



การพยากรณ์ดัชนีราคาตลาดหุ้นโดยใช้ Wavelet Transform, LSTM, และ Bi-LSTM

Forecasting Stock Market Indices Using Wavelet Transform, LSTM, and Bi-LSTM

ปิยศรัณย์ ลิขิตาภรณ์¹ สมพร ปันโกษา² และ บำรุง พ่วงเกิด³

¹สาขาวิชาวิศวกรรมการเงิน คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยหอการค้าไทย, 1910531201003@live4.utcc.ac.th

²คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยหอการค้าไทย, sompon_punpocha@yahoo.com

³ภาควิชาวิศวกรรมเครื่องกล คณะวิศวกรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง, bumroong.pu@kmitl.ac.th

บทคัดย่อ

การศึกษานี้มีวัตถุประสงค์เพื่อศึกษาประสิทธิภาพของการพยากรณ์ดัชนีราคาตลาดหุ้น โดยใช้โครงข่ายประสาทเทียม LSTM และ Bi-LSTM และเพื่อสร้างแบบจำลองเพื่อหาผลลัพธ์การพยากรณ์ที่มีประสิทธิภาพ และเพื่อศึกษาคุณสมบัติในการลดทอนสัญญาณรบกวนของการแปลงสัญญาณเฉพาะ (Wavelet Transform) ที่ส่งผลต่อความเร็วของขั้นตอนการเรียนรู้ของโครงข่ายประสาทเทียมทั้งสอง โดยข้อมูลที่นำมาใช้ในการศึกษา คือ ราคาเปิด ราคาปิด ราคาสูงสุด ราคาต่ำสุด และปริมาณการซื้อขาย ซึ่งเป็นข้อมูลแบบรายวันย้อนหลัง 32 ปี 8 เดือน ตั้งแต่วันที่ 1 มกราคม พ.ศ.2528 ถึง 31 สิงหาคม พ.ศ.2561 สำหรับดัชนีราคาตลาดหุ้น S&P 500, Nikkei 225 และ NASDAQ Composite และย้อนหลัง 30 ปี 8 เดือน ตั้งแต่วันที่ 1 มกราคม พ.ศ.2530 ถึง 31 สิงหาคม พ.ศ.2561 สำหรับดัชนีราคาตลาดหุ้น Hang Seng Index

จากการศึกษาพบว่าโครงข่ายประสาทเทียม Bi-LSTM ให้ประสิทธิภาพของการพยากรณ์ที่ดีกว่าโครงข่ายประสาทเทียม LSTM ไม่ว่าข้อมูลดัชนีราคาตลาดหุ้นจะผ่านการแปลงสัญญาณเฉพาะ (Wavelet) หรือไม่ผ่านการแปลงสัญญาณเฉพาะ (Non-wavelet) มาก่อนก็ตาม โดยได้ค่า Root Mean Square Error (RMSE) ของ S&P 500, Nikkei 225, NASDAQ Composite, และ Hang Seng Index ของ Wavelet (LSTM : Bi-LSTM) ดังนี้ 0.01646 : 0.01585, 0.00539 : 0.00517, 0.01596 : 0.01351, และ 0.01011 : 0.00873 ตามลำดับ และเช่นกันสำหรับ Non-wavelet ได้ค่าดังนี้ 0.01348 : 0.01347, 0.00551 : 0.00518, 0.01211 : 0.00937, และ 0.01033 : 0.01016 ตามลำดับ อีกทั้งการใช้ Wavelet กรองข้อมูลก่อนสร้างแบบจำลองโครงข่ายประสาทเทียมยังสามารถทำให้โครงข่ายประสาทเทียมเรียนรู้ข้อมูลได้รวดเร็วยิ่งขึ้น

แต่เมื่อพิจารณาผลประสิทธิภาพของโครงข่ายประสาทเทียมของข้อมูลที่ผ่านการแปลงสัญญาณเฉพาะแล้วผลลัพธ์ที่ได้กลับไม่ได้ดีมากนัก กล่าวคือ Nikkei 225 และ Hang Seng Index ให้ผลประสิทธิภาพที่ดีกว่าบนข้อมูลแบบ Wavelet ซึ่งได้ค่า RMSE ของ Bi-LSTM เท่ากับ 0.00518 : 0.00517 และ 0.01016 : 0.00873 (Non-wavelet : Wavelet) ตามลำดับ แต่สำหรับ S&P 500 และ NASDAQ Composite ให้ผลประสิทธิภาพที่ดีกว่าบนข้อมูลแบบ Non-wavelet ซึ่งได้ค่า RMSE ของ Bi-LSTM เท่ากับ 0.01347 : 0.01585 และ 0.00937 : 0.01351 ตามลำดับ

คำสำคัญ: การแปลงสัญญาณเฉพาะ, LSTM, Bi-LSTM, ดัชนีราคาตลาดหุ้น



ABSTRACT

This study aims to study the efficiency of forecasting stock market indices using LSTM and Bi-LSTM neural networks and to construct models for effective forecasting outcomes. Also, it aims to study the noise attenuation of wavelet transforms (Wavelet) affecting the speed of learning process of both neural networks. The used data was daily which included open price, close price, high price, low price, and trading volume. It was 32 years 8 months from January 1, 1985 to August 31, 2018 for the S&P 500, Nikkei 225, and NASDAQ Composite. Another, the Hang Seng Index, was 30 years 8 months from January 1, 1987 to August 31, 2018.

These studies have shown that Bi-LSTM neural networks provide better forecasting performance than LSTM neural networks whether the data undergoes Wavelet or not. The root-mean-square error (RMSE) of Wavelet's S&P 500, Nikkei 225, NASDAQ Composite, and Hang Seng Index (LSTM : Bi-LSTM) were obtained as 0.01646 : 0.01585, 0.00539 : 0.00517, 0.01596 : 0.01351, and 0.01011 : 0.00873, respectively. For Non-wavelet, the RMSE were 0.01348 : 0.01347, 0.00551 : 0.00518, 0.01211 : 0.00937, and 0.01033 : 0.01016, respectively. In addition, using the Wavelet to filter the data before constructing both neural network models can enable neural networks to learn information faster than usual.

However, when considering the efficiency of neural networks via the Wavelet data, the results were moderate: the Nikkei 225 and Hang Seng Index performed better on the Wavelet data, the RMSE of Bi-LSTM were 0.00518 : 0.00517 and 0.01016 : 0.00873 (Non-wavelet : Wavelet), respectively. The S&P 500 and NASDAQ Composite performed better on Non-wavelet data, Bi-LSTM's RMSE were 0.01347 : 0.01585 and 0.00937 : 0.01351, respectively.

Keywords: Wavelet Transform, LSTM, Bi-LSTM, Stock Market Indices

1. บทนำ

การพยากรณ์ หรือการคาดคะเน เป็นการคาดการณ์ถึงสิ่งที่จะเกิดขึ้นได้ในอนาคต โดยประโยชน์ของการพยากรณ์ คือ การวางแผนเพื่อรับมือหรือเตรียมการป้องกัน และการวางแผนเพื่อชัยชนะหรือสามารถทำผลกำไรได้จากการลงทุน แต่ทว่าการคาดคะเนนั้น ผลสัมฤทธิ์ของโอกาสที่จะเกิดขึ้นจริงหนึ่งร้อยเปอร์เซ็นต์มีน้อยมาก เนื่องจากมีผลกระทบต่างๆ เข้ามาเกี่ยวข้องด้วย เช่น สภาวะแวดล้อมทางธรรมชาติ ด้านเศรษฐกิจ และเหตุการณ์ที่ไม่ได้คาดคิด (Hochreiter & Schmidhuber, 1997) ยกตัวอย่างเช่น ผู้ลงทุนต้องการพยากรณ์ราคาของมะละกอ แต่มีปัจจัยเรื่องฤดูกาลและสภาพอากาศเข้ามาเกี่ยวข้องด้วย ดังนั้นความแม่นยำและความคลาดเคลื่อนจึงเป็นตัววัดที่สำคัญในการกำหนดประสิทธิภาพของการพยากรณ์ (LeBaron & Weigend, 1998) อีกทั้งการพยากรณ์แนวโน้มของราคา ไม่ว่าจะเป็นสินทรัพย์ใดก็ตาม ถือเป็นหนึ่งวิธีการที่สามารถช่วยเหลือหรือเพิ่มประสิทธิภาพให้กับนักลงทุนได้

ในปัจจุบันได้มีการนำแบบจำลองโครงข่ายประสาทเทียม (Neural Network) มาศึกษาค้นคว้าและนำมาใช้ในงานวิจัยต่างๆ เพิ่มมากขึ้น โดยโครงข่ายประสาทเทียม คือ โมเดลทางคณิตศาสตร์ ที่มีแนวคิดริเริ่มมาจากการศึกษาโครงข่ายไฟฟ้าชีวภาพ (Bioelectric Network) ในสมอง ซึ่งประกอบด้วยเซลล์ประสาท (Nerve cell or Neurons) และจุดประสานประสาท (Synapses) ที่ทำงานร่วมกัน (Caudill, 1987; Pompatcharapong, 2008) ด้วยเหตุของ



ความสามารถนี้ จึงทำให้โครงข่ายประสาทเทียมมีความสามารถในการเรียนรู้ จดจำ และจำลองข้อมูลที่ป้อนให้ไว้จากการฝึกสอน ได้เป็นอย่างดี ซึ่งผลลัพธ์ที่ได้ก็เป็นที่น่าพอใจสำหรับผู้ศึกษาค้นคว้า จึงทำให้มีงานวิจัยที่ตีพิมพ์เกี่ยวกับเรื่อง โครงข่ายประสาทเทียมออกมาอย่างต่อเนื่อง โดยโครงข่ายประสาทเทียมถูกพัฒนาต่อๆ มา เนื่องจากโครงข่ายประสาทเทียมชนิดก่อนมีข้อจำกัดบางประการที่ไม่เหมาะต่อการใช้งาน จนกระทั่งก่อเกิดโครงข่ายประสาทเทียมชนิดหนึ่งชื่อ Recurrent Neural Network (RNN) ซึ่งเป็นหนึ่งในโครงข่ายประสาทเทียมที่ได้รับความนิยม เนื่องจากสามารถแก้ปัญหาเรื่องอนุกรมเวลา (Time Series) ได้ โดยจุดเด่นของ RNN คือ การจัดการกับชุดข้อมูลขนาดใหญ่ที่ถูกเก็บอย่างต่อเนื่อง และตัดสินใจได้ดีกว่าโครงข่ายประสาทเทียมชนิดก่อนหน้า เพราะมีการตัดสินใจอีกครั้งหนึ่ง กล่าวคือ การทำ Recurrent (Limkonchotiwat, 2019) แต่ทว่า RNN ก็เกิดปัญหากับค่า Gradient ที่มีค่าน้อยลงจากการทำงานของ Back-propagation จึงมีการแก้ไขและพัฒนาเป็นโครงข่ายประสาทเทียมชนิดใหม่ขึ้นชื่อ Long Short-Term Memory (LSTM) โดยสถาปัตยกรรมของ LSTM จะประกอบด้วยส่วนต่างๆ ได้แก่ การลืมข้อมูล การเขียนข้อมูล การอัปเดตข้อมูล และการอ่านข้อมูล หลักการทำงานของ LSTM นั้น สามารถเลือกได้ว่าข้อมูลประเภทไหนควรจะจดจำ ข้อมูลประเภทไหนควรจะกำจัดออกไป ซึ่งแตกต่างจาก RNN ที่มี Tan Hyperbolic (tanh) เพียงฟังก์ชันเดียวเท่านั้น (Hochreiter & Schmidhuber, 1997; Olah, 2015)

Bi-directional LSTM หรือ Bi-LSTM เป็นอีกรูปแบบหนึ่งของ LSTM มีหลักการทำงานเหมือนกับ LSTM เพียงแต่มีการเพิ่มหนึ่งฟังก์ชันการทำงาน คือ การป้อนข้อมูลแบบย้อนกลับเข้าไปด้วย นั่นหมายความว่า ขั้นตอนในการทดสอบแบบ Bi-LSTM จะช้ากว่า LSTM (Siarni-Namini et al., 2019)

ด้วยเหตุของความล่าช้า ผู้ศึกษาจึงได้นำทฤษฎีเวฟเล็ต (Wavelet Theory) มาใช้ ซึ่งทฤษฎีเวฟเล็ต คือ ทฤษฎีทางคณิตศาสตร์ ที่เกิดขึ้นเนื่องจากการที่ Sine Wave ไม่สามารถระบุสัญญาณในช่วงเวลาที่เจาะจงได้ (Develeker, 2016) ดังนั้นทฤษฎีเวฟเล็ตจึงใช้อธิบายโครงสร้างของระบบสัญญาณที่มีสัญญาณเฉพาะ (Wavelet) มารวมกันหลายๆ สัญญาณ (Young, 1993) โดยชนิดของ Wavelet ที่ผู้ศึกษาเลือกนำมาใช้คือ Haar Wavelet (Haar, 1910) ซึ่งมีคุณสมบัติในการลดระยะเวลาในการคำนวณ เนื่องจากมีความยาวรองรับขนาดเล็ก อีกทั้งยังเป็นสัญญาณเฉพาะแบบสมมาตร ซึ่งช่วยลดอัตราการใช้หน่วยความจำในการวิเคราะห์สัญญาณและการสร้างสัญญาณใหม่ กล่าวคือ สัญญาณที่แท้จริงยังคงสามารถเรียกคืนได้อย่างมาก แม้ว่าจะลดสัญญาณรบกวนออกไปแล้วก็ตาม (Liang et al., 2019)

จากที่กล่าวมาข้างต้นจึงทำให้มีการศึกษานี้ขึ้น โดยในการศึกษานี้ได้ทำการพยากรณ์ดัชนีราคาตลาดหุ้นโดยใช้ Wavelet Transform กับโครงข่ายประสาทเทียม LSTM และ Bi-LSTM โดยได้นำหลักการของ Wavelet Transform เข้ามาจัดการกับข้อมูลก่อนการทดสอบในขั้นตอนของ Neural Network และเพื่อต้องการพยากรณ์แนวโน้มของดัชนีราคาตลาดหุ้นว่าจะเป็นไปในทิศทางไหน

2. วัตถุประสงค์การวิจัย

1. เพื่อศึกษาประสิทธิภาพของการพยากรณ์ดัชนีราคาตลาดหุ้น โดยใช้โครงข่ายประสาทเทียม LSTM และ Bi-LSTM จากการใช้ข้อมูลดัชนีราคาตลาดหุ้นและข้อมูลปริมาณซื้อขายในอดีต
2. เพื่อสร้างแบบจำลองเพื่อหาผลลัพธ์การพยากรณ์ที่มีประสิทธิภาพ และเพื่อศึกษาคุณสมบัติในการลดทอนสัญญาณรบกวนของการแปลงสัญญาณเฉพาะ (Wavelet Transform) ที่ส่งผลต่อความเร็วของขั้นตอนการเรียนรู้ของโครงข่ายประสาทเทียมทั้งสอง



3. การดำเนินการวิจัย

การศึกษานี้ได้ทำการรวบรวมข้อมูลดัชนีราคาตลาดหุ้นจาก Yahoo Finance ซึ่งรายละเอียดของข้อมูลที่รวบรวม คือ ข้อมูลราคาเปิด ราคาปิด ราคาสูงสุด ราคาต่ำสุด และปริมาณการซื้อขายแบบรายวันย้อนหลัง 32 ปี 8 เดือน ตั้งแต่วันที่ 1 มกราคม พ.ศ.2528 ถึง 31 สิงหาคม พ.ศ.2561 สำหรับดัชนีราคาตลาดหุ้น S&P 500 (GSPC), Nikkei 225 (N225) และ NASDAQ Composite (IXIC) และย้อนหลัง 30 ปี 8 เดือน ตั้งแต่วันที่ 1 มกราคม พ.ศ.2530 ถึง 31 สิงหาคม พ.ศ.2561 สำหรับดัชนีราคาตลาดหุ้น Hang Seng Index (HSI)

3.1 วิธีการประมวลผลและวิเคราะห์ข้อมูล

การดำเนินการในขั้นตอนการแปลงข้อมูล การเรียนรู้ การทดสอบ และการวัดประสิทธิภาพของโครงข่ายประสาทเทียมสำหรับการศึกษานี้ ได้ดำเนินการผ่าน Cloud ของ Google หรือรู้จักในชื่อ [Google Colab](#) ที่ให้บริการโฮสต์โปรแกรม Jupyter Notebook สำหรับภาษา Python ที่มีติดตั้ง Library ที่จำเป็นสำหรับการใช้งานเป็นที่เรียบร้อย ทั้งนี้ผู้ศึกษาได้เลือกใช้การประมวลผลประเภท GPU และ High-RAM เพราะทำให้ได้ผลลัพธ์ที่รวดเร็วกว่าการประมวลผลประเภท CPU (McNally et al., 2018)

3.1.1 การแปลงข้อมูล

เนื่องด้วยรายละเอียดของข้อมูลที่รวบรวมมีตั้งแต่หลักร้อยจนถึงหลักล้าน จึงเป็นความซับซ้อนสำหรับระบบคอมพิวเตอร์และโครงข่ายประสาทเทียม ดังนั้นเพื่อแก้ไขความซับซ้อนนี้ ผู้ศึกษาจึงทำการแปลงข้อมูลให้มีค่าอยู่ระหว่าง 0 ถึง 1 จากนั้นทำการกรองข้อมูลเพิ่มเติมด้วยการแปลงสัญญาณเฉพาะ (Wavelet transform) ด้วย Haar Wavelet ที่ระดับ 2 และใช้เกณฑ์การกรองสัญญาณเพื่อกำจัด Noise ออกไป คือ ระดับความสูงเฉลี่ยของสัญญาณที่มากกว่า 65% (Taspinar, 2018)

3.1.2 การเรียนรู้ การทดสอบ และการวัดประสิทธิภาพ

ขั้นตอนการเรียนรู้และการทดสอบสำหรับการศึกษานี้ ได้แบ่งประเภทการทดลองออกเป็น 2 ประเภท คือ ข้อมูลที่ไม่ผ่านการแปลงสัญญาณเฉพาะ (Non-wavelet) และข้อมูลผ่านการแปลงสัญญาณเฉพาะ (Wavelet) โดยแต่ละประเภทได้ทำการทดลอง 3 ครั้งต่อ 1 ดัชนีราคาตลาดหุ้น

การสร้างแบบจำลองโครงข่ายประสาทเทียมในการศึกษานี้ ได้ทำการแบ่งชุดข้อมูลออกเป็น 2 ชุด คือ ชุดข้อมูลสำหรับการเรียนรู้ และชุดข้อมูลสำหรับการทดสอบ โดยใช้อัตราส่วน 70 : 30 (Siarni-Namini et al., 2019) ตามลำดับ ซึ่งแสดงจำนวนของชุดข้อมูลดังตารางที่ 1

ตารางที่ 1 จำนวนของชุดข้อมูล

| Index | จำนวน | |
|-------------------------|------------------|----------------------------------|
| | ชุดข้อมูลทั้งหมด | ชุดข้อมูลสำหรับการเรียนรู้ (70%) |
| S&P 500 (GSPC) | 8423 | 5896 |
| Nikkei 225 (N225) | 8216 | 5751 |
| NASDAQ Composite (IXIC) | 8423 | 5896 |
| Hang Seng Index (HSI) | 7722 | 5405 |



ตารางที่ 2 ตัวแปรและค่าที่ใช้สำหรับการเรียนรู้ การทดสอบ และการวัดประสิทธิภาพของโครงข่าย

| ตัวแปร | ค่าที่ใช้ |
|--------------|-----------|
| Lookback | 5 |
| Hidden Units | 45 |
| Epochs | 100 |
| Batch Size | 32 |
| Performance | RMSE |

ตัวแปรและค่าที่ใช้สำหรับการเรียนรู้ การทดสอบ และการวัดประสิทธิภาพของโครงข่ายประสาทเทียม ดังแสดงในตารางที่ 2 สามารถอธิบายได้ดังนี้

1. Lookback = 5

จากการสรุปผลของงานวิจัยของ Saud & Shakya (2020) ได้กล่าวไว้ว่า ค่าที่เหมาะสมสำหรับการนำมาใช้กับโครงข่ายประสาทเทียมชนิด LSTM คือ น้อยกว่า 5 แต่งานวิจัยกลับไม่ได้บอกอย่างน้อยว่า 5 และดีที่สุดคืออะไร ดังนั้นผู้ศึกษาจึงได้ทำการทดลองเพิ่มเติมเกี่ยวกับเรื่องนี้ และผลลัพธ์ที่ดีที่สุด คือ 5 โดยพิจารณาจากการวัดความคลาดเคลื่อนแบบ RMSE จำนวน 3 ครั้งต่อ Lookback 1 ค่า บนดัชนีราคาตลาดหุ้น S&P 500 และตรวจสอบประสิทธิภาพของ Lookback แต่ละค่าด้วยการหาค่าเฉลี่ย

2. Hidden Units = 45

จากข้อมูลที่รวบรวมสำหรับการศึกษานี้ คือ ข้อมูลราคาเปิด ราคาปิด ราคาสูงสุด ราคาต่ำสุด และปริมาณการซื้อขาย ซึ่งก็คือข้อมูลอินพุตทั้งห้า แต่ทว่าข้อมูลทั้งห้านี้ได้มีการกรองข้อมูลด้วย Wavelet Transform จากขั้นตอนการแปลงข้อมูลมาก่อนแล้ว ซึ่งทำให้ 1 สัญญาณเกิดเป็น 3 สัญญาณแทน ฉะนั้นอินพุตทั้งหมดจะเท่ากับ $5 \times 3 = 15$ สัญญาณ ด้วยเหตุนี้จึงกำหนดให้ Hidden Units มีค่ามากกว่าอินพุตทั้งหมดอีก 3 เท่า ซึ่งมีค่าเท่ากับ $15 \times 3 = 45$ เพื่อให้โครงข่ายมีจำนวนโนดหรือนิวรอนเพิ่มขึ้น เพื่อผลลัพธ์ที่มีความละเอียดมากยิ่งขึ้น

3. Epochs = 100

กำหนดให้จำนวนรอบของการเรียนรู้เท่ากับ 100 เนื่องจากต้องการลดระยะเวลาของขั้นตอนการเรียนรู้ลง (McNally et al., 2018) อีกทั้งผลลัพธ์ที่ได้ยังอยู่ในระดับที่ดีเป็นที่น่าพอใจ

4. Batch Size = 32

เนื่องจากจำนวนรอบของการเรียนรู้ไม่มากนัก จึงกำหนดให้ Batch Size เท่ากับ 32 เพราะไม่มีความจำเป็นที่ต้องใช้ทรัพยากรของระบบที่เกินไปกว่าความต้องการใช้งานจริง

5. Performance = RMSE

การวัดประสิทธิภาพของโครงข่ายประสาทเทียมสำหรับการศึกษานี้ ได้ใช้วิธีการวัดความคลาดเคลื่อนแบบ RMSE โดยหาค่าเฉลี่ยจากการทดลองทั้ง 3 ครั้ง



4. ผลการวิจัย

จากการทดลองเพิ่มเติมเกี่ยวกับ Lookback ซึ่งผลลัพธ์ที่เหมาะสมเพื่อใช้ในการพยากรณ์ดัชนีราคาตลาดหุ้น โดยใช้ Wavelet Transform, LSTM และ Bi-LSTM นั้น ดังแสดงในตารางที่ 3 โดยพบว่า Lookback ที่มีค่าเท่ากับ 5 ให้ค่าเฉลี่ยการวัดความคลาดเคลื่อนดีที่สุด

ตารางที่ 3 สรุปผลการทดลอง Lookback บนดัชนีราคาตลาดหุ้น S&P 500

| Index | LSTM | |
|-------------------|----------|--------------|
| | Lookback | Average RMSE |
| S&P 500 (GSPC) | 5 | 0.01646 |
| | 4 | 0.02292 |
| | 3 | 0.02126 |
| | 2 | 0.01830 |
| | 1 | 0.02078 |

จากขั้นตอนการเรียนรู้ข้อมูลของโครงข่ายประสาทเทียม LSTM และ Bi-LSTM ทำให้ทราบว่า Wavelet Transform มีผลต่อระยะเวลาของขั้นตอนการเรียนรู้ข้อมูล โดยได้แสดงผลดังตารางที่ 4

ตารางที่ 4 สรุปผลระยะเวลาของขั้นตอนการเรียนรู้ข้อมูลของ LSTM และ Bi-LSTM ของข้อมูลแบบ Non-wavelet และ Wavelet


| Index | Non-wavelet | | Wavelet | |
|----------------------------|-----------------------------|-----------------------------|-----------------------------|-----------------------------|
| | LSTM | Bi-LSTM | LSTM | Bi-LSTM |
| | Avg. training time (sec) | Avg. training time (sec) | Avg. training time (sec) | Avg. training time (sec) |
| S&P 500 (GSPC) | 83.9332 | 153.3957 | 84.2038 | 149.8405 |
| Nikkei 225 (N225) | 79.7947 | 149.3873 | 78.4381 | 146.1888 |
| NASDAQ Composite (IXIC) | 83.0827 | 153.4417 | 79.3768 | 150.0174 |
| Hang Seng Index (HSI) | 76.3763 | 141.5625 | 73.2405 | 138.5663 |



ตารางที่ 5 สรุปผลประสิทธิภาพของ LSTM และ Bi-LSTM ของข้อมูลแบบ Non-wavelet และ Wavelet

| Index | Non-wavelet | | Wavelet | |
|----------------------------|-------------|-----------|-----------|-----------|
| | LSTM | Bi-LSTM | LSTM | Bi-LSTM |
| | Avg. RMSE | Avg. RMSE | Avg. RMSE | Avg. RMSE |
| S&P 500 (GSPC) | 0.01348 | 0.01347 | 0.01646 | 0.01585 |
| Nikkei 225 (N225) | 0.00551 | 0.00518 | 0.00539 | 0.00517 |
| NASDAQ Composite (IXIC) | 0.01211 | 0.00937 | 0.01596 | 0.01351 |
| Hang Seng Index (HSI) | 0.01033 | 0.01016 | 0.01011 | 0.00873 |

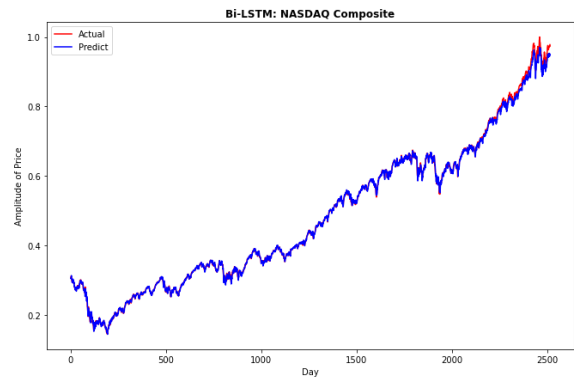

การวัดผลประสิทธิภาพของการพยากรณ์ภายหลังจากการทดสอบข้อมูลของโครงข่ายประสาทเทียม LSTM และ Bi-LSTM ทำให้ทราบว่า Bi-LSTM ให้ผลประสิทธิภาพของการพยากรณ์ดีกว่า LSTM ดังแสดงในตารางที่ 5 และรูปที่ 1 ถึง 8 ได้แสดงผลการพยากรณ์ที่ดีที่สุดของแต่ละดัชนีราคาตลาดหุ้นทั้งแบบ Non-wavelet และ Wavelet




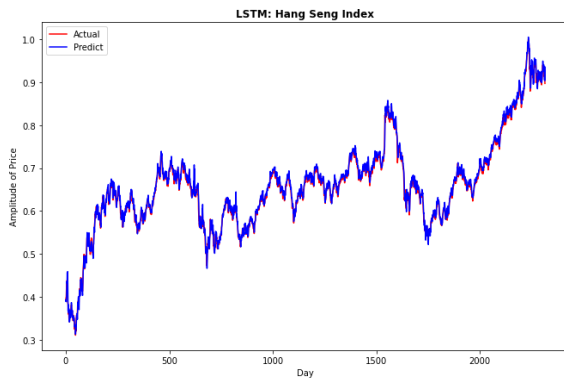
รูปที่ 1 การพยากรณ์ที่ดีที่สุดของ S&P 500 แบบ Non-wavelet



รูปที่ 2 การพยากรณ์ที่ดีที่สุดของ Nikkei 225 แบบ Non-wavelet



รูปที่ 3 การพยากรณ์ที่ดีที่สุดของ NASDAQ Composite แบบ Non-wavelet





รูปที่ 4 การพยากรณ์ที่ดีที่สุดของ Hang Seng Index แบบ Non-wavelet




รูปที่ 5 การพยากรณ์ที่ดีที่สุดของ S&P 500 แบบ Wavelet



รูปที่ 6 การพยากรณ์ที่ดีที่สุดของ Nikkei 225 แบบ Wavelet



รูปที่ 7 การพยากรณ์ที่ดีที่สุดของ NASDAQ Composite แบบ Wavelet



รูปที่ 8 การพยากรณ์ที่ดีที่สุดของ Hang Seng Index แบบ Wavelet

5. บทสรุปและข้อเสนอแนะ

จากการพยากรณ์ดัชนีราคาตลาดหุ้น โดยใช้ Wavelet Transform, LSTM และ Bi-LSTM จากข้อมูลราคาเปิด ราคาปิด ราคาสูงสุด ราคาต่ำสุด และปริมาณการซื้อขายแบบรายวัน ตั้งแต่วันที่ 1 มกราคม พ.ศ.2538 ถึง 31 สิงหาคม พ.ศ.2561 เป็นระยะเวลา 32 ปี 8 เดือน สำหรับ S&P 500 (GSPC), Nikkei 225 (N225) และ NASDAQ Composite (IXIC) ส่วน Hang Seng Index (HSI) ใช้ข้อมูลตั้งแต่วันที่ 1 มกราคม พ.ศ.2530 ถึง 31 สิงหาคม พ.ศ.2561 เป็นระยะเวลา 30 ปี 8 เดือน ซึ่งช่วงของตัวเลขมีความกว้างมาก คือ ตั้งแต่หลักร้อยจนถึงหลักล้าน ดังนั้นผู้ศึกษาจึงแปลงข้อมูลให้ช่วงของตัวเลขมีค่าอยู่ระหว่าง 0 ถึง 1 อีกทั้งทำการกรองข้อมูลเพิ่มเติมด้วย Haar Wavelet ที่ระดับ 2 เพื่อกำจัด Noise ออกไป จากนั้นได้แบ่งข้อมูลสำหรับการดำเนินการในส่วน of โครงข่ายประสาทเทียมออกเป็น 2 ชุด คือ ข้อมูลสำหรับการเรียนรู้ และข้อมูลสำหรับการทดสอบ โดยใช้อัตราส่วน 70 : 30 ตามลำดับ และยังได้กำหนดใช้การวิเคราะห์ Lookback เพื่อให้โครงข่ายประสาทเทียมเกิดการเรียนรู้และทดสอบกระทั่งได้ผลลัพธ์ที่มีประสิทธิภาพ ซึ่งทำการวัดผลประสิทธิภาพของแต่ละโครงข่ายและแบบจำลองจากการหาค่า RMSE โดยแต่ละส่วนของการศึกษานี้สามารถสรุปได้ดังนี้

สำหรับการทดลองหาค่า Lookback ที่เหมาะสมได้ทดลองกับ Wavelet LSTM บนดัชนีราคาตลาดหุ้น S&P 500 เท่านั้น โดยเลือก Lookback ที่เหมาะสมจากการหาค่าเฉลี่ย RMSE ที่น้อยที่สุด ซึ่งผลลัพธ์ คือ Lookback ที่เท่ากับ 5 และมีค่า RMSE เท่ากับ 0.01646

สำหรับระยะเวลาของขั้นตอนการเรียนรู้ของข้อมูลทั้งแบบ Non-wavelet และ Wavelet กับโครงข่ายประสาทเทียมทั้งสองชนิด ซึ่งผลลัพธ์ คือ Bi-LSTM ใช้เวลาในการดำเนินการนานกว่า LSTM แต่ใช้เวลาน้อยกว่าสำหรับการดำเนินการ LSTM 2 รอบ และเมื่อเปรียบเทียบระหว่างโครงข่ายประสาทเทียมชนิดเดียวกันที่ต่างกันที่ Non-wavelet กับ Wavelet แล้วนั้น ผลลัพธ์ คือ การใช้ Wavelet Transform ทำให้โครงข่ายประสาทเทียมเรียนรู้ข้อมูลได้เร็วขึ้น

สำหรับการพยากรณ์ดัชนีราคาตลาดหุ้น หรือการวัดประสิทธิภาพของการทดสอบของโครงข่ายประสาทเทียม พบว่าเมื่อทำการเปรียบเทียบระหว่างโครงข่ายประสาทเทียมทั้งสองนั้น Bi-LSTM ให้ประสิทธิภาพที่ดีกว่า LSTM โดยได้ค่า RMSE ของ S&P 500, Nikkei 225, NASDAQ Composite, และ Hang Seng Index ของ Wavelet (LSTM : Bi-LSTM) ดังนี้ 0.01646 : 0.01585, 0.00539 : 0.00517, 0.01596 : 0.01351, และ 0.01011 : 0.00873 ตามลำดับ และเช่นเดียวกันสำหรับ Non-wavelet ดังนี้ 0.01348 : 0.01347, 0.00551 : 0.00518, 0.01211 : 0.00937, และ



0.01033 : 0.01016 ตามลำดับ แต่เมื่อทำการเปรียบเทียบระหว่าง Non-wavelet และ Wavelet นั้น จะพบว่าแบบ Wavelet ดัชนีราคาตลาดหุ้น Nikkei 225 และ Hang Seng Index ให้ประสิทธิภาพที่ดีกว่า ซึ่งได้ค่า RMSE ของ Bi-LSTM (Non-wavelet : Wavelet) เท่ากับ 0.00518 : 0.00517 และ 0.01016 : 0.00873 ตามลำดับ แต่แบบ Non-wavelet ดัชนีราคาตลาดหุ้น S&P 500 และ NASDAQ Composite ให้ประสิทธิภาพที่ดีกว่า ซึ่งได้ค่า RMSE ของ Bi-LSTM เท่ากับ 0.01347 : 0.01585 และ 0.00937 : 0.01351 ตามลำดับ

ดังนั้นจากผลการศึกษาพบว่าโครงข่ายประสาทเทียม Bi-LSTM ให้ประสิทธิภาพที่ดีกว่าโครงข่ายประสาทเทียม LSTM และการใช้ Wavelet Transform สามารถทำให้โครงข่ายประสาทเทียมเรียนรู้ข้อมูลได้รวดเร็วยิ่งขึ้น แต่ทว่าการแปลงสัญญาณเฉพาะกลับไม่ได้แสดงถึงผลประสิทธิภาพของโครงข่ายประสาทเทียมที่ดีขึ้นเท่าไรนัก ทั้งนี้ จำนวนรอบของขั้นตอนการเรียนรู้อาจมีส่วนเกี่ยวข้องกับข้อจำกัดที่มาจากประสิทธิภาพ เนื่องจากในเบื้องต้นผู้ศึกษาต้องการลดระยะเวลาของขั้นตอนการเรียนรู้จึงได้ลดจำนวนรอบของขั้นตอนดังกล่าวลง

สุดท้ายนี้ผู้ศึกษาได้ตระหนักถึงผลการศึกษาและพบว่า ระดับขั้นของการแปลงสัญญาณเฉพาะ และเกณฑ์การลดทอนสัญญาณจากการแปลงสัญญาณเฉพาะ รวมไปถึงจำนวนชั้นซ่อน จำนวนรอบ (Epochs) จำนวนข้อมูล และการแบ่งอัตราส่วนของข้อมูล อาจส่งผลต่อผลลัพธ์ของการทดลองและการสร้างแบบจำลองโครงข่ายประสาทเทียมทั้งสอง โดยทุกๆ ข้อสงสัยควรทำการทดลองจากตัวเลขจำนวนน้อยๆ และทำการเพิ่มไปที่ระดับ เพื่อให้ตอบโต้กับผลลัพธ์ของการทดลองกระทั่งได้ผลประสิทธิภาพที่ดีที่เป็นที่น่าพอใจ และเมื่อได้แบบจำลองโครงข่ายประสาทเทียมที่ให้ผลประสิทธิภาพที่ดีเพียงพอกับการพยากรณ์ดัชนีราคาตลาดหุ้นโดยใช้ Wavelet Transform, LSTM และ Bi-LSTM แล้ว อาจจำลองการซื้อขายจากผลลัพธ์ของการพยากรณ์ เพื่อตรวจสอบความแม่นยำของการพยากรณ์นี้ และทำการวางแผน ปรับใช้ให้เหมาะสมกับสภาพตลาดในขณะนั้น เพื่อให้เกิดประโยชน์สูงสุดแก่นักลงทุน

เอกสารอ้างอิง

- Caudill, M. (1987). Neural networks primer, part I. *AI Expert*, 2(12), 46-52.
- Devleker, K. (2016). *Understanding Wavelets, Part 1: What Are Wavelets* [Video]. MathWorks. Retrieved from <https://www.mathworks.com/videos/understanding-wavelets-part-1-what-are-wavelets-121279.html>
- Hochreiter, S., & Schmidhuber, J. (1997). LONG SHORT-TERM MEMORY. *NEURAL COMPUTATION*, 9(8), 1735-1780.
- LeBaron, B., & Weigend, A. S. (1998). A bootstrap evaluation of the effect of data splitting on financial time series. *IEEE Transactions on Neural Networks*, 9(1), 213-220.
- Liang, X., Ge, Z., Sun, L., He, M., & Chen, H. (2019). LSTM with Wavelet Transform Based Data Preprocessing for Stock Price Prediction. *Hindawi, Mathematical Problems in Engineering*, 2019, Article ID 1340174.
- Limkonchotiwat, P. (2019, March 2). *Deep Learning แบบฉบับคนสามัญ EP 1 : Neural Network History*. Medium. Retrieved from <https://medium.com/mmp-li/deep-learning-แบบฉบับคนสามัญ-ep-1-neural-network-history-f7789236a9a3>



- McNally, S., Roche, J., & Caton, S. (2018). Predicting the Price of Bitcoin Using Machine Learning. *2018 26th Euromicro International Conference on Parallel, Distributed, and Network-Based Processing (PDP)*, 339-343.
- Olah, C. (2015, August 27). Understanding LSTM Networks. *colah's blog*. Retrieved from <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- Pornpatcharapong, W. (2008, February 5). *โครงข่ายประสาทเทียม (Artificial Neural Networks - ANN)*. GotoKnow. Retrieved from <https://www.gotoknow.org/posts/163433>
- Saud, A. S., & Shakya, S. (2020). Analysis of look back period for stock price prediction with RNN variants: A case study on banking sector of NEPSE. *Procedia Computer Science*, 167(2020), 788-798.
- Siami-Namini, S., Tavakoli, N., & Namin, A. S. (2019). The Performance of LSTM and BiLSTM in Forecasting Time Series. *2019 IEEE International Conference on Big Data (Big Data)*, 3285-3292.
- Taspinar, A. (2018, December 21). A guide for using the Wavelet Transform in Machine Learning. *Ahmet Taspinar*. Retrieved from <https://ataspinar.com/2018/12/21/a-guide-for-using-the-wavelet-transform-in-machine-learning/>
- Young, R. K. (1993). *Wavelet Theory and Its Applications*. Springer Science+Business Media, LLC.