



การศึกษาแบบจำลองไฮบริดสำหรับการคาดการณ์อัตราแลกเปลี่ยนเงินตราต่างประเทศ โดยใช้การสลายตัวของข้อมูลแบบ Complete Ensemble Empirical Mode Decomposition With Adaptive Noise (CEEMDAN) ร่วมกับแบบจำลองโครงข่ายประสาทเทียม Multilayer Long Short Term Memory (MLSTM)

Studying Hybrid Models for Forecasting Foreign Exchange Rates by Using The Complete Ensemble Empirical Mode Decomposition with Adaptive Noise (CEEMDAN) with The Multilayer Long Short Term Memory (MLSTM)

รุจิรดา ทองชุม¹ และ ธฤตพน อุ้วสวัสดิ์²

¹ หลักสูตรวิศวกรรมการเงิน คณะวิทยาศาสตร์ มหาวิทยาลัยหอการค้า, อีเมล Rujirada.th@gmail.com

² หลักสูตรวิศวกรรมการเงิน คณะวิทยาศาสตร์ มหาวิทยาลัยหอการค้า, อีเมล tousawat@riped.utcc.ac.th

บทคัดย่อ

การศึกษาแบบจำลองไฮบริดสำหรับการคาดการณ์อัตราแลกเปลี่ยนเงินตราต่างประเทศโดยใช้การสลายตัวของข้อมูลแบบ Complete Ensemble Empirical Mode Decomposition With Adaptive Noise (CEEMDAN) ร่วมกับแบบจำลองโครงข่ายประสาทเทียม Multilayer Long Short Term Memory (MLSTM) เป็นการใชแบบจำลองผสมระหว่างการกรองข้อมูลเพื่อแยกความถี่ตามช่วงเวลา ทำให้เลือกใช้ข้อมูลได้อย่างเหมาะสม และใช้แบบจำลองโครงข่ายประสาทเทียมระยะสั้นระยะยาวคาดการณ์ข้อมูลถัดไป

การศึกษานี้มีวัตถุประสงค์เพื่อศึกษาประสิทธิภาพและความคิดพลาดในการคาดการณ์ข้อมูลอัตราแลกเปลี่ยนเงินตราต่างประเทศของแบบจำลองไฮบริด เปรียบเทียบกับการคาดการณ์ข้อมูลล่วงหน้าโดยไม่ใช้การแยกข้อมูลแบบ CEEMDAN และประเมินการใช้แบบจำลองร่วมกันระหว่างข้อมูลในตลาดเดียวกัน

ข้อมูลที่ใช้ในการศึกษาประกอบด้วยอัตราแลกเปลี่ยน EURUSD GBPUSD JPYUSD AUDUSD ได้ศึกษาหาแบบจำลอง MLSTM ที่ดีที่สุดในการคาดการณ์ จากข้อมูลดิบ EURUSD รายวันด้วยวิธีการ Optimization และนำไปใช้กับการแยกข้อมูลแบบ CEEMDAN เพื่อประเมินความสามารถของแบบจำลองในการใช้คาดการณ์ข้อมูลอัตราแลกเปลี่ยนของชุดข้อมูลอื่นในตลาดเดียวกันด้วยวิธี Root Mean Square Error (RMSE) เปรียบเทียบความสามารถของแบบจำลองไฮบริดที่ใช้ CEEMDAN กับ MLSTM และแบบจำลองที่ไม่มีการใช้ CEEMDAN แยกข้อมูลก่อนการคาดการณ์ การศึกษานี้ใช้โปรแกรม MATLAB ในการดำเนินงาน

การศึกษาแบบจำลอง MLSTM ที่ได้จากการ Optimization ร่วมกับการแยกข้อมูลแบบ CEEMDAN เพื่อคาดการณ์ข้อมูลล่วงหน้าพบว่าสำหรับชุดข้อมูล EURUSD มีความเหมาะสม สามารถบอกทิศทางเคลื่อนไหวของอัตราแลกเปลี่ยนได้ดี มีความคลาดเคลื่อนต่ำ และมีผลการทดลองที่ดีกว่าแบบจำลองที่ไม่มีการใช้ CEEMDAN เมื่อใช้แบบจำลองสำหรับข้อมูลชุดอื่นในตลาดพบว่า ผลที่ได้มีประสิทธิภาพต่ำกว่าการใช้แบบจำลองกับชุดข้อมูลเดียวกันจากการ Optimization หาแบบจำลอง MLSTM แต่ยังคงมีประสิทธิภาพสูงสามารถบอกแนวโน้มของอัตราแลกเปลี่ยนได้



คำสำคัญ: การคาดการณ์, การแลกเปลี่ยนเงินตราต่างประเทศ, แบบจำลอง, LSTM, CEEMDAN

ABSTRACT

A study of a hybrid model for forecasting foreign exchange rates using Complete Ensemble Empirical Mode Decomposition With Adaptive Noise (CEEMDAN) in combination with a Multilayer Long Short Term Memory (MLSTM) schematic network model. that uses a filtering model to differentiate by frequency range for optimal data selection and using a short-term, long-term neural network model to predict the next data.

The purpose of this study was to study the efficiency and error in forecasting foreign exchange rate data of the hybrid model compare with the model without CEEMDAN data extraction and the sharing of the model between the same market data.

The data in the study consisted of the EURUSD GBPUSD JPYUSD AUDUSD exchange rates. Study the best MLSTM model from the daily EURUSD raw data using an Optimization method for forecasting in conjunction with the CEEMDAN data extraction to evaluate efficiency when forecasting the same market exchange rate data as other datasets. Using RMSE methods to compare the capabilities of a hybrid model using CEEMDAN with MLSTM and a model without CEEMDAN.

A study of the MLSTM model derived from optimization combined with CEEMDAN data extraction to predict the forward data. Found that for the EURUSD dataset has appropriate and represents the direction of the exchange rate movement, low tolerance, and the results were better than the not use CEEMDAN model. When using the model for other data sets on the market. The result is less efficient but is still highly effective for predicting exchange rates.

Keywords: Predict, Foreign Exchange, Model, LSTM, CEEMDAN

1. บทนำ

ในการทำการค้าระหว่างประเทศ การนำเข้า ส่งออก หรือกิจกรรมใดๆที่เกี่ยวข้องกับการซื้อขายแลกเปลี่ยนกับต่างประเทศ หลีกเลี่ยงไม่ได้ที่ต้องมีการแลกเปลี่ยนสกุลเงินเพื่อทำธุรกรรมต่างๆ ทั้งทางตรงและทางอ้อม อัตราแลกเปลี่ยนจึงเป็นอีกหนึ่งปัจจัยความเสี่ยงที่ต้องพิจารณา การคาดการณ์ และการตัดสินใจที่แม่นยำเกี่ยวกับทิศทาง การเคลื่อนไหวของอัตราแลกเปลี่ยน เป็นส่วนช่วยในการลดความเสี่ยงส่วนนี้ได้ การคาดการณ์อัตราแลกเปลี่ยนสามารถทำได้หลายวิธี การใช้แบบจำลองเพื่อคาดการณ์เป็นอีกวิธีหนึ่งที่มีการศึกษาอย่างกว้างขวาง แบบจำลองสามารถแยกย่อยได้หลายประเภท ในที่นี้จะกล่าวถึงแบบจำลองสถิติ และแบบจำลองไดนามิก การใช้แบบจำลองสถิติมีข้อจำกัดหลายประการสำหรับการคาดการณ์อัตราแลกเปลี่ยน เนื่องจากข้อมูลอัตราแลกเปลี่ยนไม่เป็นเชิงเส้น และไม่อยู่นิ่ง ดังนั้นแบบจำลองกลุ่มไดนามิกจึงมีความเหมาะสมต่อการคาดการณ์ข้อมูลมากกว่าแบบจำลองสถิติ

จากการศึกษาบทความ A hybrid Model Using Signal Processing Technology, Econometric Models And Neural Network For Carbon Spot Price Forecasting (Jinliang Zhang, Dezhi Li, Yu Hao, Zhongfu Tan, 2018) พบว่า การใช้งานแบบจำลองไฮบริดด้วยการแยกข้อมูลการเปลี่ยนแปลงของราคาแบบ Complete Ensemble Empirical Mode



Decomposition (CEEMD) ร่วมกับการใช้แบบจำลองเศรษฐมิติ CIM นำเสนอโดย (Engle and Granger, 1987) , แบบจำลองเศรษฐมิติ GARCH โดย (Bollerslev, 1986), GNN Optimized By ACA ได้ผลที่น่าพึงพอใจกว่าการใช้แบบจำลองชนิดใดชนิดหนึ่งแต่เพียงอย่างเดียว และจากบทความ Reducing Exchange Rate Risks In International Trade: A Hybrid Forecasting Approach Of CEEMDAN And Multilayer LSTM (Hualing Lin , Qiubi Sun, Sheng-Qun Chen, 2020) เมื่อเปรียบเทียบผลการคาดการณ์ของอัตราแลกเปลี่ยนเงินตราต่างประเทศโดยวิธี ARIMA, Bayesian, SVM, RNN, MRNN, LSTM, MLSTM และ MLSTM – CEEMDAN พิสูจน์ให้เห็นว่าแบบจำลอง MLSTM – CEEMDAN แบบจำลองไฮบริดที่ใช้เทคโนโลยีการประมวลผลข้อมูล ร่วมกับโครงข่ายประสาทเทียมให้ผลลัพธ์มีประสิทธิภาพในการคาดการณ์ดีกว่าแบบจำลองเดี่ยวอื่น ๆ หรือแบบจำลองร่วม

ดังนั้นจึงได้นำแบบจำลองไฮบริด MLSTM ร่วมกับ CEEMDAN มาทำการศึกษาและเปรียบเทียบความสามารถ ความผิดพลาดในการคาดการณ์ข้อมูลล่วงหน้ากับแบบจำลองที่ไม่ได้ใช้งานแบบผสมหรือแบบจำลองที่ไม่มีการแยกข้อมูลก่อนการคาดการณ์ แบบจำลองนี้ประกอบไปด้วยสองส่วนคือ

1. การแยกข้อมูลอัตราแลกเปลี่ยนในแต่ละช่วงการเปลี่ยนแปลงราคาในระยะสั้น ระยะกลาง และระยะยาว ด้วย CEEMDAN
2. การคาดการณ์ราคาด้วยโครงข่ายประสาทเทียมแบบ MLSTM จากการ Optimization

การแยกข้อมูลด้วยวิธี CEEMDAN เป็นวิธีการแยกข้อมูลที่พัฒนามาจากวิธี Empirical Mode Decomposition (EMD) ในการใช้ Hilbert–Huang Transform เพื่อแยกข้อมูลออกเป็นกลุ่มฟังก์ชันฮาร์มอนิกอย่างง่ายมีแอมพลิจูดและความถี่ของข้อมูลเปลี่ยนแปลงตามเวลา เก็บข้อมูลไว้ใน Intrinsic Mode Function (IMF) โดยการกรองสัญญาณจากการหาค่ากลางของจุด Maxima และ Minima เก็บไว้ใน IMF ลำดับที่ n จากนั้นนำสัญญาณที่ได้ลบออกจากข้อมูลต้นฉบับ ทำซ้ำและเก็บข้อมูลแยกกันจนถึงลำดับที่ n การวิเคราะห์นี้เหมาะสำหรับชุดข้อมูลที่ไม่อยู่นิ่งและไม่เป็นเชิงเส้น แต่มีข้อเสียประการหนึ่งของ EMD คือการผสมของความถี่ข้อมูลสองความถี่ขึ้นไป จึงมีการแก้ไขปัญหานี้โดยวิธี Ensemble Empirical Mode Decomposition (EEMD) วิธีนี้ได้เพิ่ม White Noise เข้าไปในข้อมูลเดิมเพื่อแยกความถี่ข้อมูลที่มีมากกว่าสองความถี่ขึ้นไป สามารถแยกสเกลได้ตามธรรมชาติด้วยการเปลี่ยนการกระจายตัวของข้อมูล White Noise โดยไม่ต้องกำหนดเกณฑ์ใด ๆ แต่วิธีนี้ยังคงมีข้อมูล White Noise ที่ยังคงค้างอยู่ในข้อมูลที่ถูกแยก ดังนั้นจึงมีการพัฒนาวิธีการแยกข้อมูลเป็นแบบ Complete Ensemble Empirical Mode Decomposition With Adaptive Noise (CEEMDAN) เพื่อทำการขจัด White Noise ออกจากข้อมูลที่ได้ โดยการเพิ่ม White Noise ทั้งค่าบวกและลบเข้าไปในข้อมูล ทำให้ White Noise หักล้างกันจึงไม่เหลือข้อมูลค้าง ข้อมูลที่ได้จึงมีความถูกต้องมากกว่าสองวิธีข้างต้น ดังนั้นขั้นตอนการแยกข้อมูลจึงใช้วิธีแบบ CEEMDAN

ส่วนแบบจำลองสำหรับการคาดการณ์อัตราแลกเปลี่ยนล่วงหน้าใช้แบบจำลองโครงข่ายประสาทเทียมแบบ MLSTM ซึ่งเป็นหนึ่งในรูปแบบของโครงสร้าง Recurrent Neural Network (RNN) ใช้ในการแก้ปัญหาโดยการให้น้ำหนักข้อมูลตามอนุกรมเวลาของ RNN โครงสร้าง LSTM จะควบคุมการเพิ่มหรือการลบสถานะข้อมูลของเซลล์ประสาท สามารถเรียนรู้การเชื่อมโยงที่ซับซ้อนได้มากกว่าแบบจำลองคลาสสิกของอนุกรมเวลา และการเพิ่มจำนวน RNN หลายชั้น หรือ MLSTM สามารถแบ่งปันข้อมูลในเครือข่ายได้ดีกว่า เมื่อเทียบกับโครงข่ายประสาทชั้นเดียว เครือข่ายประสาทหลายชั้นมีความสามารถในการคาดการณ์อย่างมีประสิทธิภาพมากกว่าและสามารถแก้ปัญหาที่ซับซ้อนได้



จึงได้เลือกศึกษาแบบจำลองไฮบริดในการแยกข้อมูลแบบ CEEMDAN ร่วมกับ โครงข่ายประสาทเทียมแบบ MLSTM เพื่อศึกษา ประเมินประสิทธิภาพและความผิดพลาดของแบบจำลอง เปรียบเทียบกับแบบจำลองเดี่ยวที่ใช้เพียงโครงข่ายประสาทเทียมแบบ MLSTM เท่านั้น รวมถึงศึกษาความเหมาะสมในการคาดการณ์ชุดข้อมูลอื่นในตลาดเดียวกันจากแบบจำลองที่ได้จากข้อมูลชุดเดียว

2. วัตถุประสงค์การวิจัย

1. เพื่อหาแบบจำลอง MLSTM ที่ดีที่สุดในการคาดการณ์อัตราแลกเปลี่ยนเงินตราต่างประเทศด้วยวิธี Optimization
2. เพื่อศึกษาและประเมินความผิดพลาดของแบบจำลองไฮบริดในการแยกข้อมูลแบบ CEEMDAN ร่วมกับ โครงข่ายประสาทเทียมแบบ MLSTM ในการคาดการณ์อัตราแลกเปลี่ยน EURUSD GBPUSD JPYUSD AUDUSD
3. เพื่อวิเคราะห์ความเหมาะสมของแบบจำลองในการใช้งานกับชุดข้อมูลที่แตกต่างในตลาดเดียวกัน
4. เพื่อทดสอบประสิทธิภาพของแบบจำลองไฮบริดเทียบระหว่างการแยกข้อมูลแบบ CEEMDAN ร่วมกับแบบจำลอง MLSTM กับแบบจำลองที่ไม่มีการใช้ขั้นตอนการแยกข้อมูลแบบ CEEMDAN

3. การดำเนินการวิจัย

3.1 การหาแบบจำลอง MLSTM ด้วยวิธี Optimization

การหาแบบจำลองใช้ข้อมูลอัตราแลกเปลี่ยนย้อนหลังของกลุ่มสกุลเงิน EURUSD รายวันในการ Optimize หาแบบจำลอง MLSTM ที่เหมาะสมในการคาดการณ์ข้อมูลล่วงหน้าที่ดีที่สุดเป็นจำนวน 5 ข้อมูลถัดไป ซึ่งแบ่งข้อมูลตามช่วงข้อมูลรายวัน รายสัปดาห์ และรายเดือน เลือกแบบจำลองที่ดีที่สุด 3 ลำดับแรกของแต่ละช่วงข้อมูล เพื่อนำมาประเมินประสิทธิภาพเปรียบเทียบหาแบบจำลองที่เหมาะสมกับชุดข้อมูลอื่นในตลาด

ตารางที่ 1 ตารางแสดงการตั้งค่าขอบเขต Optimization เพื่อหาแบบจำลอง MLSTM ที่ดีที่สุด 3 แบบจำลอง

ตัวแปร	คำอธิบาย	การตั้งค่า
Program	โปรแกรมการใช้งาน	MATLAB
Data	ข้อมูลที่ใช้ในการ Optimize	EURUS รายวัน
Delay data	ข้อมูลที่นำมาคิดย้อนหลัง	1, 10, 20
Model	แบบจำลองที่ใช้	LSTM, Bi-LSTM
maxEpochs	จำนวนสูงสุดในการเรียนรู้	512
miniBatchSize	จำนวนข้อมูลในการเรียนรู้แต่ละครั้ง	512 สำหรับราย 1 วัน (100 สำหรับราย 1 สัปดาห์ และ 23 สำหรับราย 1 เดือน)
Learning method	วิธีการเรียนรู้	ADAM
Layer	จำนวนชั้น	1-2 layer
Unit	จำนวนหน่วย	200 – 800 unit



ตัวแปร	คำอธิบาย	การตั้งค่า
Initial learn rate	อัตราการเรียนรู้	0.0001 – 0.1
Max optimization time	กำหนดเวลาการเรียนรู้	16 hours
Max iteration	จำนวนครั้งในการเรียนรู้	120

3.2 การแยกข้อมูลด้วย CEEMDAN

ทำการแยกข้อมูลด้วย CEEMDAN กำหนดตัวแปรในการแยกข้อมูลครั้งนี้ ส่วนเบี่ยงเบนมาตรฐานของ White Noise กำหนดให้เท่ากับส่วนเบี่ยงเบนมาตรฐานของข้อมูลที่นำเข้าไป ใช้จำนวนการรับรู้ที่เหมาะสม 500 และจำนวนการกรองซ้ำสูงสุด 50 ครั้งหลังจากการแยกข้อมูลจะได้ IMF จำนวนหนึ่ง

3.3 การคาดการณ์ข้อมูล IMF โดยใช้แบบจำลอง MLSTM

เมื่อแยกข้อมูลด้วยวิธี CEEMDAN แล้วจะได้ IMF จำนวน n ชุด นำข้อมูลแต่ละชุดที่ได้เข้าแบบจำลอง MLSTM เพื่อคาดการณ์ข้อมูล 5 ลำดับถัดไป จากนั้นรวมข้อมูล IMF ทุกชุดที่ทำการคาดการณ์ทั้งหมดเข้าด้วยกัน เปรียบเทียบผลลัพธ์กับข้อมูลจริงที่เกิดขึ้น และเปรียบเทียบกับการใช้แบบจำลองที่ไม่มีการแยกข้อมูล CEEMDAN ประเมินประสิทธิภาพแบบจำลองด้วย RMSE ในการหาความคลาดเคลื่อนระหว่างค่าคาดการณ์กับค่าจริงที่เกิดขึ้นในหน่วยเดียวกับค่าที่ทำนายไว้ เปรียบเทียบประสิทธิภาพของแบบจำลองสำหรับการคาดการณ์ข้อมูลรายวัน รายสัปดาห์ และรายเดือน เพื่อประเมินความสามารถของแบบจำลองที่มาจากชุดข้อมูล EURUSD รายวันในการใช้คาดการณ์ข้อมูลในตลาดเดียวกัน และช่วงข้อมูลอื่นๆ

ข้อมูลกลุ่มตัวอย่างที่ใช้

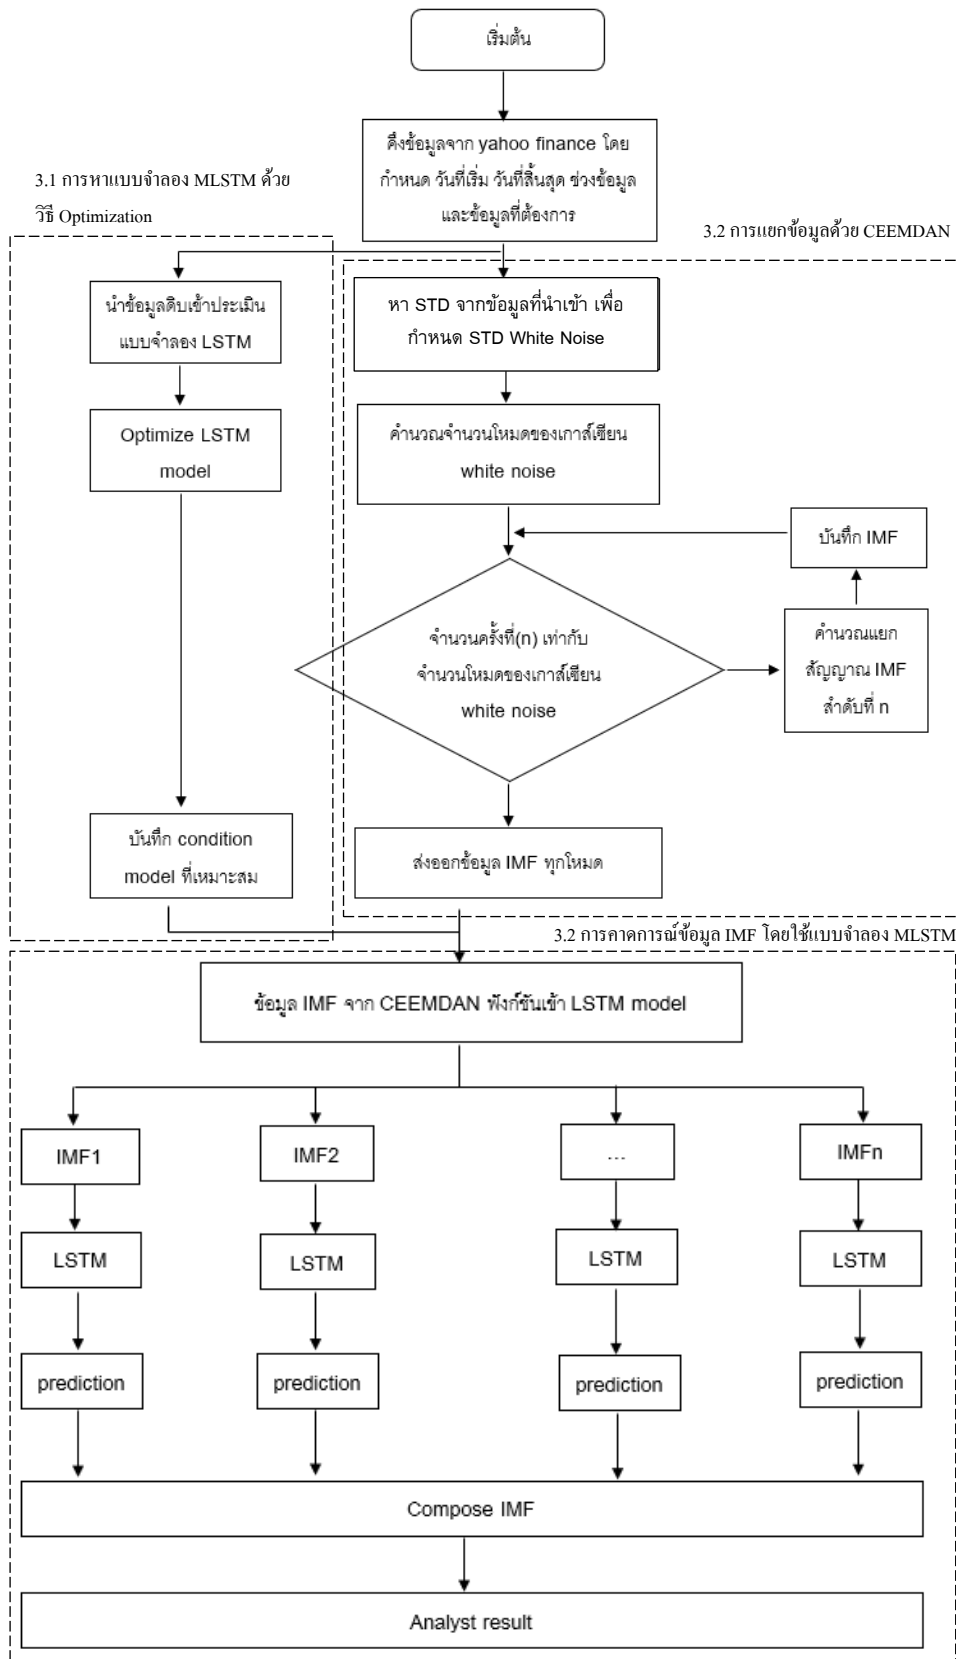
ที่มาของข้อมูล	: https://finance.yahoo.com/
ข้อมูลย้อนหลัง	: 1 มกราคม 2010 ถึง 31 ธันวาคม 2020
คู่สกุลเงินที่ใช้	: EURUSD GBPUSD JPYUSD AUDUSD
ประเภทข้อมูล	: ช่วงเวลา 1 วัน 1 สัปดาห์ และ 1 เดือน

การสร้างแบบจำลอง

การแบ่งข้อมูลสร้างแบบจำลอง	: Training 70% (ข้อมูล 70 % ของข้อมูลทั้งหมดใช้สำหรับการเรียนรู้ของแบบจำลอง) Validate 30% (ข้อมูล 30 % ของข้อมูลทั้งหมดใช้สำหรับการทดสอบแบบจำลอง) Test 5 ข้อมูลถัดไป (ข้อมูลจำนวน 5 ข้อมูลถัดไปใช้สำหรับการคาดการณ์)
แบบจำลองที่ใช้	: แบบจำลองสำหรับการแยกข้อมูล CEEMDAN แบบจำลองสำหรับการคาดการณ์ข้อมูล MLSTM



มีขั้นตอนการดำเนินการ โดยรวมแสดงเป็นรูปแบบแผนภาพดังนี้



รูปที่ 1 แผนภาพแสดงกระบวนการดำเนินการศึกษา



4. ผลการวิจัย

4.1 ผลการหาแบบจำลอง MLSTM จากการ Optimization

จากการหาแบบจำลองที่ดีที่สุดของ MLSTM ในการคาดการณ์ข้อมูลล่วงหน้าจากข้อมูล EURUSD รายวัน ได้แบบจำลองที่ดีที่สุดในการคาดการณ์ข้อมูลล่วงหน้า 3 แบบจำลอง พบว่าแบบจำลองที่เหมาะสมสำหรับช่วงข้อมูล 1 วัน, 1 สัปดาห์ และ 1 เดือน มีดังนี้

ตารางที่ 2 ตารางแสดง โครงสร้างและคุณสมบัติของแบบจำลองช่วงเวลา 1 วัน ที่ดีที่สุดจำนวน 3 แบบจำลอง

Name	Delay	Layer	Model	Unit	Learning rate	RMSE
Model1	1	1	biLSTM	263	0.0057	0.043521
Model2	1	1	LSTM	562	0.0099	0.043523
Model3	1	1	biLSTM	539	0.0069	0.043524


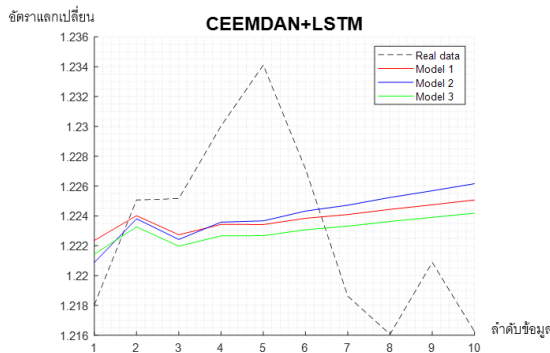
ตารางที่ 3 ตารางแสดง โครงสร้างและคุณสมบัติของแบบจำลองช่วงเวลา 1 สัปดาห์ ที่ดีที่สุดจำนวน 3 แบบจำลอง

Name	Delay	Layer	Model	Unit	Learning rate	RMSE
Model1	1	1	biLSTM	210	0.0167	0.092484
Model2	1	1	biLSTM	205	0.1404	0.092488
Model3	1	1	biLSTM	210	0.0013	0.092497

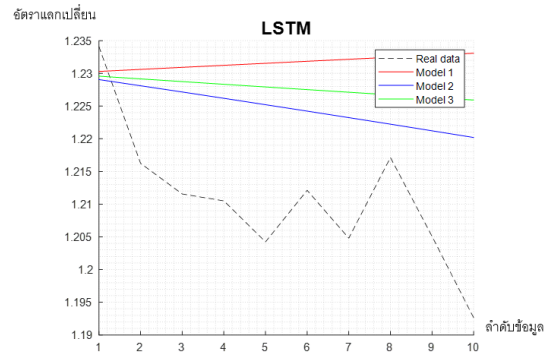
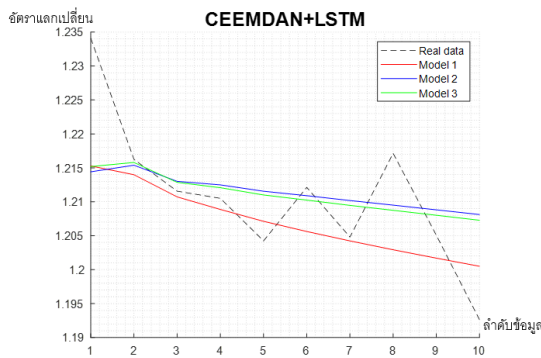
ตารางที่ 4 ตารางแสดง โครงสร้างและคุณสมบัติของแบบจำลองช่วงเวลา 1 เดือน ที่ดีที่สุดจำนวน 3 แบบจำลอง

Name	Delay	Layer	Model	Unit	Learning rate	RMSE
Model1	1	1	biLSTM	797	0.0003	0.178204
Model2	1	1	biLSTM	209	0.0009	0.178268
Model3	1	1	biLSTM	203	0.0008	0.178289

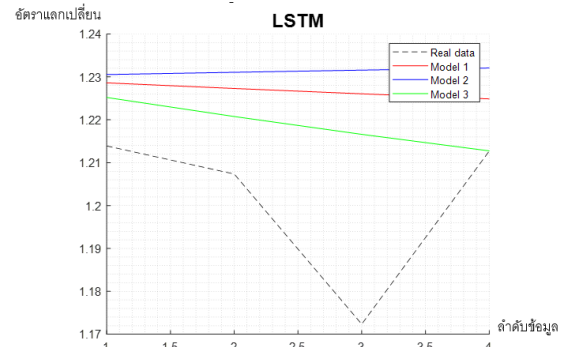
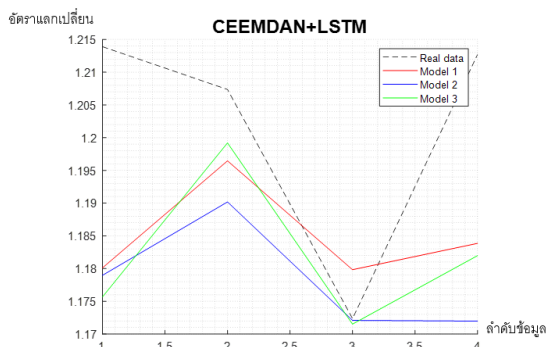
แบบจำลองการคาดการณ์ที่ดีที่สุด 3 ลำดับแรกของทุกช่วงข้อมูลมีค่าความคลาดเคลื่อน RMSE ใกล้เคียงกัน แบบจำลองช่วงเวลา 1 วันมีค่า RMSE ที่ระดับนัยสำคัญต่ำกว่า 0.05 แบบจำลองช่วงเวลา 1 สัปดาห์มีค่า RMSE ที่ระดับนัยสำคัญต่ำกว่า 0.1 และแบบจำลองช่วงเวลา 1 สัปดาห์มีค่า RMSE ที่ระดับนัยสำคัญต่ำกว่า 0.2 และแบบจำลองส่วนใหญ่ใช้โครงสร้างแบบ biLSTM มีจำนวนหน่วยที่เหมาะสมประมาณ 200 หน่วย จำนวน 1 ชั้น



รูปที่ 2 กราฟแสดงผลการประเมินแบบจำลอง CEEMDAN ร่วมกับ LSTM ของ EURUSD เปรียบเทียบกับแบบจำลองที่ไม่ใช่ CEEMDAN ช่วงข้อมูล 1 วัน คาดการณ์ข้อมูลล่วงหน้าเป็นเวลา 10 วัน ของแบบจำลองที่ดีที่สุด 3 แบบจำลอง



รูปที่ 3 กราฟแสดงผลการประเมินแบบจำลอง CEEMDAN ร่วมกับ LSTM ของ EURUSD เปรียบเทียบกับแบบจำลองที่ไม่ใช่ CEEMDAN ช่วงข้อมูล 1 สัปดาห์ คาดการณ์ข้อมูลล่วงหน้าเป็นเวลา 10 สัปดาห์ ของแบบจำลองที่ดีที่สุด 3 แบบจำลอง



รูปที่ 4 กราฟแสดงผลการประเมินแบบจำลอง CEEMDAN ร่วมกับ LSTM ของ EURUSD เปรียบเทียบกับแบบจำลองที่ไม่ใช่ CEEMDAN ช่วงข้อมูล 1 เดือน คาดการณ์ข้อมูลล่วงหน้าเป็นเวลา 4 เดือน ของแบบจำลองที่ดีที่สุด 3 แบบจำลอง



4.1 ผลการคาดการณ์ข้อมูลล่วงหน้าด้วยแบบจำลอง MLSTM

นำแบบจำลองที่ดีที่สุดทั้ง 3 แบบจำลองมาใช้คาดการณ์ข้อมูลล่วงหน้าจำนวน 5 ข้อมูลถัดไป ของแต่ละชุดข้อมูลซึ่งประกอบไปด้วยอัตราแลกเปลี่ยนคู่สกุลเงิน EURUSD GBPUSD JPYUSD และ AUDUSD ได้ผลการศึกษาดังนี้

ตารางที่ 5 ตารางแสดงผลการเปรียบเทียบแบบจำลองที่ดีที่สุดในการคาดการณ์ข้อมูล 5 วัน

FOREX	Model	Method	Total Layer	Unit	RMSE
EURUSD	CEEMDAN +LSTM Model2	LSTM	1	562	0.0058
GBPUSD	Original +LSTM Model1	biLSTM	1	263	0.0041
JPYUSD	Original +LSTM Model2	LSTM	1	562	0.0000
AUDUSD	Original +LSTM Model3	biLSTM	1	539	0.0065

ตารางที่ 6 ตารางแสดงผลการเปรียบเทียบแบบจำลองที่ดีที่สุดในการคาดการณ์ข้อมูล 5 สัปดาห์

FOREX	Model	Method	Total Layer	Unit	RMSE
EURUSD	CEEMDAN +LSTM Model1	biLSTM	1	210	0.0086
GBPUSD	Original +LSTM Model1	biLSTM	1	210	0.0038
JPYUSD	Original +LSTM Model2	biLSTM	1	205	0.0001
AUDUSD	Original +LSTM Model2	biLSTM	1	205	0.0065

ตารางที่ 7 ตารางแสดงผลการเปรียบเทียบแบบจำลองที่ดีที่สุดในการคาดการณ์ข้อมูล 4 เดือน

FOREX	Model	Method	Total Layer	Unit	RMSE
EURUSD	CEEMDAN +LSTM Model1	biLSTM	1	797	0.0232
GBPUSD	Original +LSTM Model3	biLSTM	1	209	0.0102
JPYUSD	CEEMDAN +LSTM Model3	biLSTM	1	203	0.0002
AUDUSD	Original +LSTM Model3	biLSTM	1	203	0.0114

จากผลการทดลองพบว่าแบบจำลองไฮบริดที่ใช้การแยกข้อมูล CEEMDAN ร่วมกับ MLSTM มีประสิทธิภาพดีที่สุด ในชุดข้อมูล EURUSD ซึ่งเป็นชุดข้อมูลเดียวที่แบบจำลองไฮบริดมีประสิทธิภาพสูงสุดเมื่อเปรียบเทียบกับแบบจำลองเดี่ยวที่ไม่มีการใช้ CEEMDAN มีค่า RMSE ต่ำกว่า 0.05 ในทุกช่วงข้อมูล



5. การอภิปรายผล

จากการศึกษาแบบจำลองไฮบริดการแยกข้อมูล CEEMDAN ร่วมกับ โครงข่ายประสาทเทียมแบบ MLSTM ใน ตลาดแลกเปลี่ยนเงินตราต่างประเทศ การคาดการณ์อัตราแลกเปลี่ยนของกลุ่มสกุลเงิน EURUSD, GBPUSD, JPYUSD และ AUDUSD ด้วยการหาแบบจำลองที่ดีที่สุดจากการ Optimize จากข้อมูลอัตราแลกเปลี่ยน EURUSD ย้อนหลังรายวัน ตั้งแต่วันที่ 1 มกราคม 2010 ถึงวันที่ 31 ธันวาคม 2020 เป็นจำนวน 10 ปี โดยแบ่งการเรียนรู้ของแบบจำลองและการ ทดสอบเป็นสัดส่วน 70 ต่อ 30 ของข้อมูลทั้งหมด มีค่า RMSE เฉลี่ยในแต่ละช่วงข้อมูล 0.0435, 0.0924, 0.1782 ตาม ช่วงข้อมูลรายวัน รายสัปดาห์ และรายเดือน โดยประสิทธิภาพของแบบจำลองมีจำนวนชั้นและจำนวนหน่วยไม่ สัมพันธ์กัน กล่าวได้ว่าแบบจำลองที่ดีที่สุดขึ้นอยู่กับจำนวน ลักษณะของข้อมูล และการเรียนรู้ของแบบจำลอง ซึ่ง แบบจำลองส่วนใหญ่ที่ได้จากการ Optimization มีโครงสร้างหน่วยแบบ biLSTM จำนวน 1 ชั้น และมีจำนวนหน่วย ประมาณ 200 หน่วย

การคาดการณ์ข้อมูลล่วงหน้าจากแบบจำลองที่เลือก พบว่าเมื่อใช้แบบจำลองไฮบริดสำหรับอัตราแลกเปลี่ยน EURUSD มีประสิทธิภาพในการคาดการณ์ข้อมูล 5 ลำดับถัดไปดีกว่าการใช้ข้อมูลต้นฉบับโดยตรงอย่างชัดเจนในทุก ช่วงข้อมูล ประเมินความผิดพลาด RMSE น้อยกว่าระดับนัยสำคัญที่ 0.03 แต่เมื่อนำแบบจำลองไฮบริดคาดการณ์อัตรา แลกเปลี่ยนของกลุ่มสกุลอื่นพบว่า มีประสิทธิภาพต่ำกว่าการคาดการณ์ด้วยข้อมูลต้นฉบับก่อนการแยกข้อมูล ทั้งนี้อาจ เกิดจากการหาแบบจำลองที่ดีที่สุดด้วยข้อมูล EURUSD เพียงชุดเดียว ทำให้แบบจำลองที่ได้ไม่มีความเหมาะสมกับ แบบจำลองชุดอื่น แต่อย่างไรก็ตามการใช้แบบจำลอง MLSTM ในการคาดการณ์ข้อมูลล่วงหน้ามีประสิทธิภาพสูงจาก การประเมินค่า RMSE การคาดการณ์มีความผิดพลาดจากค่าจริงในระดับนัยสำคัญที่ 0.01, 0.01 และ 0.03 โดยรวมใน แต่ละช่วงข้อมูลการคาดการณ์ และจากรูปที่ 2 ถึง 4 การคาดการณ์สามารถบอกแนวโน้มทิศทางการเคลื่อนไหวของ อัตราแลกเปลี่ยนได้ ซึ่งมีประสิทธิภาพจะลดลงตามความถี่ของข้อมูลที่มากขึ้นเนื่องจากการเปลี่ยนแปลงข้อมูลอย่างรวดเร็วทำให้มีข้อมูลรบกวนเพิ่มมากขึ้นตามไปด้วย จากรูปที่ 4 แสดงผลข้อมูลรายเดือนมีทิศทางชัดเจนสอดคล้องกับ ค่าจริงมากกว่าข้อมูลรายวันในรูปที่ 2

6. บทสรุปและข้อเสนอแนะ

จากการศึกษาประเมินประสิทธิภาพของแบบจำลองที่ได้จากการทดลองหาแบบจำลอง MLSTM ด้วยวิธี Optimization เมื่อใช้ร่วมกับการแยกข้อมูลแบบ CEEMDAN มีความเหมาะสมในการคาดการณ์ข้อมูลล่วงหน้า กับชุด ข้อมูลเดียวกันจากการเรียนรู้ของแบบจำลอง MLSTM และสามารถให้แบบจำลอง MLSTM คาดการณ์ชุดข้อมูลอื่นใน ตลาดเดียวกันได้ แต่ให้ประสิทธิภาพในการคาดการณ์ต่ำกว่าที่ควรจะเป็น ควรทำการหาแบบจำลองที่เหมาะสมด้วย วิธี Optimization แยกจากกันแต่ละชุดข้อมูล แบบจำลองไฮบริดนี้สามารถแสดงถึงลักษณะกราฟอัตรา การเปลี่ยนแปลงในการคาดการณ์ช่วง 1 ถึง 5 ข้อมูลแรก ได้ดีกว่าการใช้ข้อมูลต้นฉบับโดยตรง ดังนั้นการคาดการณ์ ข้อมูลล่วงหน้าของแต่ละชุดข้อมูลควรหาแบบจำลองที่ดีที่สุดแยกกันเพื่อความเหมาะสมตามกลุ่มสกุลเงินและตามช่วง ข้อมูล จากการศึกษาในการคาดการณ์ข้อมูลล่วงหน้าช่วงข้อมูล 1 เดือน ควรเพิ่มจำนวนข้อมูล ปรับการตั้งค่าการหา แบบจำลองที่ดีที่สุดด้วยการ Optimization ให้มีความละเอียดมากยิ่งขึ้น เนื่องด้วยข้อจำกัดของคอมพิวเตอร์อาจทำ ให้ผลที่ได้ดีกว่า เพื่อเพิ่มประสิทธิภาพของแบบจำลอง สามารถใช้แบบจำลองนี้ในการร่วมคาดการณ์อัตราแลกเปลี่ยน กับเครื่องมือทางการเงินอื่นได้ เพื่อประกอบการวิเคราะห์ทิศทางการเคลื่อนไหวของอัตราแลกเปลี่ยนได้ในอนาคต



ควรรนำปัจจัยทางเศรษฐกิจที่มีผลต่ออัตราการแลกเปลี่ยนของแต่ละคู่สกุลเงินเพื่อประกอบการวิเคราะห์และการ
คาดการณ์

กิตติกรรมประกาศ

ขอขอบคุณ อาจารย์ ดร. ธฤตพน อุ่สวัสดิ์ อาจารย์ที่ปรึกษา สำหรับการให้คำปรึกษาแนะนำในการศึกษา
ค้นคว้าอิสระและตรวจทานเนื้อหา

ขอขอบคุณ คุณสุวิชา ศศิวิมลกุล สำหรับการให้คำปรึกษาในเรื่องการเขียน โปรแกรม MATLAB และให้
ความช่วยเหลือ

เอกสารอ้างอิง

Abolfazl Nejatian. (2021). *Time Series Prediction by use of Deep learning and shallow learning algorithm.*

Retrieved from <https://www.mathworks.com/matlabcentral/fileexchange/69506-time-series-prediction>

Ben Krause. (2017). *LSTM (Long short-term memory)*. Retrieved from <https://github.com/benkrause/mLSTM>

Hualing Lin, Qiubi Sun and Sheng-Qun Chen. (2020). Reducing Exchange Rate Risks in International Trade: A
Hybrid Forecasting Approach of CEEMDAN and Multilayer LSTM. *Sustainability* 2020, 12(6), 2451.
doi:10.3390/su12062451

Jinliang Zhang, Dezhi Li, Yu Hao and Zhongfu Tan. (2018). A hybrid model using signal processing technology,
econometric models and neural network for carbon spot price forecasting. *Journal of Cleaner Production*,
204, 958-964, ISSN 0959-6526. doi: 10.1016/j.jclepro.2018.09.071

M.E.Torres, M.A. Colominas, G. Schlotthauer, and P. Flandrin. (2011). A Complete Ensemble Empirical Mode
Decomposition With Adaptive Noise. *2011 IEEE International Conference on Acoustics, Speech and
Signal Processing (ICASSP), 2011*, 4144-4147, doi: 10.1109/ICASSP.2011.5947265

Ren Ye. (2015). *EMD_EEMD (Ensemble empirical mode decomposition)*. Retrieved from
https://github.com/ron1818/PhD_code/blob/master/EMD_EEMD/ceemdan.m