดข้อมูลที่รวบรวมมามีการเรียงข้อมูลจากวันสุดท้ายไปยังวันแรก หลังจากนั้นจึงนำเข้าสู่ชุดข้อมูลไปยัง Jupyter Notebook เมื่อนำเข้าสู่ชุดข้อมูลแล้วจึงดำเนินการตรวจสอบชุดข้อมูล และทำความสะอาดข้อมูลก่อนเนื่องจากอาจจะมีข้อมูลที่สูญหายหรือข้อมูลที่ไม่ถูกต้อง ซึ่งจากการตรวจสอบข้อมูลที่รวบรวมมาเพื่อใช้สำหรับการศึกษานี้พบว่าไม่มีข้อมูลสูญหายหรือข้อมูลผิดปกติ ดังนั้น จึงทำให้ได้ข้อมูลทั้งหมดจำนวน 1160 ค่า หลังจากนั้นทำการคำนวณค่าของ EMA TEMA และ WMA โดยใช้ข้อมูลราคาปิดย้อนหลัง 7 วัน

ทำการของตลาดหลักทรัพย์เป็นค่าเริ่มต้น ซึ่งข้อมูล 7 วันแรกที่ใช้เป็นค่าเริ่มต้นในการคำนวณค่าตัวชี้วัดเชิงเทคนิคดังกล่าว เริ่มตั้งแต่วันที่ 21 มีนาคม พ.ศ. 2561 ถึง 29 มีนาคม พ.ศ. 2561 จึงทำให้เหลือข้อมูลสำหรับการฝึกและทดสอบตัวแบบรวมทั้งหมดจำนวน 1153 ค่า ประกอบด้วย ข้อมูลตั้งแต่วันที่ 30 มีนาคม พ.ศ. 2561 ถึงวันที่ 30 ธันวาคม พ.ศ. 2565

ในการศึกษานี้จะพิจารณาเปรียบเทียบทั้งหมด 3 กรณีที่มีผลต่อการทำนายราคาปิดของหุ้นทั้ง GULF โดยการใช้ตัวแบบป่าสุ่ม และตัวแบบหน่วยความจำระยะสั้นระยะยาว ดังนั้นจึงกำหนดตัวแปรนำเข้า $x_i \in \mathbb{R}^5$ ซึ่งประกอบด้วยข้อมูลราคาปิด ราคาเปิด EMA TEMA WMA และ $y_j \in \mathbb{R}$ แทนตัวแปรตามหรือตัวแปรตอบสนองสำหรับการทำนายราคาปิดของหุ้น เมื่อ $i=0,1,2,\dots,1152$ และ $j=i+1$

เมื่อได้กำหนดตัวแปรนำเข้าและตัวแปรตอบสนองของทั้ง 3 กรณีแล้วจึงนำมาแบ่งเป็นชุดข้อมูลสำหรับการฝึกและทดสอบในอัตราส่วน 70:30 นั่นคือ ชุดข้อมูลสำหรับการฝึกร้อยละ 70 และชุดข้อมูลสำหรับการทดสอบร้อยละ 30 ของข้อมูลทั้งหมดตามลำดับ จึงทำให้ได้ข้อมูลสำหรับการฝึกเป็นจำนวน 806 ค่า ซึ่งประกอบไปด้วยข้อมูลตั้งแต่วันที่ 30 พฤษภาคม พ.ศ. 2561 ถึงวันที่ 23 กรกฎาคม พ.ศ. 2564 และข้อมูลสำหรับการทดสอบเป็นจำนวน 345 ค่า ซึ่งประกอบไปด้วยข้อมูลตั้งแต่วันที่ 29

กรกฎาคม พ.ศ. 2564 ถึงวันที่ 30 ธันวาคม พ.ศ. 2565 หลังจากนั้นจึงทำการสร้างมาตรฐานชุดข้อมูล (Standardization) และแปลงมิติของตัวแปรนำเข้าสำหรับตัวแบบหน่วยความจำระยะสั้นระยะยาวให้เป็นแถวลำดับขนาด 3 มิติ



รูปที่ 2 กราฟแสดงราคาปิดของหุ้น GULF ตั้งแต่วันที่ 21 มีนาคม พ.ศ. 2561 ถึง 30 ธันวาคม พ.ศ. 2565

3.3 การสร้างตัวแบบ

ดังที่ได้กล่าวไปในการศึกษานี้ผู้วิจัยจะสร้างตัวแบบป่าสุ่ม และตัวแบบหน่วยความจำระยะสั้นระยะยาวสำหรับการทำนายราคาปิดของหุ้น GULF โดยจะทำการศึกษาทั้งหมด 3 กรณีด้วยกัน กรณีแรก Random Forest จะใช้ตัวแบบป่าสุ่มที่มีการหาค่าพารามิเตอร์ที่เหมาะสมโดยการใช้วิธี Randomized Search CV จากไลบรารี scikit-learn กรณีที่ 2 LSTM 1 จะใช้ตัวแบบหน่วยความจำระยะสั้นระยะยาวที่มีการหาค่าพารามิเตอร์ที่เหมาะสมโดยการใช้วิธี Bayesian Optimization จากไลบรารี Keras Tuner สำหรับกรณีสุดท้าย LSTM 2 จะคล้ายกับกรณีที่ 2 แต่ผู้วิจัยจะทำการปรับค่าฟังก์ชันกระตุ้นจากค่าดั้งเดิมนั่นคือ Tanh เป็น ELU ซึ่งทั้ง 3 กรณีจะใช้ข้อมูลราคาเปิด และราคาปิดในอดีตร่วมกับตัวชี้วัดเชิงเทคนิค EMA TEMA WMA สำหรับขั้นตอนการสร้างตัวแบบทั้ง มีดังนี้ 2

1) การสร้างตัวแบบป่าสุ่ม

ผู้วิจัยเลือกใช้ไลบรารี scikit-learn สำหรับการสร้างตัวแบบป่าสุ่มและใช้วิธี Randomized Search CV ในการหาค่าพารามิเตอร์ที่เหมาะสมสำหรับตัวแบบป่าสุ่ม ซึ่งในการใช้ Randomized Search CV นั้นจะต้องกำหนดรายการของค่าพารามิเตอร์ที่ต้องการหา ซึ่งผู้วิจัยกำหนดรายการของค่าพารามิเตอร์ดังตารางที่ 1 และกำหนดพารามิเตอร์ของ Randomized Search CV ประกอบด้วย estimator = RandomForestRegressor, cv = 6, n_jobs = -1, n_iter = 200

2) การสร้างตัวแบบหน่วยความจำระยะสั้นระยะยาว

ผู้วิจัยเลือกใช้ไลบรารี Keras สำหรับการสร้างตัวแบบหน่วยความจำระยะสั้นระยะยาวและใช้วิธี Bayesian Optimization ในการหาค่าพารามิเตอร์ที่เหมาะสมจากไลบรารี Keras Tuner โดยประยุกต์ใช้กับชุดข้อมูลสำหรับการฝึก ซึ่งมีรายละเอียดของค่าต่าง ๆ แสดงดังตารางที่ 2 และจะกำหนดค่าพารามิเตอร์ของ Bayesian Optimization ดัง นี้ objective = (“root_mean_squared_error”, direction=”min”), max_trials = 10, executions_per_trial = 3 และกำหนด validation_split = 0.1

ตารางที่ 1 ค่าพารามิเตอร์ของตัวแบบป่าสุ่มที่เป็นไปได้

พารามิเตอร์	ค่าของพารามิเตอร์ที่เป็นไปได้
n_estimators	20,50,100,500,1000
max_depth	10,20,30,40
min_samples_split	3, 5, 7, 9, 12
min_samples_leaf	1,2,3,4,5,6,7,8,9,10,11,12,13,14,15
bootstrap	True, False
random_state	1,2,30,42

ตารางที่ 2 ค่าพารามิเตอร์ของตัวแบบหน่วยความจำระยะสั้นระยะยาวที่เป็นไปได้

พารามิเตอร์	ค่าของพารามิเตอร์ที่เป็นไปได้
n_layers	(1,2,3,4,5)
units	(32,64,96,128,160)
dropout	(0.1,0.2,0.3,0.4,0.5)
optimizer	Adam
learning_rate	(0.0001,0.001,0.01)
loss	MSE
metrics	RMSE
epochs	(10,20)
batch_size	(16,30)

หลังจากที่ดำเนินการหาค่าพารามิเตอร์ที่เหมาะสมสำหรับทั้งสองตัวแบบในทั้ง 3 กรณีเสร็จสิ้นแล้วจึงนำตัวแบบที่ให้ผลลัพธ์แม่นยำมากที่สุดโดยพิจารณาจากค่า RMSE น้อยที่สุดมาประยุกต์ใช้กับชุดข้อมูลสำหรับการทดสอบ

3.4 การเปรียบเทียบความเหมาะสมของตัวแบบ

ในการศึกษานี้ผู้วิจัยจะวิเคราะห์และเปรียบเทียบความเหมาะสมของผลการทำนายราคาปิดของหุ้นที่ได้รับจากทั้ง 2 ตัวแบบใน 3 กรณีศึกษาที่ได้กล่าวมาแล้วก่อนหน้านี้ โดยพิจารณาจากค่าความคลาดเคลื่อน และกราฟแสดงการเปรียบเทียบระหว่างค่าจริงและค่าทำนาย ซึ่งค่าความคลาดเคลื่อนที่นำมาใช้ในการศึกษานี้ได้แก่ ค่ารากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error : RMSE) ค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error : MAPE) และค่าสัมประสิทธิ์การตัดสินใจ (Coefficient of Determination: R²) โดยมีนิยามดังนี้

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad (5)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (6)$$

และ
$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (7)$$

โดยที่ y_i คือ ค่าจริงที่ i
 \hat{y}_i คือ ค่าทำนายที่ i
 \bar{y} คือ ค่าเฉลี่ยของค่าจริง
 N คือ จำนวนข้อมูลทั้งหมด

4. ผลการดำเนินงานวิจัย

ในหัวข้อนี้จะกล่าวถึงผลการทำนายราคาปิดของหุ้น GULF สำหรับทั้ง 3 กรณีที่เป็นกรณีศึกษา พร้อมทั้งเปรียบเทียบและวิเคราะห์ผลการทำนายซึ่งมีรายละเอียดดังนี้

จากการประยุกต์ใช้ตัวแบบป่าสุ่ม และตัวแบบหน่วยความจำระยะสั้นระยะยาวกับชุดข้อมูลสำหรับการฝึกของหุ้น GULF (ข้อมูล ณ วันที่ 30 พฤษภาคม พ.ศ. 2561 ถึงวันที่ 23 กรกฎาคม พ.ศ. 2564) เพื่อคำนวณค่าพารามิเตอร์ที่เหมาะสมสำหรับตัวแบบทั้ง 3 กรณีนั้น ทำให้ได้ค่าพารามิเตอร์ที่เหมาะสมสำหรับแต่ละตัวแบบดังรายละเอียดในตารางที่ 3 และมีค่า RMSE แสดงในตารางที่ 4

ตารางที่ 3 ค่าพารามิเตอร์ที่เหมาะสมของตัวแบบสำหรับหุ้น GULF ในแต่ละกรณี

Model	Parameter
Random Forest	n_estimators = 1000, max_depth = 10, min_samples_split = 7, min_samples_leaf = 1, bootstrap = True, random_state = 2
LSTM 1	n_layers = 1, units = 160, Dropout_rate = 0, learning_rate = 0.01, epochs = 20, batch_size = 30
LSTM 2	n_layers = 1, units = 160, Dropout_rate = 0, learning_rate = 0.01, epochs = 10, batch_size = 30

ตารางที่ 4 ค่า RMSE ของตัวแบบทั้ง 3 กรณี จากการประยุกต์ใช้ตัวแบบกับชุดข้อมูลสำหรับการฝึก

Error	Random Forest	LSTM 1	LSTM 2
RMSE	0.3708	0.6939	0.7025

ซึ่งลักษณะสถาปัตยกรรมของตัวแบบหน่วยความจำระยะสั้นระยะยาวที่ใช้ในการทดลองสามารถสรุป (Model Summary) ได้ดังรูปที่ 3

Model: "sequential"

Layer (type)	Output Shape	Param #
lstm (LSTM)	(None, 1, 160)	106240
dropout (Dropout)	(None, 1, 160)	0
dense (Dense)	(None, 1, 1)	161

=====
 Total params: 106,401
 Trainable params: 106,401
 Non-trainable params: 0

รูปที่ 3 Model Summary ของตัวแบบหน่วยความจำระยะสั้นระยะยาว

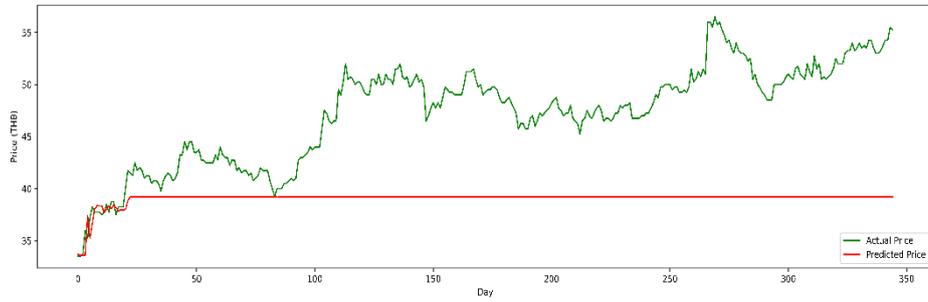
และจากการประยุกต์ใช้ค่าพารามิเตอร์ในตารางที่ 3 กับตัวแบบในแต่ละกรณีกับชุดข้อมูลสำหรับการทดสอบของหุ้น GULF (ข้อมูล ณ วันที่ 29 กรกฎาคม พ.ศ. 2564 ถึงวันที่ 30 ธันวาคม พ.ศ. 2565) ได้ค่า MAPE RMSE และ R² แสดงดังตารางที่ 5

ตารางที่ 5 ค่า MAPE RMSE และ R² ของตัวแบบทั้ง 3 กรณี จากการประยุกต์ใช้ตัวแบบกับชุดข้อมูลสำหรับการทดสอบ

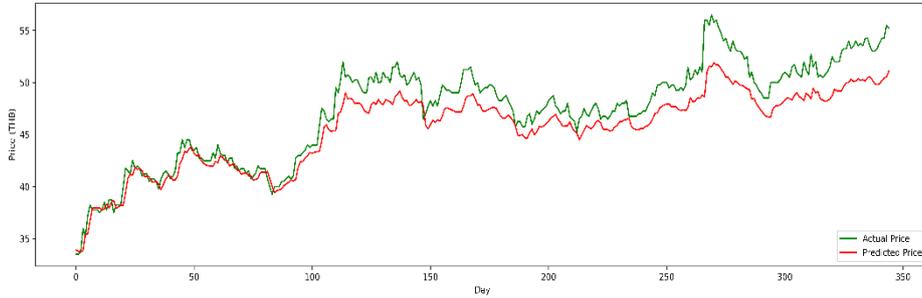
Error	Random Forest	LSTM 1	LSTM 2
MAPE	0.1654	0.0355	0.0115
RMSE	9.2876	2.1028	0.7723
R ²	-2.8607	0.8021	0.9733

จากตารางที่ 5 จะเห็นได้ว่าตัวแบบ LSTM 2 มีค่า MAPE และ RMSE น้อยที่สุดเมื่อเปรียบเทียบกับทั้ง 3 กรณี อีกทั้งยังมีค่า R² สูงที่สุด โดยสามารถแสดงกราฟการเปรียบเทียบระหว่างราคาปิดจริง และผลลัพธ์จากการประยุกต์ตัวแบบกับข้อมูลสำหรับชุดทดสอบเพื่อทำนายราคาปิดของหุ้น GULF ในแต่ละกรณีดังรูปที่ 4 ถึง 6 ตามลำดับ

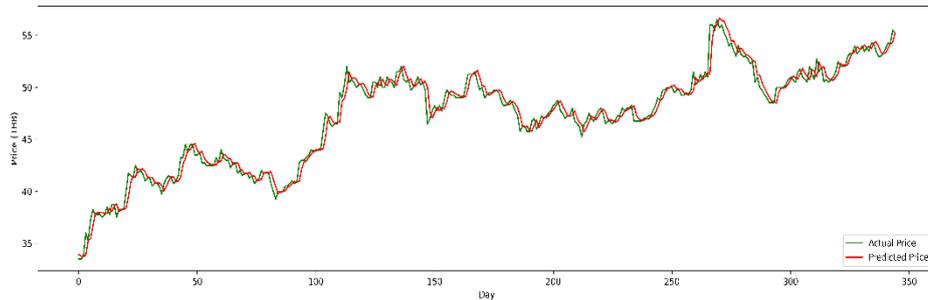
จากกราฟจะเห็นได้ว่าผลลัพธ์การทำนายราคาปิดของหุ้น GULF ที่ได้จากตัวแบบ LSTM 2 นั้นมีลักษณะใกล้เคียงกับราคาปิดจริงมากที่สุด และเมื่อเปรียบเทียบกราฟแสดงค่าทำนายของราคาหุ้น GULF ที่ได้จากตัวแบบทั้ง 3 กรณีดังรูปที่ 7 เห็นชัดว่า ผลลัพธ์จากตัวแบบ Random Forest นั้นมีลักษณะของกราฟที่ไม่สอดคล้องกับราคาปิดจริง และเมื่อเปรียบเทียบกราฟแสดงผลลัพธ์จากตัวแบบ LSTM 1 และ LSTM 2 นั้นพบว่า มีลักษณะของกราฟสอดคล้องกับราคาปิดจริง แต่ตัวแบบ LSTM 2 ให้ผลลัพธ์ที่มีลักษณะของกราฟใกล้เคียงกับราคาปิดจริงมากที่สุด ซึ่งสอดคล้องกับค่า MAPE และ RMSE ของตัวแบบ LSTM 2 ที่มีค่าน้อยที่สุด และมีค่า R² สูงที่สุด



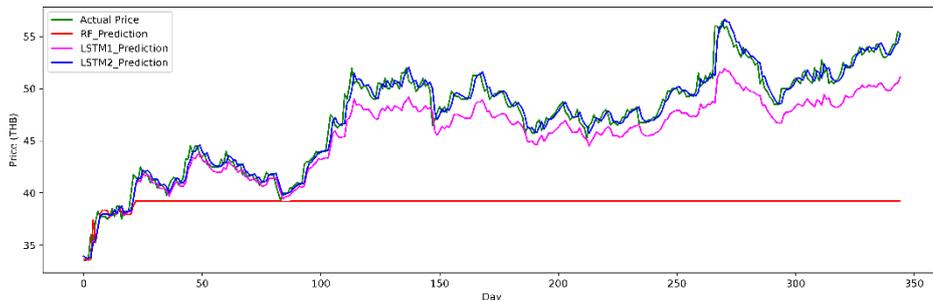
รูปที่ 4 กราฟเปรียบเทียบราคาปิดของหุ้น GULF ระหว่างค่าจริงและทำนายสำหรับตัวแบบ Random Forest



รูปที่ 5 กราฟเปรียบเทียบราคาปิดของหุ้น GULF ระหว่างค่าจริงและทำนายสำหรับตัวแบบ LSTM 1



รูปที่ 6 กราฟเปรียบเทียบราคาปิดของหุ้น GULF ระหว่างค่าจริงและทำนายสำหรับตัวแบบ LSTM 2



รูปที่ 7 กราฟเปรียบเทียบราคาปิดของหุ้น GULF ระหว่างค่าจริงและค่าทำนายจากทั้ง กรณีย 3

5.สรุปและอภิปรายผล

งานวิจัยนี้ได้นำเสนอผลการศึกษาศักยภาพในการทำนายราคาปิดของหุ้น GULF โดยการใช้ตัวแบบป่าสุ่มและตัวแบบหน่วยความจำระยะสั้นระยะยาว ซึ่งมีกรณีศึกษาทั้งหมด 3 กรณี ประกอบด้วย กรณีแรกการใช้ตัวแบบป่าสุ่มที่มีการหาค่าพารามิเตอร์ที่เหมาะสม หรือเรียกว่าตัวแบบ Random Forest กรณีที่สองการใช้ตัวแบบหน่วยความจำระยะสั้นระยะยาวที่มีการหาค่าพารามิเตอร์ที่เหมาะสม หรือเรียกว่าตัวแบบ LSTM 1 และกรณีที่สาม

จะคล้ายกับกรณีที่สองแต่ทำการปรับค่าฟังก์ชันกระตุ้นจากฟังก์ชัน Tanh เป็นฟังก์ชัน ELU หรือเรียกว่าตัวแบบ LSTM 2 โดยใช้ชุดข้อมูลพื้นฐานในอดีตของหุ้นที่ประกอบด้วย ราคาเปิด และราคาปิดของหุ้น GULF ตั้งแต่วันที่ 21 มีนาคม พ.ศ. 2561 ถึง 31 ธันวาคม พ.ศ. 2565 ร่วมกับตัวชี้วัดเชิงเทคนิค ได้แก่ EMA TEMA และ WMA

ผลการศึกษา พบว่า ตัวแบบหน่วยความจำระยะสั้นระยะยาวทั้งสองกรณี (LSTM 1 และ LSTM 2) นั้นมีประสิทธิภาพในการทำนายราคาปิดของหุ้น GULF

มากกว่าตัวแบบป่าสุ่ม (Random Forest) ดังจะเห็นได้จากการมีค่า MAPE และ RMSE ที่น้อยกว่า และมีค่า R^2 สูงกว่า ตลอดจนกราฟแสดงค่าทำนายราคาปิดของหุ้นมีลักษณะใกล้เคียงกับราคาปิดจริงมากกว่า และเมื่อนำผลลัพธ์ที่ได้จากตัวแบบหน่วยความจำระยะสั้นระยะยาวทั้งสองกรณีมาเปรียบเทียบกัน พบว่าตัวแบบ LSTM 2 ที่มีการปรับใช้ฟังก์ชัน ELU เป็นฟังก์ชันกระตุ้นแทนฟังก์ชัน Tanh นั้นมีประสิทธิภาพในการทำนายราคาปิดของหุ้น GULF มากกว่าตัวแบบ LSTM 1 อีกทั้งยังมีประสิทธิภาพมากที่สุดเมื่อเปรียบเทียบกันทั้งสามกรณี ดังนั้น สามารถสรุปได้ว่าตัวแบบหน่วยความจำระยะสั้นระยะยาวนั้นมีประสิทธิภาพในการทำนายราคาปิดของหุ้น GULF ที่มีลักษณะราคาอยู่ในแนวโน้มขาขึ้นระยะยาว หรือ Uptrend นับตั้งแต่เริ่มทำการซื้อขายในตลาดหลักทรัพย์แห่งประเทศไทย และการเลือกใช้ฟังก์ชัน ELU เป็นฟังก์ชันกระตุ้นสำหรับตัวแบบหน่วยความจำระยะสั้นระยะยาวนั้น ส่งผลให้ได้ตัวแบบที่มีประสิทธิภาพมากขึ้น ซึ่งสามารถนำไปใช้ในการประเมินราคาหุ้นเพื่อเป็นข้อมูลส่วนหนึ่งสำหรับประกอบการตัดสินใจลงทุนในหุ้นได้

นอกจากนี้ผู้วิจัยได้นำตัวแบบทั้ง 3 กรณีมาปรับใช้กับหุ้นที่มีลักษณะแนวโน้มของราคาเคลื่อนที่ออกข้าง (Sideway Trend) และหุ้นวัฏจักร (Cyclical Trend) ในช่วงเวลาเดียวกัน เช่น BCP และ PTTEP พบว่าตัวแบบ LSTM 2 ยังคงมีประสิทธิภาพในการทำนายราคาปิดของหุ้นเหนือกว่าตัวแบบอื่นจากทั้ง 3 กรณีที่ได้นำเสนอ

สำหรับงานวิจัยในอนาคต หากนำข้อมูลปัจจัยพื้นฐานหรือตัวชี้วัดเชิงเทคนิคเพิ่มเติมเข้ามาร่วมพิจารณาในการกำหนดตัวแปรอิสระอาจช่วยเพิ่มประสิทธิภาพของตัวแบบมากขึ้นไปอีก ตลอดไปจนถึงการตรวจสอบประสิทธิภาพของตัวแบบในลักษณะดังเช่นในการศึกษานี้กับหุ้นอื่นที่มีลักษณะแนวโน้มของราคาหุ้นคล้ายกัน เพื่อการประยุกต์ใช้ประกอบการตัดสินใจลงทุนในอนาคต

เอกสารอ้างอิง

Bhandari, H. N., Rimal, B., Pokhrel, N. R., Rimal, R., Dahal, K. R., & Khatri, R. K. (2022). Predicting stock market index using LSTM. *Machine Learning with Applications*, 9, 100320. <https://doi.org/10.1016/j.mlwa.2022.100320>

Boongasame, L. (2021). *DEEP LEARNING*. Paper Print Publishing.

Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>

Chollet, F., & others. (2015). Keras. Retrieved from <https://keras.io>

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. Retrieved from <http://www.deeplearningbook.org>

Goswami, S., & Yadav, S. (2021). Stock Market Prediction Using Deep Learning LSTM Model. *2021 International Conference on Smart Generation Computing, Communication and Networking (SMART GENCON)*, Pune, India, 2021, pp. 1-5. <https://doi.org/10.1109/SMARTGENCON51891.2021.9645837>.

Hansun, S. (2013). A new approach of moving average method in time series analysis. *2013 Conference on New Media Studies (CoNMedia)*.

Huang, J.-Z., Huang, W., & Ni, J. (2019). Predicting bitcoin returns using high-dimensional technical indicators. *The Journal of Finance and Data Science*, 5(3), 140-155. <https://doi.org/10.1016/j.jfds.2018.10.001>

Kaewmaha, W., & Punyachitporn, V. (2021). Predicting Stock Return Using Machine Learning. *Journal of Innovation in Business, Management, and Social Sciences*, 2(3), 108-123.

M. R. Vargas, B. S. L. P. de Lima and A. G. Evsukoff. (2017). Deep learning for stock market prediction from financial news articles. In *2017 IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications (CIVEMSA)*, Annecy, France, 2017, pp. 60-65. <https://doi.org/10.1109/CIVEMSA.2017.7995302>.

Mulloy, P. G. (1994). Smoothing Data With Less Lag. *Technical Analysis of Stocks & Commodities*, 12(2), 72-80.

Pardeshi, Y., & Kale, P. (2021). Technical Analysis Indicators in Stock Market Using Machine Learning: A Comparative Analysis. In *12th International Conference on Computing Communication and Networking Technologies (ICCCNT)*.

Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, E. (2011). Scikit-learn: Machine learning in Python. *the Journal of machine Learning research*, 12, 2825-2830.

Saraubon, K. (2022). *Learn AI: Deep Learning with Python*. Intermedia Publishing.

Schmidhuber, J., & Hochreiter, S. (1997). Long short-term memory. *Neural Comput*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>

Vijh, M., Chandola, D., Tikkiwal, V. A., & Kumar, A. (2020). Stock Closing Price Prediction using Machine Learning Techniques. *Procedia Computer Science*, 167, 599-606. <https://doi.org/10.1016/j.procs.2020.03.326>