

โครงการประชาสัมพันธ์สำหรับพยากรณ์ราคาสูงสุดและราคาต่ำสุดบนตลาดอัตราแลกเปลี่ยน



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

สาขาวิชาวิทยาศาสตร์คอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2562

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Neural Network for Forecasting High Price and Low Price on Foreign Exchange Market



A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Science in Computer Science

Department of Computer Engineering

FACULTY OF ENGINEERING

Chulalongkorn University

Academic Year 2019

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	โครงข่ายประสาทเทียมสำหรับพยากรณ์ราคาสูงสุดและราคาต่ำสุดบนตลาดอัตราแลกเปลี่ยน
โดย	นายชญณ ชินประสาทศักดิ์
สาขาวิชา	วิทยาศาสตร์คอมพิวเตอร์
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	ผู้ช่วยศาสตราจารย์ ดร.นัทที นิภานันท์

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

.....	คณบดีคณะวิศวกรรมศาสตร์
(ศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)	
คณะกรรมการสอบวิทยานิพนธ์	ประธานกรรมการ
.....	(ผู้ช่วยศาสตราจารย์ ดร.อรรณวิทย์ สุตแสง)
.....	อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(ผู้ช่วยศาสตราจารย์ ดร.นัทที นิภานันท์)	
.....	กรรมการ
(ดร.เอกพล ช่างสูวณิช)	
.....	กรรมการภายนอกมหาวิทยาลัย
(รองศาสตราจารย์ ดร.สรณะ นุชอนงค์)	

ชฎณ ชินประสาทศักดิ์ : โครงข่ายประสาทเทียมสำหรับพยากรณ์ราคาสูงสุดและราคาต่ำสุดบนตลาดอัตราแลกเปลี่ยน. (Neural Network for Forecasting High Price and Low Price on Foreign Exchange Market) อ.ที่ปรึกษาหลัก : ผศ. ดร.นัทธินิภาพันธ์

งานวิจัยนี้เปรียบเทียบโครงข่ายประสาทเทียม 4 แบบจำลองจากงานวิจัยต้นแบบ (I. โครงข่ายประสาทเทียมแบบส่งค่าย้อนกลับ II. โครงข่ายประสาทเทียมอย่างถูกต้องของเบส III. ขั้นตอนผสมผสานระหว่างการแยกส่วนประกอบของรูปแบบเชิงประจักษ์กับขั้นตอนโครงข่ายประสาทเทียมแบบความแรงของเวลาอย่างสุ่ม IV. ขั้นตอนผสมผสานระหว่างข้อมูลแบบสุ่มเชิงเวลาที่มีประสิทธิภาพกับโครงข่ายประสาทเทียมแบบเรเดียลเบซิสฟังก์ชัน) และงานวิจัยที่นำเสนอ 2 แบบจำลอง (I. ขั้นตอนผสมผสานระหว่างการแยกส่วนประกอบของรูปแบบเชิงประจักษ์, ข้อมูลแบบสุ่มเชิงเวลาที่มีประสิทธิภาพ และโครงข่ายประสาทเทียมแบบเรเดียลเบซิสฟังก์ชัน II. ขั้นตอนผสมผสานระหว่างการแยกส่วนประกอบของรูปแบบเชิงประจักษ์, ข้อมูลแบบสุ่มเชิงเวลาที่มีประสิทธิภาพ และโครงข่ายประสาทเทียมอย่างถูกต้องของเบส) ในการพยากรณ์อัตราแลกเปลี่ยนของคู่สกุลเงิน ยูโร/ดอลลาร์สหรัฐ โดยการใช้อินพุตเป็นตัวบ่งชี้ทางเทคนิคและวัดประสิทธิภาพของแบบจำลองด้วยระบบจำลองการซื้อขาย ซึ่งประกอบด้วย กลยุทธ์การลงทุน วิธีจัดการความเสี่ยง และหลักการบริหารเงิน ผลการทดลองแสดงให้เห็นว่าโครงข่ายประสาทเทียมที่นำเสนอให้ผลตอบแทนที่ดีกว่าแบบจำลองจากงานวิจัยต้นแบบ

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สาขาวิชา วิทยาศาสตร์คอมพิวเตอร์
ปีการศึกษา 2562

ลายมือชื่อนิสิต
ลายมือชื่อ อ.ที่ปรึกษาหลัก

5970119821 : MAJOR COMPUTER SCIENCE

KEYWORD: Machine Learning, Artificial Neural Network, Bayesian Regularization, Empirical Mode Decomposition, Stochastic Time Strength Function, Stochastic Time Strength Neural Network, Radial Basis Function, Radial Basis Function Neural Network, Exchange Rate, Prediction
 Krin Chinprasatsak : Neural Network for Forecasting High Price and Low Price on Foreign Exchange Market. Advisor: Asst. Prof. NATTEE NIPARNAN, Ph.D.

This research compares 4 neural networks from the original researches (I. Backpropagation Neural Network II. Bayesian Regularized Neural Network III. Empirical Mode Decomposition Stochastic Time Strength Neural Network IV. Random Data-time Effective Radial Basis Function Neural Network) and 2 proposed neural networks (I. Empirical Mode Decomposition Random Data-time Effective Radial Basis Function Neural Network II. Empirical Mode Decomposition Random Data-time Effective Bayesian Regularized Neural Network) for predicting the exchange rate of EUR/USD currency pairs using input as a technical indicator and evaluating the networks with trading simulations consisting of investment strategies, risk management methods and financial management principles. The experiments show that the proposed neural networks yield higher returns than the original researches.

Field of Study: Computer Science

Student's Signature

Academic Year: 2019

Advisor's Signature

กิตติกรรมประกาศ

วิทยานิพนธ์นี้สำเร็จลุล่วงได้ด้วยความกรุณาจาก ผู้ช่วยศาสตราจารย์ ดร. นันทิ นิภานันท์ อาจารย์ที่ปรึกษา ผู้คอยให้คำปรึกษา ให้แง่คิด ทั้งในด้านวิชาการและด้านอื่น ๆ และเป็นผู้ตรวจทาน แก้ไขทำให้วิทยานิพนธ์เล่มนี้ลุล่วงไปได้ด้วยดี ขอขอบพระคุณเป็นอย่างสูงมา ณ ที่นี้

ขอขอบพระคุณ ผศ.ดร. อรรถวิทย์ สุตแสง รศ.ดร.สรณะ นุชอนงค์ และ ดร.เอกพล ช่วงสุวนิช ผู้ให้เกียรติเป็นประธานกรรมการและกรรมการสอบวิทยานิพนธ์ ที่ชี้แนะแนวทางในการปรับปรุง วิทยานิพนธ์ให้มีคุณภาพยิ่งขึ้น

ที่สำคัญที่สุด ขอขอบคุณ คุณพ่อ คุณแม่ และครอบครัว ที่คอยเป็นกำลังใจในการทำงานวิจัยนี้ เสมอมา จนกระทั่งวิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงไปได้ด้วยดี

ชฎณ ชินประสาทศักดิ์



สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ค
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ฅ
สารบัญรูปภาพ.....	ญ
บทที่ 1 บทนำ	1
1.1 ที่มาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์ของงานวิจัย	3
1.3 ขอบเขตงานวิจัย	3
1.4 ประโยชน์ที่ได้รับจากงานวิจัย.....	3
1.5 วิธีดำเนินงานวิจัย.....	3
1.6 ผลงานวิจัยที่ได้ตีพิมพ์	4
บทที่ 2 ทฤษฎีที่เกี่ยวข้องและงานวิจัยที่เกี่ยวข้อง.....	5
2.1 ทฤษฎีที่เกี่ยวข้อง	5
2.1.1 โครงข่ายประสาทเทียม (Neural Network).....	5
2.1.2 ขั้นตอนการส่งค่าย้อนกลับ (Backpropagation).....	5
2.1.3 โครงข่ายประสาทเทียมอย่างถูกต้องของเบส์ (Bayesian Regularized Neural Network)	7
2.1.4 ขั้นตอนวิธีเลเวนเบิร์ก-มาร์ควาร์ด (Levenberg-Marquardt Algorithm).....	8
2.1.5 การแยกส่วนประกอบของรูปแบบเชิงประจักษ์ (Empirical Mode Decomposition) (EMD).....	9

2.1.6	โครงข่ายประสาทเทียมแบบความแรงของเวลาอย่างสุ่ม (Stochastic Time Strength Neural Network) (STNN).....	11
2.1.7	ขั้นตอนผสมผสานระหว่างการแยกส่วนประกอบของรูปแบบเชิงประจักษ์กับขั้นตอนโครงข่ายประสาทเทียมแบบความแรงของเวลาอย่างสุ่ม (Empirical Mode Decomposition Stochastic Time Strength Neural Network) (EMD-STNN)..	12
2.1.8	ขั้นตอนผสมผสานระหว่างข้อมูลแบบสุ่มเชิงเวลาที่มีประสิทธิภาพกับโครงข่ายประสาทเทียมแบบเรเดียลเบซิสฟังก์ชัน (Random Data-time Effective Radial Basis Function Neural Network) (RT-RBFNN)	13
2.2	งานวิจัยที่เกี่ยวข้อง.....	15
2.2.1	งานวิจัยต้นแบบ.....	15
2.2.2	งานวิจัยด้านการวิเคราะห์ทางเทคนิค	16
2.2.3	งานวิจัยด้านการวิเคราะห์ปัจจัยพื้นฐาน.....	18
บทที่ 3	งานวิจัยที่นำเสนอ.....	20
3.1	แรงบันดาลใจ.....	20
3.2	ขั้นตอนผสมผสานระหว่างการแยกส่วนประกอบของรูปแบบเชิงประจักษ์, ข้อมูลแบบสุ่มเชิงเวลาที่มีประสิทธิภาพ และโครงข่ายประสาทเทียมแบบเรเดียลเบซิสฟังก์ชัน (Empirical Mode Decomposition Random Data-time Effective Radial Basis Function Neural Network) (EMD-RT-RBFNN).....	20
3.2.1	การใช้งาน EMD	22
3.2.2	การตั้งค่าเบื้องต้นของ EMD-RT-RBFNN	23
3.2.3	เอาต์พุตของ EMD-RT-RBFNN.....	24
3.3	ขั้นตอนผสมผสานระหว่างการแยกส่วนประกอบของรูปแบบเชิงประจักษ์, ข้อมูลแบบสุ่มเชิงเวลาที่มีประสิทธิภาพ และโครงข่ายประสาทเทียมอย่างถูกต้องของเบสส์ (Empirical Mode Decomposition Random Data-time Effective Radial Basis Function Neural Network) (EMD-RT-BRNN).....	25
3.3.1	การใช้งาน EMD	26

3.2.2 การตั้งค่าเบื้องต้นของ EMD-RT-BRNN	27
3.2.3 เาต์พุตของ EMD-RT- BRNN.....	28
3.4 ชุดข้อมูล	28
บทที่ 4 ระบบจำลองการซื้อขาย.....	30
4.1 ความสำคัญของระบบจำลองการซื้อขาย	30
4.2 ระบบจำลองการซื้อขาย	30
4.3 ผลการทดลอง	34
4.4 สรุปผลการทดลอง	35
บทที่ 5 สรุปผลการวิจัย และข้อเสนอแนะ	36
5.1 สรุปผลการวิจัย	36
5.2 ข้อเสนอแนะ	37
บรรณานุกรม.....	39
ประวัติผู้เขียน.....	42



สารบัญตาราง

	หน้า
ตารางที่ 1 แสดงการตั้งค่าเบื้องต้นสำหรับแบบจำลองทั้งหมดของ EMD-RT-RBFNN.....	24
ตารางที่ 2 แสดงการตั้งค่าเบื้องต้นสำหรับแบบจำลองทั้งหมดของ EMD-RT-BRNN.....	28
ตารางที่ 3 ประสิทธิภาพของแบบจำลอง.....	35



สารบัญรูปภาพ

หน้า

ภาพที่ 1 แสดงตัวอย่างโครงข่ายประสาทเทียมที่มีการเปลี่ยนค่าน้ำหนักที่ส่งจากปมที่ 1 ไปปมที่ 4 .. 6	
ภาพที่ 2 ลำดับขั้นตอนการทำงานของ EMD-RT-RBFNN	21
ภาพที่ 3 แบบจำลองสำหรับพยากรณ์ราคาสูงสุดและราคาต่ำสุดของ EMD-RT-RBFNN	22
ภาพที่ 4 ซ้าย) แสดงการใช้งาน EMD กับอนุกรมเวลาของราคาสูงสุด ขวา) แสดงการใช้งาน EMD กับอนุกรมเวลาของราคาต่ำสุด (ที่มา : [2])	23
ภาพที่ 5 ลำดับขั้นตอนการทำงานของ EMD-RT-BRNN	25
ภาพที่ 6 แบบจำลองสำหรับพยากรณ์ราคาสูงสุดและราคาต่ำสุดของ EMD-RT-BRNN	26
ภาพที่ 7 ซ้าย) แสดงการใช้งาน EMD กับอนุกรมเวลาของราคาสูงสุด ขวา) แสดงการใช้งาน EMD กับอนุกรมเวลาของราคาต่ำสุด (ที่มา : [2])	27
ภาพที่ 8 ตัวอย่างที่ 1 ของระบบจำลองการซื้อขาย (ที่มา : https://www.tradingview.com/chart/Uy3q4WdP/)	32
ภาพที่ 9 ตัวอย่างที่ 2 ของระบบจำลองการซื้อขาย (ที่มา : https://www.tradingview.com/chart/Uy3q4WdP/)	33
ภาพที่ 10 ตัวอย่างที่ 3 ของระบบจำลองการซื้อขาย (ที่มา : https://www.tradingview.com/chart/Uy3q4WdP/)	34

บทที่ 1 บทนำ

1.1 ที่มาและความสำคัญของปัญหา

ตลาดอัตราแลกเปลี่ยนเป็นตลาดการเงินที่ใหญ่ที่สุดในโลกด้วยปริมาณการซื้อขายต่อวันที่มากกว่า 6.6 ล้านล้านดอลลาร์สหรัฐ (ณ เมษายน 2563) [1] เป็นมูลค่ามากกว่า 23 เท่าของมูลค่าการซื้อขายเฉลี่ยต่อวันของตลาดทุนโลกและมากกว่า 40 เท่าของผลประกอบการประจำปีของผลิตภัณฑ์มวลรวมโลก การพยากรณ์อัตราแลกเปลี่ยนเป็นสิ่งท้าทายนักวิจัยทั่วโลกเนื่องจากผลประโยชน์ที่น่าสนใจในการลงทุน [2] อย่างไรก็ตามการพยากรณ์อัตราแลกเปลี่ยนมีความซับซ้อนมาก เนื่องจากสถานะแวดล้อมที่เต็มไปด้วยสัญญาณรบกวนและความผันผวนที่สูง [3] ความซับซ้อนของการเคลื่อนไหวของอัตราแลกเปลี่ยนมีความเกี่ยวข้องกับหลายปัจจัยได้แก่ เศรษฐกิจ, การเมือง, ภัยธรรมชาติ และการเก็งกำไร โดยเฉลี่ยแล้วมากกว่า 90% ของปริมาณการซื้อขายในแต่ละวันในตลาดอัตราแลกเปลี่ยนคือการเก็งกำไร [4] เทคนิคทางสถิติแบบดั้งเดิมสำหรับการพยากรณ์ได้มาถึงขีดจำกัดในการประยุกต์ใช้งานกับข้อมูลที่ไม่เป็นเชิงเส้น เช่นอัตราแลกเปลี่ยนคู่สกุลเงิน [5] ปัญญาประดิษฐ์เข้ามามีบทบาทในการวิเคราะห์และพยากรณ์ข้อมูลที่มีความซับซ้อนเกินกว่าความสามารถทางสถิติจะแก้ได้ ผู้จัดทำมีความสนใจในการใช้ปัญญาประดิษฐ์เพื่อพยากรณ์อัตราแลกเปลี่ยนคู่สกุลเงิน ขั้นตอนวิธีในการวิเคราะห์ข้อมูลของปัญญาประดิษฐ์มีอยู่ด้วยกันหลายวิธี เช่น โครงข่ายประสาทเทียม (Artificial Neural Network), ต้นไม้ตัดสินใจ (Decision Tree), การเรียนรู้ของเบย์ (Bayesian Learning), ขั้นตอนวิธีเชิงพันธุกรรม (Genetic Algorithm) ฯลฯ ในงานวิจัยนี้ผู้จัดทำมีความสนใจใช้โครงข่ายประสาทเทียมในการพยากรณ์ข้อมูล เนื่องจากความสามารถของโครงข่ายประสาทเทียมที่สามารถประมาณฟังก์ชันต่อเนื่องไม่เชิงเส้นใด ๆ ก็ได้โดยไม่ต้องกำหนดรูปแบบอย่างเป็นทางการให้กับแบบจำลอง [6]

ในงานวิจัยนี้ผู้จัดทำวัดประสิทธิภาพของโครงข่ายประสาทเทียม (Artificial Neural Network) จากงานวิจัยต้นแบบ 4 ขั้นตอนวิธี และโครงข่ายประสาทเทียมที่นำเสนอ 3 ขั้นตอนวิธี ในการพยากรณ์อัตราแลกเปลี่ยนรายวันของคู่สกุลเงิน EUR/USD บนระบบจำลองการซื้อขาย

ผู้จัดทำเลือก 4 ขั้นตอนวิธี ได้แก่ 1. โครงข่ายประสาทเทียมแบบส่งค่าย้อนกลับ (Backpropagation Neural Network) (BPNN) 2. โครงข่ายประสาทเทียมอย่างถูกต้องของเบย์ (Bayesian Regularized Neural Network) (BRNN) 3. ขั้นตอนผสมผสานระหว่างการแยกส่วนประกอบของรูปแบบเชิงประจักษ์กับโครงข่ายประสาทเทียมแบบความแรงของเวลาอย่างสุ่ม (Empirical Mode Decomposition Stochastic Time Strength Neural Network) (EMD-STNN) 4. ขั้นตอนผสมผสานระหว่างข้อมูลแบบสุ่มเชิงเวลาที่มีประสิทธิภาพกับโครงข่ายประสาทเทียมแบบเรเดียลเบซิส

ฟังก์ชัน (Random Data-time Effective Radial Basis Function Neural Network) มาใช้ในการพยากรณ์อัตราแลกเปลี่ยนคู่สกุลเงินด้วยเหตุผล 3 ประการ 1) ขั้นตอนวิธีทั้ง 4 สามารถพยากรณ์ราคาได้อย่างแม่นยำในตลาดหุ้นซึ่งมีลักษณะของข้อมูลเป็นแบบอนุกรมเวลาเหมือนกับตลาดอัตราแลกเปลี่ยน 2) ขั้นตอนวิธีทั้ง 4 ใช้อินพุตเป็นตัวบ่งชี้ทางเทคนิค (Technical Indicator) ที่มีในตลาดอัตราแลกเปลี่ยน 3) ขั้นตอนวิธีทั้ง 4 ถูกตีพิมพ์ในงานวิจัยที่มีจำนวนผู้อ้างอิงเยอะและงานวิจัยเหล่านี้ อยู่ในวารสารที่มีดัชนีเฮิร์สช์ (Hirsch Index) (H Index) สูง

ผู้จัดทำได้นำเสนอโครงข่ายประสาทเทียมขึ้นมา 2 ขั้นตอนวิธี ได้แก่ 1. ขั้นตอนผสมผสานระหว่างการแยกส่วนประกอบของรูปแบบเชิงประจักษ์, ข้อมูลแบบสุ่มเชิงเวลาที่มีประสิทธิภาพ และโครงข่ายประสาทเทียมแบบเรเดียลเบสฟังก์ชัน (Empirical Mode Decomposition Random Data-time Effective Radial Basis Function Neural Network) (EMD-RT-RBFNN) 2. ขั้นตอนผสมผสานระหว่างการแยกส่วนประกอบของรูปแบบเชิงประจักษ์, ข้อมูลแบบสุ่มเชิงเวลาที่มีประสิทธิภาพ และโครงข่ายประสาทเทียมอย่างถูกต้องของเบส์ (Empirical Mode Decomposition Random Data-time Effective Bayesian Regularized Neural Network) (EMD-RT-BRNN) ในการพยากรณ์อัตราแลกเปลี่ยนคู่สกุลเงินด้วยเหตุผล 3 ประการ 1) การใช้ EMD อาจให้ผลลัพธ์การพยากรณ์ที่แม่นยำมากขึ้น เพราะการใช้ EMD-STNN ให้ผลลัพธ์การพยากรณ์ที่แม่นยำกว่า STNN บนข้อมูลตลาดหุ้น 2) การใช้ RT-RBFNN อาจให้ผลลัพธ์การพยากรณ์ที่แม่นยำมากขึ้น เพราะการใช้ RT-RBFNN ให้ผลลัพธ์การพยากรณ์ที่แม่นยำกว่า STNN บนข้อมูลตลาดหุ้น 3) การใช้การทำให้อายุของเบส์ (Bayesian Regularization) อาจให้ผลลัพธ์การพยากรณ์ที่แม่นยำขึ้น เนื่องจาก Bayesian Regularization ช่วยลดปัญหาความพอดีที่มากเกินไปของข้อมูลที่ใช้สอน (Overfitting) และการเรียนที่มากเกินไป (Overtraining) ซึ่งเพิ่มประสิทธิภาพในการพยากรณ์ของโครงข่ายประสาทเทียม ปัญหาที่ต้องแก้ในงานนี้สามารถแบ่งได้เป็น 3 ส่วนหลัก ๆ ได้แก่ 1) การเคลื่อนไหวเฉลี่ยรายวันของแต่ละคู่สกุลเงินในตลาดอัตราแลกเปลี่ยนมีค่าน้อยกว่า 1% ในขณะที่หุ้นมีการเคลื่อนไหวเฉลี่ยรายวันของราคาเฉลี่ยอยู่ที่ 10% ความผิดพลาดในการพยากรณ์เพียงเล็กน้อยอาจทำให้ผลลัพธ์ในการลงทุนติดลบได้ 2) พฤติกรรมที่แตกต่างกันระหว่างตลาดหุ้นและตลาดอัตราแลกเปลี่ยน ตลาดหุ้นมีเวลาเปิดและปิดตลาดที่แน่นอนในวันทำงาน (จันทร์ - ศุกร์) ในขณะที่ตลาดอัตราแลกเปลี่ยนเปิดตลอด 24 ชั่วโมงตลอด 5 วัน ในการพยากรณ์อัตราแลกเปลี่ยนคู่สกุลเงินรายวันการที่ตลาดอัตราแลกเปลี่ยนไม่มีเวลาเปิดและปิดตลาดที่แน่นอนทำให้ตัวบ่งชี้ทางเทคนิค (Technical Indicator) มีความไม่ชัดเจนแตกต่างจากตลาดหุ้นที่ตัวบ่งชี้ทางเทคนิคมีความชัดเจนมากกว่า 3) การวัดประสิทธิภาพทั่ว ๆ ไป เช่น ค่าเฉลี่ยของค่าผิดพลาดยกกำลังสอง (Mean Squared Error) (MSE), ค่าเฉลี่ยของค่าคลาดเคลื่อนสมบูรณ์ (Mean Absolute Error) (MAE) และค่าเฉลี่ยของร้อยละความผิดพลาดสมบูรณ์ (Mean Absolute Percentage Error) (MAPE) ไม่ได้บ่งชี้ถึงประสิทธิภาพที่ได้จากการ

ลงทุนจริง [7] ดังนั้นในงานวิจัยนี้เราจะทำการสร้างระบบจำลองการซื้อขาย (Trading System) ขึ้นมาเพื่อวัดประสิทธิภาพของโครงข่ายประสาทเทียมแต่ละขั้นตอนวิธีเมื่อนำผลลัพธ์ไปใช้ในการลงทุน ระบบจำลองการซื้อขายประกอบด้วย 3 ส่วนหลักได้แก่ กลยุทธ์การลงทุน, วิธีการจัดการความเสี่ยง และหลักการบริหารเงิน

1.2 วัตถุประสงค์ของงานวิจัย

สร้างโครงข่ายประสาทเทียมจากงานวิจัยต้นแบบ 4 ขั้นตอนวิธี และโครงข่ายประสาทเทียมที่นำเสนอ 2 ขั้นตอนวิธี ในการพยากรณ์อัตราแลกเปลี่ยนของคู่สกุลเงิน EUR/USD โดยใช้อินพุตเป็นตัวบ่งชี้ทางเทคนิค (Technical Indicator) และวัดผลโครงข่ายประสาทเทียมด้วยระบบจำลองการซื้อขายที่มีกลยุทธ์การลงทุน, วิธีจัดการความเสี่ยง และหลักการบริหารเงิน

1.3 ขอบเขตงานวิจัย

- 1) ใช้ข้อมูลอัตราแลกเปลี่ยนของคู่สกุลเงิน EUR/USD ตั้งแต่วันที่ 12 พฤษภาคม 2548 ถึง 6 ธันวาคม 2562 เท่านั้น
- 2) ใช้อินพุตเป็นตัวบ่งชี้ทางเทคนิค (Technical Indicator) เท่านั้น
- 3) ใช้ขั้นตอนวิธีในการพยากรณ์ดังกล่าวในบทที่ 3 เท่านั้น
- 4) ทำการวัดผลด้วยระบบจำลองการซื้อขาย (Trading System) ที่มีกลยุทธ์การลงทุน, วิธีจัดการความเสี่ยง และหลักการบริหารเงิน ดังกล่าวในบทที่ 4 เท่านั้น

1.4 ประโยชน์ที่ได้รับจากงานวิจัย

ได้โครงข่ายประสาทเทียม (Artificial Neural Network) ที่เหมาะสมในการพยากรณ์อัตราแลกเปลี่ยนคู่สกุลเงิน EUR/USD

1.5 วิธีดำเนินงานวิจัย

- 1) ศึกษางานวิจัยที่เกี่ยวข้องกับการพยากรณ์อนุกรมเวลาทางการเงิน
- 2) เลือกรงานวิจัยต้นแบบด้านการพยากรณ์อนุกรมเวลาทางการเงิน
- 3) ศึกษาทฤษฎีในงานวิจัยต้นแบบ
- 4) ศึกษาวิธีการวัดผลในงานวิจัยต้นแบบ
- 5) สร้างแบบจำลองเพื่อพยากรณ์ราคาสูงสุดและต่ำสุดของคู่สกุลเงิน EUR/USD
- 6) วัดผล, เปรียบเทียบ และสรุปผลที่ได้
- 7) จัดทำเอกสารวิทยานิพนธ์

1.6 ผลงานวิจัยที่ตีพิมพ์

K. Chinprasatsak, N. Niparnan, A. Sudsang, “Neural Network for Forecasting High Price and Low Price on Foreign Exchange Market”, Seventeenth International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI), 2020



บทที่ 2 ทฤษฎีที่เกี่ยวข้องและงานวิจัยที่เกี่ยวข้อง

2.1 ทฤษฎีที่เกี่ยวข้อง

2.1.1 โครงข่ายประสาทเทียม (Neural Network)

โครงข่ายประสาทเทียม [7] เป็นขั้นตอนวิธีที่สามารถส่งค่าจากอินพุตไปหาเอาต์พุต โดยการแปลงผลรวมเชิงเส้นไปสู่ฟังก์ชันไม่เชิงเส้น เราสามารถคำนวณค่าความผิดพลาดของโครงข่ายประสาทเทียมได้จากฟังก์ชันความผิดพลาด นิยามฟังก์ชันความผิดพลาด $E(\vec{w})$ ได้ดังสมการต่อไปนี้

$$E(\vec{w}) = \frac{1}{2} \sum_{p \in P} (t_p - a_p)^2$$

โดยที่

P เป็นชุดข้อมูลสอน

t_p เป็นเอาต์พุตเป้าหมายในตัวอย่างที่ p

a_p เป็นเอาต์พุตที่ได้จากการพยากรณ์ในตัวอย่างที่ p

$E(\vec{w})$ เป็นฟังก์ชันของ \vec{w} ในที่นี้เราต้องการที่จะหา \vec{w} ที่ทำให้ค่าความผิดพลาดน้อยที่สุดในระดับท้องถิ่นหรือในระดับสากล ในงานวิจัยนี้เราจะอธิบาย 2 ขั้นตอนวิธีที่ใช้ในการปรับค่า \vec{w} ซึ่งได้แก่ 1) ขั้นตอนการส่งค่าย้อนกลับ 2) ขั้นตอนวิธีเลเวนเบิร์ก-มาร์ควาร์ด

2.1.2 ขั้นตอนการส่งค่าย้อนกลับ (Backpropagation)

ขั้นตอนการส่งค่าย้อนกลับ (Backpropagation Algorithm) [8] เป็นขั้นตอนวิธีที่ถูกใช้ในโครงข่ายประสาทเทียมเพื่อคำนวณความชันของกราฟความผิดพลาดและค่าน้ำหนัก ซึ่งความชันนี้จำเป็นสำหรับการปรับค่าน้ำหนักของโครงข่ายประสาทเทียมในหลักการการเคลื่อนลงตามความชัน (Gradient Descent) ซึ่งสามารถอธิบายได้ดังสมการต่อไปนี้

$$\vec{w}_{k+1} = \vec{w}_k - \eta \nabla E(\vec{w}_k)$$

โดยที่


\vec{w}_{k+1} เป็นเวกเตอร์ค่าน้ำหนักในรอบที่ $k + 1$

\vec{w}_k เป็นเวกเตอร์ค่าน้ำหนักในรอบที่ k

η เป็นอัตราการเรียนรู้

ตัวอย่าง

พิจารณาเครือข่ายประสาทเทียมดังแสดงในภาพที่ 1



ภาพที่ 1 แสดงตัวอย่างโครงข่ายประสาทเทียมที่มีการเปลี่ยนค่าน้ำหนักที่ส่งจากปมที่ 1 ไปปมที่ 4

การเปลี่ยนแปลงค่าน้ำหนักที่ส่งจากปมที่ 1 ไปปมที่ 4 (w_{14}) ทำให้ฟังก์ชันค่าผิดพลาดมีการเปลี่ยนแปลง และเราสามารถหาอัตราการเปลี่ยนแปลงของฟังก์ชันค่าผิดพลาด ต่อ w_{14} ($\frac{\partial E(\vec{w})}{\partial w_{14}}$) ได้ เราสามารถบรรยายผลจากการเปลี่ยนแปลง w_{14} ได้ดังนี้

w_{14} เปลี่ยนแปลง ทำให้ z_4 เปลี่ยนแปลง

z_4 เปลี่ยนแปลง ทำให้ a_4 เปลี่ยนแปลง

a_4 เปลี่ยนแปลง ทำให้ z_7 และ z_8 เปลี่ยนแปลง

z_7 และ z_8 เปลี่ยนแปลง ทำให้ a_7 และ a_8 เปลี่ยนแปลงตามลำดับ

a_7 และ a_8 เปลี่ยนแปลง ทำให้ $E_7(\vec{w})$ และ $E_8(\vec{w})$ เปลี่ยนแปลงตามลำดับ โดยที่

$$\begin{aligned} z_4 &= b_4 + w_{14}a_1 + w_{24}a_2 + w_{34}a_3 \\ a_4 &= \sigma(z_4) \\ z_7 &= b_7 + w_{47}a_4 + w_{57}a_5 + w_{67}a_6 \\ a_7 &= \sigma(z_7) \\ z_8 &= b_8 + w_{48}a_4 + w_{58}a_5 + w_{68}a_6 \\ a_8 &= \sigma(z_8) \end{aligned}$$

สามารถเขียนเป็นสมการโดยใช้กฎลูกโซ่ (Chain Rule) ได้ดังนี้

$$\frac{\partial E(\vec{w})}{\partial w_{14}} = \frac{\partial E_7(\vec{w})}{\partial w_{14}} + \frac{\partial E_8(\vec{w})}{\partial w_{14}}$$

$$\begin{aligned}
&= \frac{\partial E_7(\vec{w})}{\partial a_7} \frac{\partial a_7}{\partial z_7} \frac{\partial z_7}{\partial a_4} \frac{\partial a_4}{\partial z_4} \frac{\partial z_4}{\partial w_{14}} + \frac{\partial E_8(\vec{w})}{\partial a_8} \frac{\partial a_8}{\partial z_8} \frac{\partial z_8}{\partial a_4} \frac{\partial a_4}{\partial z_4} \frac{\partial z_4}{\partial w_{14}} \\
&= \left(\frac{\partial E_7(\vec{w})}{\partial a_7} \frac{\partial a_7}{\partial z_7} \frac{\partial z_7}{\partial a_4} + \frac{\partial E_8(\vec{w})}{\partial a_8} \frac{\partial a_8}{\partial z_8} \frac{\partial z_8}{\partial a_4} \right) \frac{\partial a_4}{\partial z_4} \frac{\partial z_4}{\partial w_{14}}
\end{aligned}$$

2.1.3 โครงข่ายประสาทเทียมอย่างถูกต้องของเบส์ (Bayesian Regularized Neural Network)

โครงข่ายประสาทเทียมอย่างถูกต้องของเบส์ (Bayesian Regularized Neural Network) เป็นกระบวนการที่ช่วยลดปัญหาความพอดีที่มากเกินไปของข้อมูลที่ใช้สอน (Overfitting) และการเรียนที่มากเกินไป (Overtraining) ซึ่งเพิ่มประสิทธิภาพในการพยากรณ์และในการทำให้ถูกต้องของโครงข่ายประสาทเทียม

ใน โครงข่ายประสาทเทียมอย่างถูกต้องของเบส์ (Bayesian Regularized Neural Network) มีการกำหนดฟังก์ชันค่าผิดพลาดใหม่ดังสมการต่อไปนี้

$$F(\vec{w}) = \beta E_D(\vec{w}) + \alpha E_W(\vec{w})$$

โดยที่

$$\begin{aligned}
E_D(\vec{w}) &= \sum_{p=1}^P \sum_{m=1}^M e_{p,m}^2 \\
E_W(\vec{w}) &= \sum_{n=1}^N w_n^2
\end{aligned}$$

β และ α คือสัมประสิทธิ์ที่เราต้องการหาเพื่อทำให้โครงข่ายประสาทเทียมมีความถูกต้องมากที่สุด

เราสามารถหา α และ β ด้วย 5 ขั้นตอนต่อไปนี้

- 1) กำหนดค่าเริ่มต้นของ α , β และค่าน้ำหนัก ในที่นี้เราเลือก $\alpha = 0$, $\beta = 1$ และสุ่มค่าของค่าน้ำหนักแต่ละตัวในช่วง $[0, 1]$
- 2) ใช้ขั้นตอนเลเวนเบิร์ก-มาร์ควาร์ด (Levenberg-Marquardt Algorithm) เพื่อลดฟังก์ชันค่าผิดพลาดให้น้อยที่สุด ในขั้นตอนนี้เราจะได้เวกเตอร์ค่าน้ำหนักที่ทำให้ฟังก์ชันค่าผิดพลาดมีค่าน้อยสุดระดับท้องถิ่น
- 3) คำนวณตัวแปรที่มีประสิทธิภาพ $\gamma = N - 2\alpha \text{tr}(H)^{-1}$ โดยที่ $H \approx 2\beta J^T J + 2\alpha I_N$
- 4) คำนวณค่า α และ β สำหรับฟังก์ชันค่าผิดพลาดใหม่ $\alpha = \frac{\gamma}{2E_W(\vec{w})}$ และ $\beta = \frac{n-\gamma}{2E_D(\vec{w})}$
- 5) ทำซ้ำขั้นตอนที่ 2 ถึง 4 จนกว่า α และ β ลู่เข้า

2.1.4 ขั้นตอนวิธีเลเวนเบิร์ก-มาร์ควาร์ด (Levenberg-Marquardt Algorithm)

ขั้นตอนวิธีเลเวนเบิร์ก-มาร์ควาร์ด (Levenberg-Marquardt Algorithm) [9-11] เป็นอีกขั้นตอนวิธีที่ใช้ในการปรับค่าน้ำหนักของโครงข่ายประสาทเทียม ซึ่งวิธีการนี้ผสมผสานข้อดีด้านความเร็วในการปรับค่าน้ำหนักของขั้นตอนวิธีเกาส์-นิวตัน (Gauss-Newton Algorithm) และความมีเสถียรภาพของขั้นตอนวิธีการส่งค่าย้อนกลับ (Backpropagation Algorithm) เพื่อความสะดวกในการอธิบายการปรับค่าน้ำหนักโดยขั้นตอนวิธีเลเวนเบิร์ก-มาร์ควาร์ด ขอนิยามฟังก์ชันค่าผิดพลาดใหม่ (Cost Function) $E(\vec{w})$ ดังสมการต่อไปนี้

$$E(\vec{w}) = \frac{1}{2} \sum_{p=1}^P \sum_{m=1}^M e_{p,m}^2$$

โดยที่

p เป็นดัชนีของตัวอย่างมีค่าตั้งแต่ 1 ถึง P

m เป็นดัชนีของเอาต์พุตมีค่าตั้งแต่ 1 ถึง M

$e_{p,m}$ เป็นผลต่างของเอาต์พุตเป้าหมายและเอาต์พุตของโครงข่ายประสาทเทียมที่ m ในตัวอย่างที่ p ซึ่งสามารถนิยามได้ดังสมการต่อไปนี้

$$e_{p,m} = t_{p,m} - a_{p,m}$$

โดยที่

$t_{p,m}$ เป็นเอาต์พุตเป้าหมายที่ m ในตัวอย่างที่ p

$a_{p,m}$ เป็นเอาต์พุตของโครงข่ายประสาทเทียมที่ m ในตัวอย่างที่ p

การปรับค่าน้ำหนักของขั้นตอนวิธีเลเวนเบิร์ก-มาร์ควาร์ด (Levenberg-Marquardt Algorithm) อธิบายดังสมการต่อไปนี้

$$\vec{w}_{k+1} = \vec{w}_k - (J_k^T J_k + \lambda I)^{-1} J_k \vec{e}_k$$

โดยที่

\vec{w}_{k+1} เป็นเวกเตอร์ค่าน้ำหนักในรอบที่ $k + 1$

\vec{w}_k เป็นเวกเตอร์ค่าน้ำหนักในรอบที่ k

J_k เป็นจาโคเบียนเมทริกซ์ในรอบที่ k

\vec{e}_k เป็นเวกเตอร์ผลต่างระหว่างเอาต์พุตเป้าหมายและเอาต์พุตของโครงข่ายประสาท

เทียมในรอบที่ k

เรานิยามจาโคเบียนเมทริกซ์ J ได้ดังสมการต่อไปนี้

$$J = \begin{bmatrix} \frac{\partial e_{1,1}}{\partial w_1} & \frac{\partial e_{1,1}}{\partial w_2} & \cdots & \frac{\partial e_{1,1}}{\partial w_N} \\ \frac{\partial e_{1,2}}{\partial w_1} & \frac{\partial e_{1,2}}{\partial w_2} & \cdots & \frac{\partial e_{1,2}}{\partial w_N} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_{1,M}}{\partial w_1} & \frac{\partial e_{1,M}}{\partial w_2} & \cdots & \frac{\partial e_{1,M}}{\partial w_N} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_{p,1}}{\partial w_1} & \frac{\partial e_{p,1}}{\partial w_2} & \cdots & \frac{\partial e_{p,1}}{\partial w_N} \\ \frac{\partial e_{p,2}}{\partial w_1} & \frac{\partial e_{p,2}}{\partial w_2} & \cdots & \frac{\partial e_{p,2}}{\partial w_N} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_{p,M}}{\partial w_1} & \frac{\partial e_{p,M}}{\partial w_2} & \cdots & \frac{\partial e_{p,M}}{\partial w_N} \end{bmatrix}$$

โดยที่ N เป็นจำนวนค่าน้ำหนักทั้งหมดในโครงข่ายประสาทเทียม

และนิยามเวกเตอร์ผลต่างระหว่างเอาต์พุตเป้าหมายและเอาต์พุตของโครงข่ายประสาทเทียม \vec{e} ได้ดังสมการต่อไปนี้

$$e = \begin{bmatrix} e_{1,1} \\ e_{1,2} \\ \vdots \\ e_{1,M} \\ \vdots \\ e_{p,1} \\ e_{p,2} \\ \vdots \\ e_{p,M} \end{bmatrix}$$

2.1.5 การแยกส่วนประกอบของรูปแปดเชิงประจักษ์ (Empirical Mode Decomposition) (EMD)

การแยกส่วนประกอบของรูปแบบเชิงประจักษ์ (Empirical mode decomposition) (EMD) [2] เป็นกระบวนการที่เสนอขึ้นเพื่อสกัดความผันผวนที่ฝังตัวอยู่ในอนุกรมเวลาออกมาเป็นฟังก์ชันรูปแบบที่แท้จริง (Intrinsic Mode Function) (IMF) หลายชุด และส่วนเหลือ (Residual) 1 ชุด ซึ่ง IMF จะมีคุณสมบัติ 2 ข้อคือ

1. ตลอดช่วงทั้งหมดของข้อมูล จำนวนของจุดสุดขีดสัมพัทธ์ต้องเท่ากับจำนวนครั้งที่กราฟตัดแกน X หรือต่างกัน 1
2. ที่ทุกจุดของข้อมูล ค่าเฉลี่ยของกรอบบนและกรอบล่างต้องเป็น 0

เราสามารถอธิบายวิธีการสกัดความผันผวนด้วย 6 ขั้นตอนต่อไปนี้

- 1) หาจุดสูงสุดระดับท้องถิ่นและจุดต่ำสุดระดับท้องถิ่นทั้งหมดของอนุกรมเวลา $X(t)$
- 2) เชื่อมจุดสูงสุดระดับท้องถิ่นด้วยคิวบิกสไปลน์ (Cubic Spline) เพื่อกำหนดกรอบบน (Upper Envelope) $U(t)$ เชื่อมจุดต่ำสุดระดับท้องถิ่นด้วยคิวบิกสไปลน์ (Cubic Spline) เพื่อกำหนดกรอบล่าง (Lower Envelope) $L(t)$
- 3) คำนวณกรอบเฉลี่ยแบบจุดต่อจุด $m(t)$ ซึ่งนิยามโดย $m(t) = (U(t) + L(t))/2$
- 4) คำนวณตัวเลือก IMF ได้จาก $h(t) = X(t) - m(t)$
- 5) พิจารณา $h(t)$ เป็นอนุกรมเวลาและทำซ้ำขั้นตอนที่ 1 ถึง 4 จนกว่ากรอบบนและกรอบล่างจะสมมาตรซึ่งหมายถึงค่าเฉลี่ยของ $U(t)$ และ $L(t)$ ที่เป็น 0 ที่ทุกจุดของข้อมูล ถ้า $h(t)$ มีคุณสมบัติเป็น IMF ครบทั้ง 2 ข้อ รับ $h(t)$ เป็น IMF ลำดับที่ i (เริ่มต้นที่ 1 และเพิ่มขึ้นทีละ 1) แสดงโดย $C_i(t)$ และแทนที่ $X(t)$ ด้วยส่วนเหลือ (Residual) ซึ่งคำนวณได้ดังนี้ $R_i(t) = X(t) - C_i(t)$
- 6) ทำซ้ำขั้นตอนที่ 1 ถึง 5 โดยสกัดส่วนเหลือ (Residual) จนกระทั่งถึงเงื่อนไขการหยุด

หลังจากเสร็จสิ้นขั้นตอนการสกัดทั้งหมด เราได้ส่วนเหลือ (Residual) และกลุ่มของ IMF ซึ่งตั้งชื่อว่า $C_i(t)$ ($i = 1, 2, \dots, M$) เราสามารถสร้าง $X(t)$ ขึ้นมาใหม่ได้จากการรวมทุก ๆ $C_i(t)$ และส่วนเหลือ (Residual) บรรยายได้ดังสมการต่อไปนี้

$$R_M(t) = X(t) - \sum_{i=1}^M C_i(t)$$

โดยที่

$$R_i(t) = R_{i-1}(t) - C_i(t)$$

2.1.6 โครงข่ายประสาทเทียมแบบความแรงของเวลาอย่างสุ่ม (Stochastic Time Strength Neural Network) (STNN)

โครงข่ายประสาทเทียมแบบความแรงของเวลาอย่างสุ่ม (Stochastic Time Strength Neural Network) (STNN) [2] เป็นโครงข่ายประสาทเทียมที่มีการพิจารณาค่าน้ำหนักของแต่ละจุดข้อมูลที่เกิดขึ้นในอนุกรมเวลา โดยมีการกำหนดฟังก์ชันค่าผิดพลาดใหม่ดังสมการต่อไปนี้

$$E(t_n) = \frac{1}{N} \sum_{n=1}^N \rho(t_n) (d_{t_n} - y_{t_n})^2$$

โดยที่

t_n เป็นเวลาของตัวอย่าง n

d_{t_n} เป็นเอาต์พุตเป้าหมายที่เวลา t_n

y_{t_n} เป็นเอาต์พุตจากโครงข่ายประสาทเทียมที่เวลา t_n

N เป็นจำนวนข้อมูลทั้งหมด

$\rho(t_n)$ เป็นฟังก์ชันความแรงของเวลาอย่างสุ่ม (Stochastic Time Strength Function) ที่เวลา t_n ซึ่งนิยามดังสมการต่อไปนี้

$$\rho(t_n) = \frac{1}{\beta} \exp \left\{ \int_{t_0}^{t_n} \mu(t) dt + \int_{t_0}^{t_n} \sigma(t) dB(t) \right\}$$

โดยที่

$\beta (> 0)$ เป็นสัมประสิทธิ์ความแรงของเวลา (Time Strength Coefficient)

$\mu(t)$ เป็นฟังก์ชันแนวโน้ม (Drift Function)

$\sigma(t)$ เป็นฟังก์ชันความผันผวน (Volatility Function)

$B(t)$ เป็นการเคลื่อนที่แบบไร้อิศทาง (Standard Brownian Motion)

นิยาม $\mu(t)$ และ $\sigma(t)$ ได้สมการต่อไปนี้

$$\mu(t) = \frac{1}{(c-t)^2}$$

$$\sigma(t) = \left[\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2 \right]^{\frac{1}{2}}$$

โดยที่

c เป็นตัวแปรซึ่งมีขนาดเท่ากับจำนวนของตัวอย่างที่ใช้สอน

t เป็นเวลา

\bar{x} เป็นค่าเฉลี่ยของตัวอย่างข้อมูลอินพุต

x_i เป็นอินพุตเวกเตอร์ตัวที่ i

สำหรับการปรับค่าน้ำหนักสามารถทำได้โดยใช้ขั้นตอนการส่งค่าย้อนกลับ (Backpropagation Algorithm)

2.1.7 ขั้นตอนผสมผสานระหว่างการแยกส่วนประกอบของรูปแบบเชิงประจักษ์กับขั้นตอนโครงข่ายประสาทเทียมแบบความแรงของเวลาอย่างสุ่ม (Empirical Mode Decomposition Stochastic Time Strength Neural Network) (EMD-STNN)

ขั้นตอนผสมผสานระหว่างการแยกส่วนประกอบของรูปแบบเชิงประจักษ์และขั้นตอนโครงข่ายประสาทเทียมแบบความแรงของเวลาอย่างสุ่ม (Empirical Mode Decomposition Stochastic Time Strength Neural Network) (EMD-STNN) [2] เป็นกระบวนการที่ผสมผสานระหว่างการแยกส่วนประกอบของรูปแบบเชิงประจักษ์ (EMD) และโครงข่ายประสาทเทียมแบบความแรงของเวลาอย่างสุ่ม (STNN) โดยที่ EMD ทำหน้าที่สกัดข้อมูลของอนุกรมเวลาหลัก $X(t)$ ออกเป็นฟังก์ชันรูปแบบที่แท้จริง (Intrinsic Mode Function) (IMF) หลายชุด และส่วนเหลือ (Residual) หลังจากนั้นใช้ IMF และ Residual เหล่านี้เป็นอินพุตให้กับ STNN ในการพยากรณ์ ซึ่งจะได้ผลลัพธ์การพยากรณ์เป็นจำนวนชุดเท่ากับจำนวนชุดของ IMF และ Residual ที่ได้จาก EMD ในขั้นตอนสุดท้ายทำการรวมผลลัพธ์การพยากรณ์ทุกชุดให้เป็นชุดเดียวโดยใช้สมการต่อไปนี้

$$\tilde{X}(t) = \sum_{i=1}^M \tilde{C}_i(t) x \rho_i + \tilde{R}_M(t) \rho_{M+1}, \quad t = 1, \dots, N$$

โดยที่

$\tilde{X}(t)$ เป็นผลลัพธ์การพยากรณ์สุดท้ายของอนุกรมเวลาหลัก

$\tilde{C}_i(t)$ เป็นผลลัพธ์การพยากรณ์ของ IMF แต่ละชุด

ρ_i เป็นสัมประสิทธิ์การรวมของผลลัพธ์การพยากรณ์สำหรับ IMF แต่ละชุด

$\tilde{R}_M(t)$ เป็นผลลัพธ์การพยากรณ์ของ Residual

ในที่นี้เรากำหนดให้ $\rho_i = 1$ สำหรับ $i = 1, 2, \dots, M, M + 1$

2.1.8 ขั้นตอนผสมผสานระหว่างข้อมูลแบบสุ่มเชิงเวลาที่มีประสิทธิภาพกับโครงข่ายประสาทเทียมแบบเรเดียลเบซิสฟังก์ชัน (Random Data-time Effective Radial Basis Function Neural Network) (RT-RBFNN)

RT-RBFNN [6] เป็นโครงข่ายประสาทเทียมที่มีฟังก์ชันกระตุ้น (Activation Function) ในชั้นซ่อน (Hidden Layer) เป็นเรเดียลเบซิสฟังก์ชัน (Radial Basis Function) ซึ่งสามารถคำนวณเอาต์พุตของโครงข่ายประสาทเทียมได้ด้วยสมการต่อไปนี้

$$f(x) = w_0 + \sum_{i=1}^h w_i \phi(\|x - c_i\|)$$

โดยที่

x เป็นอินพุตเวกเตอร์

h เป็นจำนวนของนิวรอนในชั้นซ่อน

c_i เป็นเวกเตอร์ศูนย์กลางของปมที่ i ในชั้นซ่อน

ϕ เป็นเรเดียลเบซิสฟังก์ชัน (Radial Basis Function) ซึ่งนิยามได้ดังสมการต่อไปนี้

$$\phi(\|x - c_i\|) = \exp\{-\|x - c_i\|^2 / 2\beta_i^2\}$$

โดยที่

β_i เป็นความกว้างของศูนย์กลางตัวที่ i

ในชั้นเริ่มแรกเราสุ่มค่าให้กับค่าน้ำหนัก, เวกเตอร์ศูนย์กลาง และความกว้างของศูนย์กลาง หลังจากนั้นเราทำการปรับค่าเหล่านี้โดยใช้ขั้นตอนวิธีการส่งค่าย้อนกลับ (Backpropagation Algorithm) ซึ่งสามารถหาอัตราการเปลี่ยนแปลงของค่าน้ำหนัก, เวกเตอร์ศูนย์กลาง และความกว้างของศูนย์กลางได้ด้วยสมการดังต่อไปนี้

$$\begin{aligned} \Delta w_i &= -\eta_1 \frac{\partial E(\vec{w})}{\partial w_i} = \eta_1 \epsilon_{t_n} \rho(t_n) \phi(\|x - c_i\|) \\ \Delta c_i &= -\eta_2 \frac{\partial E(\vec{w})}{\partial c_i} = \eta_2 \epsilon_{t_n} w_i \rho(t_n) \frac{\phi(\|x - c_i\|)}{\beta_i^2} (x - c_i) \\ \Delta \beta_i &= -\eta_3 \frac{\partial E(\vec{w})}{\partial \beta_i} = \eta_3 \epsilon_{t_n} w_i \rho(t_n) \frac{\phi(\|x - c_i\|)}{\beta_i^3} \|x - c_i\| \end{aligned}$$

โดยที่

η_1, η_2, η_3 เป็นอัตราการเรียนรู้

$E(\vec{w})$ เป็นฟังก์ชันค่าผิดพลาด

- w_i เป็นค่าน้ำหนักตัวที่ i
 c_i เป็นเวกเตอร์ศูนย์กลางของปมที่ i ในชั้นซ่อน
 β_i เป็นความกว้างของศูนย์กลางตัวที่ i
 t_n เป็นเวลาของตัวอย่าง n
 ϵ_{t_n} เป็นค่าผิดพลาดที่เอาต์พุตที่เวลา t_n
 $\rho(t_n)$ เป็นฟังก์ชันข้อมูลแบบสุ่มเชิงเวลาที่มีประสิทธิภาพ (Random Data-time Effective Function) ที่เวลา t_n

ซึ่งนิยาม ϵ_{t_n} และ $\rho(t_n)$ ได้สมการดังต่อไปนี้

$$\epsilon_{t_n} = d_{t_n} - y_{t_n}$$

$$\rho(t_n) = \frac{1}{\beta} \exp \left\{ \int_{t_0}^{t_n} \mu(t) dt + \int_{t_0}^{t_n} \sigma(t) dB(t) \right\}$$

โดยที่

- $\beta (> 0)$ เป็นสัมประสิทธิ์ความแรงของเวลา (Time Strength Coefficient)
 $\mu(t)$ เป็นฟังก์ชันแนวโน้ม (Drift Function)
 $\sigma(t)$ เป็นฟังก์ชันความผันผวน (Volatility Function)
 $B(t)$ เป็นการเคลื่อนที่แบบไร้อิศทาง (Standard Brownian Motion)

นิยาม $\mu(t)$ ได้สมการต่อไปนี้

$$\mu(t) = \frac{1}{(t + a)^2}$$

โดยที่

- a เป็นตัวแปรซึ่งมีขนาดเท่ากับจำนวนของตัวอย่างที่ใช้สอน
 t เป็นเวลา

นิยาม $\sigma(t)$ ได้สมการต่อไปนี้

$$\sigma(t) = \left[\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2 \right]^{\frac{1}{2}}$$

เราสามารถปรับค่าน้ำหนัก, เวกเตอร์ศูนย์กลาง และความกว้างของศูนย์กลาง ในแต่ละรอบของการสอนได้โดยใช้สมการดังต่อไปนี้

$$\begin{aligned}w_i(l+1) &= w_i(l) + \Delta w_i = w_i(l) + \eta_1 \epsilon_{t_n} \rho(t_n) \phi_i \\c_i(l+1) &= c_i(l) + \Delta c_i = c_i(l) + \eta_2 \epsilon_{t_n} w_i \rho(t_n) \frac{\phi_i}{\beta_i^2} (x - c_i) \\\beta_i(l+1) &= \beta_i(l) + \Delta \beta_i = \beta_i(l) + \eta_3 \epsilon_{t_n} w_i \rho(t_n) \frac{\phi_i}{\beta_i^3} \|x - c_i\|\end{aligned}$$

โดยที่

$w_i(l+1)$	เป็นค่าน้ำหนักตัวที่ i ในรอบที่ $l+1$
$w_i(l)$	เป็นค่าน้ำหนักตัวที่ i ในรอบที่ l
$c_i(l+1)$	เป็นเวกเตอร์ศูนย์กลางของปมที่ i ในชั้นซ่อน ในรอบที่ $l+1$
$c_i(l)$	เป็นเวกเตอร์ศูนย์กลางของปมที่ i ในชั้นซ่อน ในรอบที่ l
$\beta_i(l+1)$	เป็นความกว้างของศูนย์กลางตัวที่ i ในรอบที่ $l+1$
$\beta_i(l)$	เป็นความกว้างของศูนย์กลางตัวที่ i ในรอบที่ l

2.2 งานวิจัยที่เกี่ยวข้อง

2.2.1 งานวิจัยต้นแบบ

[7] นำเสนอการใช้โครงข่ายประสาทเทียมในการพยากรณ์ราคาสูงสุดและราคาต่ำสุดของวันปัจจุบันบนข้อมูลหุ้นของสองบริษัทตัวหลักของตลาดหลักทรัพย์บราซิล (BM&F BOVESPA) โดยใช้อินพุตที่แตกต่างกันสามชุด ผู้เขียนได้นำเสนอระบบจำลองการซื้อขายรายวันเพื่อเปลี่ยนเอาต์พุตของโครงข่ายประสาทเทียมไปสู่การตัดสินใจทางการลงทุนซึ่งชี้ให้นักลงทุนเห็นช่วงเวลาที่ดีที่สุดในการซื้อขายและทำกำไร ผู้เขียนวัดประสิทธิภาพของโครงข่ายประสาทเทียมสองวิธีได้แก่การใช้ ค่าเฉลี่ยของร้อยละความผิดพลาดสมบูรณ์ (Mean Absolute Percentage Error) (MAPE) และวัดผลตอบแทนต่อปี (Annualized Return) โครงข่ายประสาทเทียมถูกนำมาเปรียบเทียบประสิทธิภาพกับ 4 เกณฑ์มาตรฐาน ผลลัพธ์แสดงให้เห็นว่าโครงข่ายประสาทเทียมให้ค่าเฉลี่ยของร้อยละความผิดพลาดสมบูรณ์น้อยกว่าของเกณฑ์มาตรฐาน 50% และให้ผลตอบแทนต่อปีสองเท่าของเงินลงทุน [3] นำเสนอโครงข่ายประสาทเทียมอย่างถูกต้องของเบส์ (Bayesian Regularized Artificial Neural Network) ในการพยากรณ์ราคาปิดของหนึ่งในอนาคตบนข้อมูลหุ้นของบริษัทไมโครซอฟท์ (Microsoft Corp) และบริษัทกลุ่มโกลแมนแซชส์ (Golman Sachs Group) โดยราคาตลาด (Market Price) และตัวชี้วัดทางเทคนิค (Technical Indicator) ถูกใช้เป็นอินพุตให้กับโครงข่ายประสาทเทียม โครงข่ายประสาทเทียมอย่างถูกต้องของเบส์ช่วยลดปัญหาความ

พอดีที่มากเกินไปของข้อมูลที่ใช้สอน (Overfitting) และการเรียนที่มากเกินไป (Overtraining) โดยการกำหนดกฎความน่าจะเป็นให้กับค่าน้ำหนักของโครงข่าย ซึ่งกำจัดการความซับซ้อนส่วนเกินของโครงข่ายอย่างอัตโนมัติ ช่วยเพิ่มประสิทธิภาพการพยากรณ์และความทั่วไปของโครงข่าย [2] นำเสนอขั้นตอนผสมผสานระหว่างการแยกส่วนประกอบของรูปแบบเชิงประจักษ์กับโครงข่ายประสาทเทียมแบบความแรงของเวลาอย่างสุ่ม (Empirical Mode Decomposition Stochastic Time Strength Neural Network) (EMD-STNN) เพื่อพยากรณ์ราคาปิดของหนึ่งวันในอนาคตของ NYSE, DAX, FTSE และ HSI การแยกส่วนประกอบของรูปแบบเชิงประจักษ์ (Empirical Mode Decomposition) (EMD) เป็นขั้นตอนในการแยกส่วนประกอบของรูปแบบที่ฝังอยู่ในอนุกรมโครงข่ายประสาทเทียมแบบความแรงของเวลาอย่างสุ่ม (Stochastic Time Strength Neural Network) เป็นโครงข่ายประสาทเทียมที่มีการพิจารณาค่าน้ำหนักของแต่ละจุดข้อมูลที่เพิ่มขึ้นในอนุกรมเวลาของฟังก์ชันค่าผิดพลาด หลักการทำงานของ (EMD-STNN) ประกอบด้วยสามขั้นตอน ในขั้นตอนแรกคือการใช้ EMD ในการแยกรูปแบบที่ฝังอยู่ในอนุกรมออกมาเป็นชุด ๆ หลังจากนั้นใช้ STNN พยากรณ์ราคาปิดของอนุกรมย่อยแต่ละชุด ขั้นตอนสุดท้ายคือการนำผลลัพธ์การพยากรณ์ของอนุกรมย่อยแต่ละชุดมารวมกันเพื่อให้ได้ผลลัพธ์การพยากรณ์สุดท้าย ประสิทธิภาพของ EMD-STNN ดีกว่าแบบจำลองแบบดั้งเดิมเช่น โครงข่ายประสาทเทียมแบบส่งค่าย้อนกลับ (BPNN), โครงข่ายประสาทเทียมแบบความแรงของเวลาอย่างสุ่ม (STNN) และซัพพอร์ตเวกเตอร์แมชชีน (SVM) อย่างชัดเจน และค่าสัมประสิทธิ์ความสัมพันธ์ (R) ระหว่างเอาต์พุตเป้าหมายและเอาต์พุตที่ได้จากแบบจำลอง มากกว่า 0.99 [6] นำเสนอขั้นตอนผสมผสานระหว่างข้อมูลแบบสุ่มเชิงเวลาที่มีประสิทธิภาพกับโครงข่ายประสาทเทียมแบบเรเดียลเบสซิสฟังก์ชัน (Random Data-Time Effective Radial Basis Function Neural Network) (RBFRT) ในการพยากรณ์ราคาปิดของหนึ่งวันในอนาคตของน้ำมันดิบ (Crude Oil), SSE, N225 และ DAX ซึ่ง RBFRT ใช้โครงข่ายประสาทเทียมแบบเรเดียลเบสซิสฟังก์ชัน (Radial Basis Function Neural Network) ในการสร้างแบบจำลอง โดยฟังก์ชันค่าผิดพลาดที่ใช้มีการให้ค่าน้ำหนักกับแต่ละจุดเวลาที่เกิดขึ้นในอนุกรมเวลา ผลลัพธ์การทดลองแสดงให้เห็นว่าประสิทธิภาพของ RBFRT ดีกว่าโครงข่ายประสาทเทียมแบบเรเดียลเบสซิสฟังก์ชันที่ไม่มีการให้ค่าน้ำหนักกับแต่ละจุดเวลาในฟังก์ชันค่าผิดพลาด และค่าสัมประสิทธิ์ความสัมพันธ์ (R) ระหว่างเอาต์พุตเป้าหมายและเอาต์พุตที่ได้จากแบบจำลอง มากกว่า 0.99

2.2.2 งานวิจัยด้านการวิเคราะห์ทางเทคนิค

งานวิจัยด้านการวิเคราะห์ทางเทคนิคผู้จัดทำได้ให้ความสำคัญกับโครงข่ายประสาทเทียม เพราะในช่วง 10 ปีที่ผ่านมา โครงข่ายประสาทเทียมมีชื่อเสียงเป็นอย่างมากในการพยากรณ์ตลาดทางการเงิน [12, 13] ได้นำเสนอหลักฐานว่าโครงข่ายประสาทเทียมมีความสามารถในการ

พยากรณ์อัตราแลกเปลี่ยนคู่สกุลเงินได้ ข้อมูลอนุกรมเวลาและตัวบ่งชี้ทางเทคนิค (Technical Indicator) เช่น ค่าเฉลี่ยเคลื่อนที่ (Moving Average) ถูกใช้เป็นอินพุตให้กับโครงข่ายประสาทเทียม เพื่อจับกฎการเคลื่อนที่ของอัตราแลกเปลี่ยน อัตราแลกเปลี่ยนคู่สกุลเงิน AUD/USD, CHF/USD, DEM/USD, GBP/USD และ JPY/USD ถูกพยากรณ์โดยโครงข่ายประสาทเทียมที่ผ่านการเรียนแล้ว การวิเคราะห์ช่วงของการปรับขนาดแบบดั้งเดิม (Traditional Rescaled Range Analysis) ถูกนำมาทดสอบประสิทธิภาพของแต่ละคู่อัตราแลกเปลี่ยนก่อนที่จะนำข้อมูลย้อนหลังมาสอนโครงข่ายประสาทเทียม ผลลัพธ์แสดงให้เห็นว่าโดยปราศจากการใช้ข้อมูลอื่น ๆ ของตลาด โครงข่ายประสาทเทียมก็สามารถให้การพยากรณ์ที่เป็นประโยชน์ได้และสามารถที่จะทำกำไรได้บนข้อมูลที่นอกเหนือจากกลุ่มตัวอย่างด้วยตัวบ่งชี้ทางเทคนิคพื้นฐาน [14] อธิบายการประยุกต์ใช้งานของการทำให้เป็นปกติของเบส์ (Bayesian Regularization) สำหรับการสอนโครงข่ายประสาทเทียมแบบส่งค่าไปข้างหน้า (Feedforward Neural Network) โดยใช้ขั้นตอนวิธีเกาส์-นิวตัน (Gauss-Newton Algorithm) ในการประมาณค่าเฮสเซียนเมทริกซ์ (Hessian Matrix) ซึ่งทำได้สะดวกเมื่อใช้ขั้นตอนวิธีเลเวนเบิร์ก-มาร์ควาร์ด (Levenberg-Marquardt Algorithm) การประมาณค่าเฮสเซียนเมทริกซ์ (Hessian Matrix) ด้วยขั้นตอนวิธีของเกาส์-นิวตัน (Gauss-Newton Algorithm) ถูกใช้ในการลดค่าใช้จ่ายในการคำนวณที่สูงเกินไป (Computational Overhead) ผลลัพธ์ของการประยุกต์ใช้งานชี้ให้เห็นว่าโครงข่ายประสาทเทียมที่ได้มีประสิทธิภาพในการทำให้เป็นทั่วไปอย่างดียิ่ง [15] นำเสนอฟังก์ชันประสิทธิภาพของเวลาอย่างสุ่มใหม่ (New Stochastic Time Effective Function) เพื่อจำลองโครงข่ายประสาทเทียมแบบประสิทธิภาพของเวลาอย่างสุ่ม (Stochastic Time Effective Neural Network) ความสำเร็จของแบบจำลองได้ถูกวิเคราะห์ด้วยการทดลองบนข้อมูลดัชนีตลาด HSI, DJI และ IXIC และ SP500 และความถูกต้องของตัวแปรความแปรปรวนของการเคลื่อนที่แบบไร้ทิศทาง (Brownian Motion) ได้ถูกทดสอบ นอกจากนี้ยังได้แสดงผลการพยากรณ์โดยใช้โครงข่ายประสาทเทียมแบบประสิทธิภาพของเวลาอย่างสุ่ม (Stochastic Time Effective Neural Network) [16] นำเสนอขั้นตอนผสมผสานระหว่างโครงข่ายประสาทเทียมแบบเลอฌ็องด์ร์ (Legendre Neural Network) กับฟังก์ชันความแรงของเวลาอย่างสุ่ม (Random Time Strength Function) โดยผู้เขียนมีความเชื่อว่าข้อมูลในชุดข้อมูลสอนควรสะท้อนพฤติกรรมที่แตกต่างกันในเวลาที่แตกต่างกัน ถ้าข้อมูลทั้งหมดถูกมาใช้สอนให้กับโครงข่ายประสาทเทียมโดยมีน้ำหนักเท่ากัน ระบบเครือข่ายอาจไม่สอดคล้องกับพฤติกรรมของตลาด นอกจากนี้ยังได้ทดสอบแบบจำลองนี้กับดัชนีตลาด SAI, SBI, DJI และ IXIC สำหรับแต่ละค่าฟังก์ชันแนวโน้ม (Tendency Function) และฟังก์ชันความผันผวนแบบไร้ทิศทางอย่างสุ่ม (Random Brownian Volatility Function) ที่แตกต่างกัน วัดประสิทธิภาพของแบบจำลองด้วยค่าเฉลี่ยของร้อยละความผิดพลาดสมบูรณ์ (Mean Absolute Percentage Error) (MAPE) และวิธีการถดถอยเชิงเส้น ผลลัพธ์ที่ออกมาแสดงให้เห็นว่าขั้นตอนวิธีนี้

ให้ความแม่นยำที่มากขึ้นในการพยากรณ์ [17] พัฒนาขั้นตอนผสมผสานระหว่างการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis) กับโครงข่ายประสาทเทียมแบบประสิทธิภาพของเวลาอย่างสุ่ม (Stochastic Time Effective Neural Network) สำหรับพยากรณ์อนุกรมเวลาทางการเงิน โดยมีหลักการทำงาน 2 ขั้นตอนดังนี้คือ เริ่มแรกใช้การขั้นตอนวิเคราะห์องค์ประกอบหลักสกัดองค์ประกอบหลักของข้อมูลอินพุต หลังจากนั้นใช้องค์ประกอบหลักที่ได้เป็นอินพุตให้กับโครงข่ายประสาทเทียมแบบประสิทธิภาพของเวลาอย่างสุ่มเพื่อพยากรณ์ ในการเปรียบเทียบประสิทธิภาพของแบบจำลองระหว่างขั้นตอนวิธีที่เสนอ, โครงข่ายประสาทเทียมแบบประสิทธิภาพของเวลาอย่างสุ่ม, โครงข่ายประสาทเทียมแบบส่งค่าย้อนกลับ (Backpropagation Neural Network) และ ขั้นตอนผสมผสานระหว่างโครงข่ายประสาทเทียมแบบส่งค่าย้อนกลับกับการวิเคราะห์องค์ประกอบหลัก การวิเคราะห์เชิงประจักษ์แสดงให้เห็นว่าขั้นตอนวิธีที่เสนอมีประสิทธิภาพในการพยากรณ์อนุกรมเวลาทางการเงินที่สูงกว่า [18] นำเสนอขั้นตอนผสมผสานการแปลงเวฟเลตแบบไม่ต่อเนื่อง (Discrete Wavelet Transform) กับระหว่างโครงข่ายประสาทเทียมแบบส่งค่าย้อนกลับ (Backpropagation Neural Network) เพื่อพยากรณ์ราคาปิดของหุ้นในตลาดหลักทรัพย์อินเดีย ขั้นตอนวิธีนี้ในขั้นแรกใช้การแปลงเวฟเลตแบบไม่ต่อเนื่อง (Discrete Wavelet Transform) เพื่อสกัดข้อมูลย้อนหลัง ต่อจากนั้นใช้สัมประสิทธิ์การประมาณ (Approximation Coefficient) และสัมประสิทธิ์ส่วนย่อย (Detail Coefficient) เป็นอินพุตให้กับโครงข่ายประสาทเทียมแบบส่งค่าย้อนกลับ (Backpropagation Neural Network) เพื่อพยากรณ์ราคาของหุ้นในอนาคต ผลลัพธ์การจำลองแสดงให้เห็นว่าการใช้ขั้นตอนวิธีที่นำเสนอให้ผลลัพธ์ที่แม่นยำมากกว่าเมื่อเปรียบเทียบกับโครงข่ายประสาทเทียมที่ใช้อินพุตเป็นข้อมูลที่ไม่ผ่านการแปลงเวฟเลตแบบไม่ต่อเนื่อง

2.2.3 งานวิจัยด้านการวิเคราะห์ปัจจัยพื้นฐาน

[19] ได้นำเสนอส่วนประกอบของระบบการพยากรณ์และทำการเปรียบเทียบขั้นตอนในการเลือกคุณลักษณะของข่าว, ขั้นตอนในการให้ค่าน้ำหนักคุณลักษณะของข่าว, คุณลักษณะทั้งหมดที่ใช้, แหล่งข่าว, การเลือกช่วงเวลาที่ได้รับผลกระทบจากข่าวที่ออก, รูปแบบในการแบ่งกลุ่มเป้าหมาย, จำนวนกลุ่มคุณลักษณะเป้าหมาย และขั้นตอนวิธีที่ใช้แบ่งกลุ่มของคุณลักษณะเป้าหมาย ของแต่ละงานวิจัย [20] ทำการวัดสภาพอารมณ์ของข่าวและน้ำเสียงของผู้เขียนข่าว เพื่อตอบคำถามในงานวิจัยสองข้อคือ ข่าวการคาดการณ์/ข่าวที่รายงานผลตามจริง มีผลกระทบต่อพยากรณ์ราคาใหม่ และ น้ำเสียงของผู้เขียนในเชิงบวก/เชิงลบ มีผลต่อการพยากรณ์ราคาใหม่ เพื่อตอบคำถามสองข้อนี้ ผู้เขียนได้ทำการทดลองสามชุด 1) ใช้เอาต์พุตที่ได้จากวิธีการคำนามที่เหมาะสม (Proper nouns) และราคาของหุ้นขณะที่ยังเป็นอินพุตให้กับซัพพอร์ตเวกเตอร์รีเกรสชัน (Support Vector Regression) ในการพยากรณ์ราคาของหุ้นหลังจากที่ข่าว

ออกเป็นเวลา 20 นาที 2) ใช้เอาต์พุตที่ได้จากวิธีการ Proper nouns , ราคาของหุ้นขณะที่ข่าวออก และสภาพอารมณ์ของข่าว (ข่าวการคาดการณ์/ข่าวที่รายงานผลตามจริง) เป็นอินพุตให้กับซัพพอร์ตเวกเตอร์รีเกรสชัน (Support Vector Regression) ในการพยากรณ์ราคาของหุ้นหลังจากที่ข่าวออกเป็นเวลา 20 นาที 3) ใช้เอาต์พุตที่ได้จากวิธีการ Proper nouns , ราคาของหุ้นขณะที่ข่าวออก , สภาพอารมณ์ของข่าว (ข่าวการคาดการณ์/ข่าวที่รายงานผลตามจริง) และน้ำเสียงของข่าว (เชิงบวก/เชิงลบ) เป็นอินพุตให้กับซัพพอร์ตเวกเตอร์รีเกรสชัน (Support Vector Regression) ในการพยากรณ์ราคาของหุ้นหลังจากที่ข่าวออกเป็นเวลา 20 นาที เหตุผลที่ผู้เขียนเลือกช่วงเวลา 20 นาทีหลังจากที่ข่าวออก เพราะอ้างอิงจากผลลัพธ์ของ [21] ซึ่งค้นพบว่าช่วงเวลาอยู่ 20 นาทีก่อนข่าวออกและหลังข่าวออกในการเปลี่ยนแปลงราคาของหุ้น การเปลี่ยนแปลงราคาก่อนข่าวออก 20 นาที ถูกเชื่อว่าเป็นผลลัพธ์มาจากนักลงทุนที่รู้ข่าวข้อมูลของข่าวก่อนที่จะมีการประกาศข่าว และการเปลี่ยนแปลงราคาหลังข่าวออก 20 นาทีเป็นผลลัพธ์จากการที่นักลงทุนได้รับข่าวไม่พร้อมกัน ทำให้ตัดสินใจในการลงทุนไม่พร้อมกัน [22] เสนอการพยากรณ์ความผันผวนของราคาหุ้นจากการวิเคราะห์ข่าวการเปิดเผยข้อมูลของบริษัท ซึ่งมีเอาต์พุตเป้าหมาย 2 กลุ่มคือกลุ่มที่มีความผันผวนสูงอย่างผิดปกติ และกลุ่มที่มีความผันผวนสูงในระดับทั่วไป ผู้เขียนดำเนินการทดลองโดยเลือกกลุ่มข่าวเฉพาะที่ทำให้เกิดความผันผวนของราคาทันทีหลังจากข่าวออก และนำกลุ่มข่าวที่ได้แบ่งเป็นสองกลุ่มตามเอาต์พุตเป้าหมาย โดยข่าวที่ทำให้เกิดความผันผวนของราคาสูงอย่างผิดปกติมีจำนวน 25% ของข่าวทั้งหมด และข่าวที่ทำให้เกิดความผันผวนของราคาสูงในระดับทั่วไปมีจำนวน 75% ของข่าวทั้งหมด ผู้เขียนสร้างอินพุตเวกเตอร์โดยใช้วิธี TF-IDF และทำการทดลองการพยากรณ์ความผันผวนโดยใช้ 4 ขั้นตอนวิธีได้แก่ การค้นหาเพื่อนบ้านใกล้สุด k ตัว (k-Nearest Neighbor), โครงข่ายประสาทเทียม (Neural Network), ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine) และตัวเรียนรู้ของเบสอย่างง่าย (Naive Bayes) ผลลัพธ์จากการทดลองแสดงให้เห็นว่า Support Vector Machine ให้ผลลัพธ์การพยากรณ์ที่ดีที่สุด [23] นำเสนอวิธีการพยากรณ์ทิศทางการเคลื่อนไหวระหว่างวันของตลาดอัตราแลกเปลี่ยน ผู้เขียนนำเสนอ 3 ขั้นตอนการวิเคราะห์ข้อความ (Text Mining) 1) การวิเคราะห์ทางภาษาศาสตร์ 2) วิเคราะห์อารมณ์ของข่าวเพื่อระบุความรู้สึกของนักลงทุนต่อตลาด 3) การลดมิติของคุณสมบัติของข่าวที่ถูกสกัด ขั้นตอนทั้งสามถูกออกแบบมาเพื่อรองรับกระแสของข้อมูลที่เข้ามาจำนวนมาก และทำการวิเคราะห์แบบจำลองทันทีที่มีข้อมูลใหม่เข้ามา [13]

บทที่ 3 งานวิจัยที่นำเสนอ

3.1 แรงแบบคาลใจ

จากงานวิจัยต้นแบบทั้ง 4 งานตามที่ได้กล่าวใน 2.2.1 สามารถสรุปถึงส่วนประกอบที่สำคัญที่ช่วยพัฒนาประสิทธิภาพของแบบจำลองได้ 4 ส่วนได้แก่

- 1) ความสามารถของ EMD ในการแยกสัญญาณที่แฝงอยู่ในอนุกรมเวลา ความสามารถในการเพิ่มประสิทธิภาพของแบบจำลองด้วย EMD แสดงใน [3]
- 2) ความสามารถของฟังก์ชันความแรงของเวลาอย่างนุ่มซึ่งช่วยพิจารณาค่าความสำคัญของแต่ละตัวอย่างในอนุกรมเวลา ซึ่งช่วยให้แบบจำลองมีการปรับตัวได้อย่างทันท่วงทีกับพฤติกรรมของตลาดในปัจจุบัน ความสามารถในการเพิ่มประสิทธิภาพของแบบจำลองด้วยฟังก์ชันความแรงของเวลาอย่างนุ่มแสดงใน [8]
- 3) ความสามารถของการทำให้ถูกต้องของเบสส์ช่วยลดปัญหาความพอดีที่มากเกินไป (Overfitting) ของข้อมูลที่ใช้สอนและการเรียนที่มากเกินไป (Overtraining) ความสามารถในการเพิ่มประสิทธิภาพของแบบจำลองด้วยการทำให้ถูกต้องของเบสส์แสดงใน [2]
- 4) ความสามารถของโครงข่ายประสาทเทียมแบบเรเดียลเบซิสฟังก์ชันที่มีการใช้เรเดียลเบซิสเป็นฟังก์ชันกระตุ้นในชั้นซ่อนและใช้ผลรวมเชิงเส้นในการรวมค่าที่ได้จากเรเดียลเบซิสฟังก์ชันเหล่านั้นเป็นฟังก์ชันกระตุ้นในชั้นเอาต์พุต ความสามารถในการพยากรณ์ของแบบจำลองแสดงใน [6]

ผู้จัดทำจึงมีความสนใจที่จะนำส่วนประกอบที่ 1, 2, 3 มาพัฒนาร่วมกัน ซึ่งได้เป็นขั้นตอนวิธีที่ 1 ในงานวิจัยชิ้นนี้ นอกจากนั้นผู้จัดทำยังมีความสนใจที่จะนำส่วนประกอบที่ 1, 2, 4 มาพัฒนาร่วมกัน ซึ่งได้เป็นขั้นตอนวิธีที่ 2 ในงานวิจัยชิ้นนี้

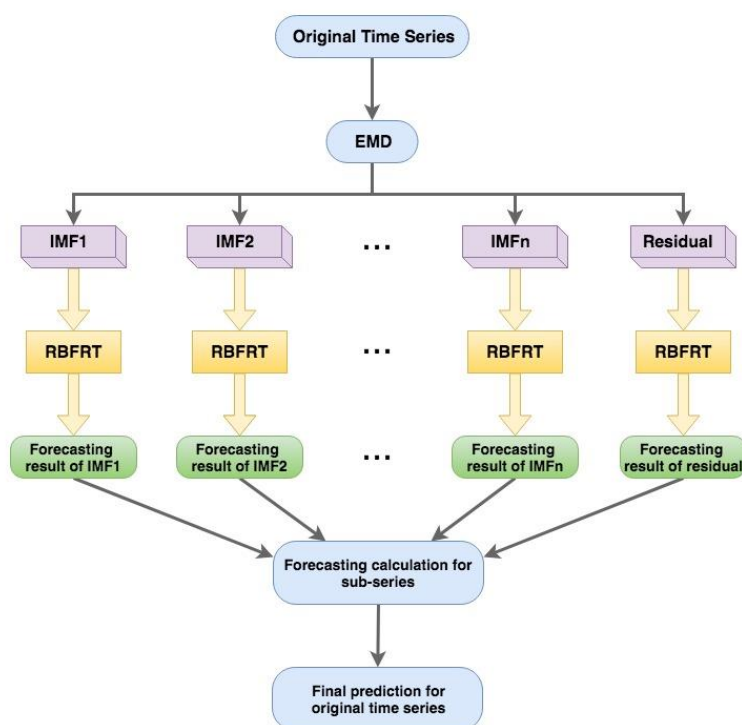
3.2 ขั้นตอนผสมผสานระหว่างการแยกส่วนประกอบของรูปแบบเชิงประจักษ์, ข้อมูลแบบนุ่มเชิงเวลาที่มีประสิทธิภาพ และโครงข่ายประสาทเทียมแบบเรเดียลเบซิสฟังก์ชัน (Empirical Mode Decomposition Random Data-time Effective Radial Basis Function Neural Network) (EMD-RT-RBFNN)

EMD-RT-RBFNN คือขั้นตอนวิธีที่ผสมผสานระหว่าง EMD, RT และ RBFNN ซึ่งขั้นตอนวิธีแต่ละส่วนมีความสำคัญดังนี้

- 1) EMD มีหน้าที่แยกส่วนประกอบอนุกรมเวลาดันฉบับให้ออกมาเป็นฟังก์ชันรูปแบบที่แท้จริง (IMF) หลายชุดและส่วนเหลือ (Residual) 1 ชุด


- 2) RT มีหน้าที่พิจารณาค่าความสำคัญของแต่ละจุดข้อมูลที่เกิดขึ้นในอนุกรมเวลา
- 3) RBFNN มีหน้าที่เป็นเครื่องมือพยากรณ์ในรูปแบบของโครงข่ายประสาทเทียมที่มีฟังก์ชันกระตุ้น (Activation Function) ในชั้นซ่อน (Hidden Layer) เป็นเรเดียลเบซิสฟังก์ชัน (Radial Basis Function)

ลำดับขั้นตอนการทำงานของ EMD-RT-RBFNN แสดงดังภาพที่ 2



ภาพที่ 2 ลำดับขั้นตอนการทำงานของ EMD-RT-RBFNN


ในงานวิจัยนี้เราสร้างแบบจำลอง EMD-RT-RBFNN 1 แบบจำลอง เพื่อพยากรณ์อัตราแลกเปลี่ยนของคู่สกุลเงิน EUR/USD โดยมีเอาต์พุต 2 ปมคือราคาสูงสุดและราคาต่ำสุด แบบจำลองสำหรับพยากรณ์ราคาสูงสุดของ EMD-RT-RBFNN และแบบจำลองสำหรับพยากรณ์ราคาต่ำสุดของ EMD-RT-RBFNN แสดงดังภาพที่ 3



ภาพที่ 3 แบบจำลองสำหรับพยากรณ์ราคาสูงสุดและราคาต่ำสุดของ EMD-RT-RBFNN

3.2.1 การใช้งาน EMD

ในงานวิจัยนี้เราใช้อนุกรมเวลาดั้งแบบ 2 อนุกรมได้แก่ อนุกรมเวลาของราคาสูงสุดและอนุกรมเวลาของราคาต่ำสุด เราประยุกต์ใช้ EMD ทั้งอนุกรมเวลาของราคาสูงสุดและราคาต่ำสุดเพื่อแยกส่วนประกอบของอนุกรมเวลาเป็นหลาย ๆ IMF ตัวอย่างการใช้งาน EMD กับอนุกรมเวลาของราคาสูงสุดและราคาต่ำสุด แสดงดังภาพที่ 4



ภาพที่ 4 ซ้าย) แสดงการใช้งาน EMD กับอนุกรมเวลาของราคาสูงสุด ขวา) แสดงการใช้งาน EMD กับอนุกรมเวลาของราคาต่ำสุด (ที่มา : [2])

3.2.2 การตั้งค่าเบื้องต้นของ EMD-RT-RBFNN

สำหรับแบบจำลองประเภทโครงข่ายประสาทเทียม การตั้งค่าพื้นฐานสำหรับแบบจำลองมีความสำคัญอย่างยิ่งในการสร้างงานวิจัย เนื่องจากการเปลี่ยนการตั้งค่าเบื้องต้นเพียงน้อยนิดอาจส่งผลกระทบต่อผลลัพธ์ของแบบจำลองเป็นอย่างมาก เพื่อความชัดเจนในการทำงานวิจัยผู้จัดทำจึงแสดงการตั้งค่าเบื้องต้นของแบบจำลองสำหรับแต่ละ IMF และ Residual ของอนุกรมราคาสูงสุดและอนุกรมราคาต่ำสุดดังตารางที่ 1

โครงสร้าง	15 x 6 x 2
ฟังก์ชันค่าผิดพลาด	$E(t_n) = \frac{1}{N} \sum_{n=1}^N \rho(t_n) (d_{t_n} - y_{t_n})^2$
อินพุต	ราคาสูงสุดของทั้ง 5 วันก่อนหน้า ราคาต่ำสุดของทั้ง 5 วันก่อนหน้า EMA วันล่าสุดของราคาสูงสุด (period = 5) EMA วันล่าสุดของราคาต่ำสุด (period = 5) Upper Band วันล่าสุดของราคาปิด (period = 5) Lower Band วันล่าสุดของราคาปิด (period = 5) ราคาเปิดของวันปัจจุบัน

เอาต์พุต	ราคาสูงสุดของวันปัจจุบัน และราคาต่ำสุดของวันปัจจุบัน
การทำให้เป็นมาตรฐาน	การทำให้เป็นมาตรฐานแบบน้อยสุดมากที่สุด ซึ่งจะได้ค่าอยู่ในช่วง [0, 1]
ฟังก์ชันกระตุ้นสำหรับชั้นซ่อน	เรเดียลเบซิลฟังก์ชัน
ฟังก์ชันกระตุ้นสำหรับชั้นเอาต์พุต	ผลรวมเชิงเส้น
ค่าน้ำหนัก	สุ่มค่าจากในช่วง (-0.1, 0.1)
เวกเตอร์ศูนย์กลาง	สุ่มค่าในช่วง (0, 1)
ความกว้าง	สุ่มค่าในช่วง (0.1, 0.3)
จำนวนรอบการปรับค่าน้ำหนัก	1000 รอบ
อัตราการเรียนรู้	0.01

ตารางที่ 1 แสดงการตั้งค่าเบื้องต้นสำหรับแบบจำลองทั้งหมดของ EMD-RT-RBFNN

3.2.3 เอาต์พุตของ EMD-RT-RBFNN

หลังจากนั้นใช้ IMF และ Residual เหล่านี้เป็นอินพุตให้กับ RT-RBFNN ในการพยากรณ์ ซึ่งจะได้ผลลัพธ์การพยากรณ์เป็นจำนวนชุดเท่ากับจำนวนชุดของ IMF และ Residual ที่ได้จาก EMD ในขั้นตอนสุดท้ายทำการรวมผลลัพธ์การพยากรณ์ทุกชุดให้เป็นชุดเดียวโดยใช้สมการต่อไปนี้

$$\text{โดยที่} \quad \tilde{X}(t) = \sum_{i=1}^M \tilde{C}_i(t) \times \rho_i + \tilde{R}_M(t) \rho_{M+1}, \quad t = 1, \dots, N$$

$\tilde{X}(t)$ เป็นผลลัพธ์การพยากรณ์สุดท้ายของอนุกรมเวลาหลัก

$\tilde{C}_i(t)$ เป็นผลลัพธ์การพยากรณ์ของ IMF แต่ละชุด

ρ_i เป็นสัมประสิทธิ์การรวมของผลลัพธ์การพยากรณ์สำหรับ IMF แต่ละชุด

$\tilde{R}_M(t)$ เป็นผลลัพธ์การพยากรณ์ของ Residual


ในที่นี้เรากำหนดให้ $\rho_i = 1$ สำหรับ $i = 1, 2, \dots, M, M + 1$

3.3 ขั้นตอนผสมผสานระหว่างการแยกส่วนประกอบของรูปแบบเชิงประจักษ์, ข้อมูลแบบสุ่มเชิงเวลาที่มีประสิทธิภาพ และโครงข่ายประสาทเทียมอย่างถูกต้องของเบส (Empirical Mode Decomposition Random Data-time Effective Radial Basis Function Neural Network) (EMD-RT-BRNN)

EMD-RT-BRNN คือขั้นตอนวิธีที่ผสมผสานระหว่าง EMD, RT และ BRNN ซึ่งขั้นตอนวิธีแต่ละส่วนมีความสำคัญดังนี้


- 1) EMD มีหน้าที่แยกส่วนประกอบอนุกรมเวลาดั้งเดิมให้ออกมาเป็นฟังก์ชันรูปแบบที่แท้จริง (IMF) หลายชุดและส่วนเหลือ (Residual) 1 ชุด
- 2) RT มีหน้าที่พิจารณาค่าความสำคัญของแต่ละจุดข้อมูลที่เกิดขึ้นในอนุกรมเวลา
- 3) BRNN มีหน้าที่เป็นเครื่องมือพยากรณ์ในรูปแบบของโครงข่ายประสาทเทียมที่มีการใช้ทฤษฎีของเบสในการช่วยลดปัญหาความพอดีที่มากเกินไปของข้อมูลที่ใช้สอน (Overfitting) และการเรียนที่มากเกินไป (Overtraining)

ลำดับขั้นตอนการทำงานของ EMD-RT-BRNN แสดงดังภาพที่ 5



ภาพที่ 5 ลำดับขั้นตอนการทำงานของ EMD-RT-BRNN


ในงานวิจัยนี้เราสร้างแบบจำลอง EMD-RT-BRNN 1 แบบจำลอง เพื่อพยากรณ์อัตราแลกเปลี่ยนของคู่สกุลเงิน EUR/USD โดยมีเอาต์พุต 2 ปมคือราคาสูงสุดและราคาต่ำสุด แบบจำลองสำหรับพยากรณ์ราคาสูงสุดของ EMD-RT-BRNN และแบบจำลองสำหรับพยากรณ์ราคาต่ำสุดของ EMD-RT-BRNN แสดงดังภาพที่ 6



ภาพที่ 6 แบบจำลองสำหรับพยากรณ์ราคาสูงสุดและราคาต่ำสุดของ EMD-RT-BRNN

3.3.1 การใช้งาน EMD

ในงานวิจัยนี้เราใช้ออนุกรมเวลาต้นแบบ 2 อุนุกรมได้แก่ อุนุกรมเวลาของราคาสูงสุดและอุนุกรมเวลาของราคาต่ำสุด เราประยุกต์ใช้ EMD ทั้งอุนุกรมเวลาของราคาสูงสุดและราคาต่ำสุดเพื่อแยกส่วนประกอบของอุนุกรมเวลา ตัวอย่างการใช้งาน EMD กับอุนุกรมเวลาของราคาสูงสุดและราคาต่ำสุด แสดงดังภาพที่ 7



ภาพที่ 7 ซ้าย) แสดงการใช้งาน EMD กับอนุกรมเวลาของราคาสูงสุด (ขวา) แสดงการใช้งาน EMD กับอนุกรมเวลาของราคาต่ำสุด (ที่มา : [2])

3.2.2 การตั้งค่าเบื้องต้นของ EMD-RT-BRNN

สำหรับแบบจำลองประเภทโครงข่ายประสาทเทียม การตั้งค่าพื้นฐานสำหรับแบบจำลองมีความสำคัญอย่างยิ่งในการสร้างงานวิจัย เนื่องจากการเปลี่ยนการตั้งค่าเบื้องต้นเพียงน้อยนิดอาจส่งผลกระทบต่อผลลัพธ์ของแบบจำลองเป็นอย่างมาก เพื่อความชัดเจนในการทำงานวิจัยผู้จัดทำจึงแสดงการตั้งค่าเบื้องต้นของแบบจำลองสำหรับแต่ละ IMF และ Residual ของอนุกรมราคาสูงสุดและอนุกรมราคาต่ำสุดดังตารางที่ 2

โครงสร้าง	15 x 6 x 2
ฟังก์ชันค่าผิดพลาด	$E(t_n) = \beta \frac{1}{N} \sum_{n=1}^N \rho(t_n) (d_{t_n} - y_{t_n})^2 + \alpha \sum_{m=1}^N w_m^2$
อินพุต	ราคาสูงสุดของทั้ง 5 วันก่อนหน้า ราคาต่ำสุดของทั้ง 5 วันก่อนหน้า EMA วันล่าสุดของราคาสูงสุด (period = 5) EMA วันล่าสุดของราคาต่ำสุด (period = 5) Upper Band วันล่าสุดของราคาปิด (period = 5) Lower Band วันล่าสุดของราคาปิด (period = 5) ราคาเปิดของวันปัจจุบัน

เอาต์พุต	ราคาสูงสุดของวันปัจจุบัน และราคาต่ำสุดของวันปัจจุบัน
การทำให้เป็นมาตรฐาน	การทำให้เป็นมาตรฐานแบบน้อยสุดมากที่สุด ซึ่งจะได้ค่าอยู่ในช่วง [0, 1]
ฟังก์ชันกระตุ้นสำหรับชั้นซ่อน	ซิกมอยด์
ฟังก์ชันกระตุ้นสำหรับชั้นเอาต์พุต	ผลรวมเชิงเส้น
ค่าน้ำหนัก	สุ่มค่าจากในช่วง (-1, 1)
จำนวนรอบการปรับค่าน้ำหนัก	1000 รอบ
อัตราการเรียนรู้	0.01

ตารางที่ 2 แสดงการตั้งค่าเบื้องต้นสำหรับแบบจำลองทั้งหมดของ EMD-RT-BRNN

3.2.3 เอาต์พุตของ EMD-RT- BRNN

หลังจากนั้นใช้ IMF และ Residual เหล่านี้เป็นอินพุตให้กับ RT-BRNN ในการพยากรณ์ ซึ่งจะได้ผลลัพธ์การพยากรณ์เป็นจำนวนชุดเท่ากับจำนวนชุดของ IMF และ Residual ที่ได้จาก EMD ในขั้นตอนสุดท้ายทำการรวมผลลัพธ์การพยากรณ์ทุกชุดให้เป็นชุดเดียวโดยใช้สมการต่อไปนี้

$$\hat{X}(t) = \sum_{i=1}^M \tilde{C}_i(t) \times \rho_i + \tilde{R}_M(t) \rho_{M+1}, \quad t = 1, \dots, N$$

โดยที่

$\hat{X}(t)$ เป็นผลลัพธ์การพยากรณ์สุดท้ายของอนุกรมเวลาหลัก

$\tilde{C}_i(t)$ เป็นผลลัพธ์การพยากรณ์ของ IMF แต่ละชุด

ρ_i เป็นสัมประสิทธิ์การรวมของผลลัพธ์การพยากรณ์สำหรับ IMF แต่ละชุด

$\tilde{R}_M(t)$ เป็นผลลัพธ์การพยากรณ์ของ Residual

ในที่นี้เรากำหนดให้ $\rho_i = 1$ สำหรับ $i = 1, 2, \dots, M, M + 1$

3.4 ชุดข้อมูล

งานวิจัยนี้พิจารณาข้อมูลอัตราแลกเปลี่ยน EUR/USD ตั้งแต่วันที่ 12 พฤษภาคม 2548 จนถึงวันที่ 6 ธันวาคม 2562 ซึ่งเป็นจำนวนวันทำการทั้งสิ้น 3,800 วัน ผู้เขียนแบ่งข้อมูลในช่วงเวลาดังกล่าวเป็นชุดข้อมูลสอนและชุดข้อมูลทดสอบ ด้วยอัตราส่วนระหว่างชุดข้อมูลสอนและชุดข้อมูลทดสอบเป็น 87.5:12.5 ซึ่งหมายความว่าข้อมูลตั้งแต่วันที่ 1 จนถึงวันที่ 3,300 จะถูกนำมาพิจารณา

เป็นชุดข้อมูลสอนเพื่อใช้ในการสร้างแบบจำลอง และข้อมูลตั้งแต่วันที่ 3,301 จนถึงวันที่ 3,800 จะถูกนำมาใช้เป็นชุดข้อมูลทดสอบเพื่อวัดประสิทธิภาพของแบบจำลอง



บทที่ 4 ระบบจำลองการซื้อขาย

4.1 ความสำคัญของระบบจำลองการซื้อขาย

การวัดประสิทธิภาพทั่ว ๆ ไป เช่น ค่าเฉลี่ยของค่าผิดพลาดยกกำลังสอง (Mean Squared Error) (MSE), ค่าเฉลี่ยของค่าคลาดเคลื่อนสมบูรณ์ (Mean Absolute Error) (MAE) และค่าเฉลี่ยของร้อยละความผิดพลาดสมบูรณ์ (Mean Absolute Percentage Error) (MAPE) ไม่ได้บ่งชี้ถึงประสิทธิภาพที่ได้จากการลงทุนจริง [7] ดังนั้นในงานวิจัยนี้เราจะทำการสร้างระบบจำลองการซื้อขาย (Trading System) ขึ้นมาเพื่อวัดประสิทธิภาพของโครงข่ายประสาทเทียมแต่ละชั้นตอนวิธีเมื่อนำผลลัพธ์ไปใช้ในการลงทุน ระบบจำลองการซื้อขายประกอบด้วย 3 ส่วนหลักได้แก่ กลยุทธ์การลงทุน, วิธีการจัดการความเสี่ยง และหลักการบริหารเงิน

4.2 ระบบจำลองการซื้อขาย

ผลลัพธ์การพยากรณ์ราคาสูงสุดและราคาต่ำสุดรายวันของ EMD-RT-RBFNN และ EMD-RT-BRNN จะถูกใช้เป็นอินพุตให้กับระบบจำลองการซื้อขาย ระบบจำลองการซื้อขายประกอบด้วย 3 ส่วนหลักได้แก่ กลยุทธ์การลงทุน, วิธีการจัดการความเสี่ยง และหลักการบริหารเงิน ในงานวิจัยนี้ใช้ราคาปิดที่กรอบเวลา 15 นาทีในการพิจารณาการลงทุน

ให้ $close$ เป็นราคาปิดของกรอบเวลา 15 นาที

min เป็นราคาต่ำสุดที่ได้จากการพยากรณ์

max เป็นราคาสูงสุดที่ได้จากการพยากรณ์

ตรรกะของระบบการลงทุนสามารถแบ่งได้เป็น 3 เงื่อนไขดังนี้

1. ในกรณีที่ไม่มีคำสั่งซื้อหรือขายเปิดอยู่
 - a. ถ้า $close \leq min$ แล้วเปิดคำสั่งซื้อ
 - b. ถ้า $close \geq max$ แล้วเปิดคำสั่งขาย
 - c. ถ้า $min < close < max$ แล้วไม่ทำอะไร
2. ในกรณีที่ถือคำสั่งซื้ออยู่
 - a. ถ้า $close \leq min$ แล้วไม่ทำอะไร
 - b. ถ้า $close \geq max$ แล้วปิดคำสั่งซื้อและเปิดคำสั่งขาย
 - c. ถ้า $min < close < max$ แล้วไม่ทำอะไร
 - d. ถ้า $close$ ผ่านราคา ณ จุดตัดขาดทุน แล้วปิดคำสั่งซื้อ

- e. ถ้าเป็นราคาที่สุดท้ายของวัน แล้วปิดคำสั่งซื้อ
3. ในกรณีที่ถือคำสั่งขายอยู่
- ถ้า $close \leq min$ แล้วปิดคำสั่งขายและเปิดคำสั่งซื้อ
 - ถ้า $close \geq max$ แล้วไม่ทำอะไร
 - ถ้า $min < close < max$ แล้วไม่ทำอะไร
 - ถ้า $close$ ผ่านราคา ณ จุดตัดขาดทุน แล้วปิดคำสั่งขาย
 - ถ้าเป็นราคาที่สุดท้ายของวัน แล้วปิดคำสั่งขาย

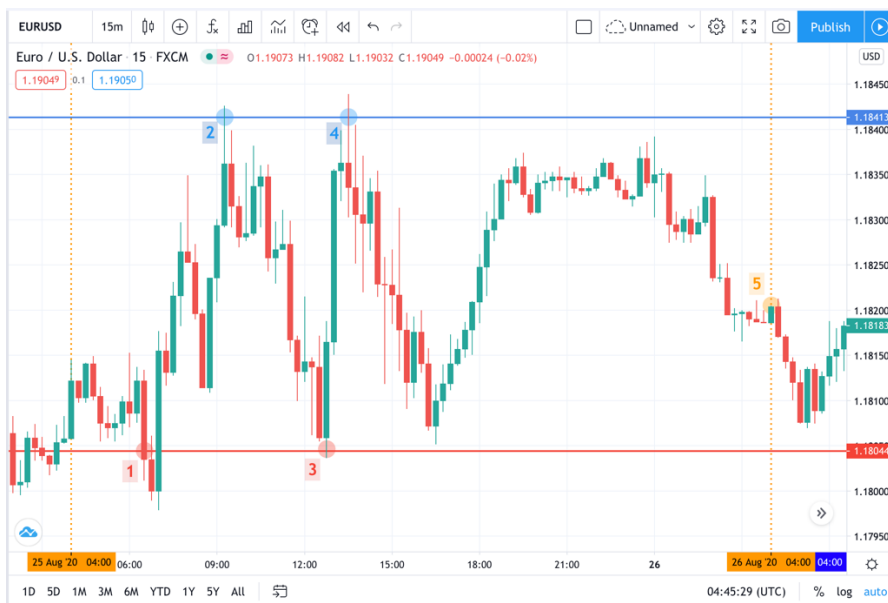
สรุปกลยุทธ์การลงทุนได้เป็น 6 ข้อดังนี้

- ซื้อ เมื่อ $close \leq min$, ขาย เมื่อ $close \geq max$
- ซื้อ เมื่อ $close \leq min$, ขายในราคาที่สุดท้ายของวัน
- ซื้อ เมื่อ $close \leq min$, ขายที่จุดหยุดการขาดทุน
- ขาย เมื่อ $close \geq max$, ซื้อ เมื่อ $close \leq min$
- ขาย เมื่อ $close \geq max$, ซื้อในราคาที่สุดท้ายของวัน
- ขาย เมื่อ $close \geq max$, ซื้อที่จุดหยุดการขาดทุน

เพื่อความชัดเจนในการอธิบายระบบจำลองการซื้อขาย ผู้เขียนนำเสนอตัวอย่างการทำงานของระบบจำลองการซื้อขาย 3 ตัวอย่าง ซึ่งแต่ละตัวอย่างจะเป็นเหตุการณ์ที่แตกต่างกันทั้งหมด

ตัวอย่างที่ 1

ในตัวอย่างนี้เรายังไม่พิจารณาเรื่องจุดตัดขาดทุน เส้นประสีส้มแสดงถึงจุดเวลาเริ่มต้นและเวลาสิ้นสุดของวัน เส้นทึบสีน้ำเงินแสดงถึงราคาสูงสุดที่พยากรณ์ได้ในวันนั้น ๆ และเส้นทึบสีแดงแสดงถึงราคาต่ำสุดที่พยากรณ์ได้ในวันนั้น ๆ ภาพที่ 8 แสดงตัวอย่างการเปิดคำสั่งซื้อขายใน 1 วัน ซึ่งบรรยายได้ดังนี้ เมื่อราคาปิดของกรอบเวลา 15 นาทีลงมาต่ำกว่าเส้นราคาต่ำสุดพยากรณ์เราจะเปิดคำสั่งซื้อที่ตำแหน่ง 1 หลังจากนั้นเมื่อราคาขึ้นไปจนสูงกว่าราคาสูงสุดพยากรณ์เราจะปิดคำสั่งซื้อที่ตำแหน่ง 2 และขณะเดียวกันเราก็จะเปิดคำสั่งขาย ต่อมาเมื่อราคาลงกลับมาถึงจุดที่ต่ำกว่าราคาต่ำสุดพยากรณ์เราก็จะปิดคำสั่งขายและเปิดคำสั่งซื้อที่ตำแหน่ง 3 เมื่อราคาขึ้นจนถึงตำแหน่งที่ 4 เราก็จะปิดคำสั่งซื้อและเปิดคำสั่งขาย และเราจะเห็นได้ว่าต่อจากนั้นราคาไม่เคลื่อนที่ผ่านเส้นราคาสูงสุดและต่ำสุดพยากรณ์อีกเลย สิ่งที่ระบบของเราทำก็คือปิดคำสั่งซื้อขายทั้งหมดที่นาที่สุดท้ายของวัน



ภาพที่ 8 ตัวอย่างที่ 1 ของระบบจำลองการซื้อขาย (ที่มา : <https://www.tradingview.com/chart/Uy3q4WdP/>)

ตัวอย่างที่ 2

ในตัวอย่างนี้เรายังไม่พิจารณาเรื่องจุดตัดขาดทุน เส้นประสีส้มแสดงถึงจุดเวลาเริ่มต้นและเวลาสิ้นสุดของวัน เส้นทึบสีน้ำเงินแสดงถึงราคาสูงสุดที่พยากรณ์ได้ในวันนี้ และเส้นทึบสีแดงแสดงถึงราคาต่ำสุดที่พยากรณ์ได้ในวันนี้ ๑ ภาพที่ 9 แสดงตัวอย่างการเปิดคำสั่งซื้อขายใน 1 วัน ซึ่งบรรยายได้ดังนี้ เส้นราคาสูงสุดพยากรณ์เป็นเส้นแรกที่ราคาปิดของกรอบเวลา 15 นาทีไปสัมผัส ณ ตำแหน่งที่ 1 เราเปิดคำสั่งขาย หลังจากนั้นเราจะเห็นได้ว่าราคาอยู่เหนือเส้นราคาสูงสุดพยากรณ์เกือบตลอด แต่เราไม่เปิดคำสั่งขายเพิ่ม เพราะเรายังมีคำสั่งขายที่ยังไม่ปิดค้างอยู่ สุดท้ายเราจะไปปิดคำสั่งขายนี้ที่นาทีสุดท้ายของวัน ณ ตำแหน่งที่ 2



ภาพที่ 9 ตัวอย่างที่ 2 ของระบบจำลองการซื้อขาย (ที่มา :

<https://www.tradingview.com/chart/Uy3q4WdP/>)

ตัวอย่างที่ 3

ในตัวอย่างนี้เราพิจารณาเรื่องจุดตัดขาดทุน เส้นประสีส้มแสดงถึงจุดเวลาเริ่มต้นและเวลาสิ้นสุดของวัน เส้นทึบสีน้ำเงินแสดงถึงราคาสูงสุดที่พยากรณ์ได้ในวันนั้น ๆ เส้นทึบสีแดงแสดงถึงราคาต่ำสุดที่พยากรณ์ได้ในวันนั้น ๆ เส้นประสีม่วงแสดงราคา ณ จุดตัดขาดทุน ภาพที่ 10 แสดงตัวอย่างการเปิดคำสั่งซื้อขายใน 1 วัน ซึ่งบรรยายได้ดังนี้ เส้นราคาสูงสุดพยากรณ์เป็นเส้นแรกที่ราคาปิดของกรอบเวลา 15 นาทีไปสัมผัส ณ ตำแหน่งที่ 1 เราเปิดคำสั่งขาย หลังจากนั้นจะเห็นว่าราคาเคลื่อนที่ไปสัมผัสเส้นประสีม่วงซึ่งเป็นจุดตัดขาดทุนของคำสั่งขายที่ตำแหน่ง 2 เมื่อเราตัดขาดทุนเสร็จ เราจะเปิดคำสั่งขายอีกครั้งที่ 2 ตามกลยุทธ์การลงทุนตามที่กล่าวข้างต้น สุดท้ายเราจะไปปิดคำสั่งขายนี้ที่นาทีสุดท้ายของวัน ณ ตำแหน่งที่ 3



ภาพที่ 10 ตัวอย่างที่ 3 ของระบบจำลองการซื้อขาย (ที่มา :

<https://www.tradingview.com/chart/Uy3q4WdP/>)

ระบบจำลองการซื้อขายมีการจัดการความเสี่ยงและการบริหารเงินด้วยการตั้งจุดหยุดขาดทุนไว้ที่ 1% ของเงินในบัญชี [7] จำนวนเงินตั้งต้นในบัญชีคือ 10,000 ดอลลาร์ และในงานวิจัยนี้เราใช้อัตราทดในการเทรดเป็น 1:3 นั่นหมายความว่าจากเงินต้นที่เรามี 10,000 ดอลลาร์ เราสามารถลงทุนด้วยด้วยจำนวนเงินสูงสุด 30,000 ดอลลาร์ ด้วยหลักอัตราทดที่บริษัทซื้อขายหลักอัตราแลกเปลี่ยนเสนอให้เรา ในที่นี้เราซื้อขายอัตราแลกเปลี่ยนแต่ละครั้งด้วยจำนวนเงิน 20,000 ดอลลาร์

4.3 ผลการทดลอง

ผู้จัดทำป้อนราคาสูงสุดและราคาต่ำสุดที่ได้จากการพยากรณ์ของโครงข่ายประสาทเทียมต้นแบบ 4 แบบจำลอง (BPNN, BRNN, EMD-STNN, RF-RBFNN) และโครงข่ายประสาทเทียมที่นำเสนอในงานวิจัยนี้อีก 2 แบบจำลอง (EMD-RF-RBFNN, EMD-RF-BRNN) ไปเป็นอินพุตให้กับระบบจำลองการซื้อขายเพื่อทดสอบประสิทธิภาพของแบบจำลองบนข้อมูลทดสอบ ในที่นี้เราวัดประสิทธิภาพของโครงข่ายประสาทเทียมในแง่ของผลตอบแทนรวม (Total Return) และร้อยละการขาดทุนสะสม (Drawdown) ผลตอบแทนรวมสามารถคำนวณได้ดังสมการต่อไปนี้

$$\text{ผลตอบแทนรวม} = \frac{(\text{จำนวนเงินในวันสุดท้าย} - \text{จำนวนเงินตั้งต้น}) \times 100}{\text{จำนวนเงินตั้งต้น}}$$

ร้อยละการขาดทุนสะสมคือ ร้อยละการขาดทุนต่อเนื่องสูงสุดระหว่าง 2 จุดสูงสุดของเงินสะสมในบัญชี ประสิทธิภาพของแบบจำลองทั้ง 6 งานแสดงดังตารางที่ 3

แบบจำลอง	ผลตอบแทนรวม (%)	ร้อยละการขาดทุนสะสม (%)	จำนวนการซื้อขายต่อวัน (%)
BPNN	1.14	12.20	0.59
BRNN	13.74	12.28	0.64
EMD-STNN	4.67	9.19	0.44
RT-RBFNN	5.35	11.34	0.61
EMD-RT-RBFNN	20.64	6.96	0.51
EMD-RT-BRNN	21.27	8.48	0.65

ตารางที่ 3 ประสิทธิภาพของแบบจำลอง

ผลลัพธ์ที่ได้จากงานวิจัยนี้ได้จากเวลาตามบทที่ 3.4

4.4 สรุปผลการทดลอง

ในงานวิจัยชิ้นนี้ผู้เขียนนำเสนอแบบจำลองโครงข่ายประสาทเทียม 2 แบบจำลอง ได้แก่ EMD-RT-RBFNN และ EMD-RT-BRNN ซึ่งแบบจำลองที่นำเสนอได้รับผลตอบแทนที่ดีกว่างานวิจัยต้นแบบทั้ง 4 งาน ซึ่งเป็นผลเนื่องมาจากความสามารถของ EMD ในการสกัดข้อมูลในอนุกรมเวลาซึ่งช่วยเพิ่มประสิทธิภาพของ RT-RBFNN และ RT-BRNN

การที่ผลตอบแทนของ EMD-RT-BRNN สูงกว่าแบบจำลองอื่น ๆ เป็นผลมาจากการลดปัญหาความพอดีที่มากเกินไปของข้อมูลที่ใช้สอนของ BRNN และศักยภาพของข้อมูลแบบสุ่มเชิงเวลาที่มีประสิทธิภาพในการพิจารณาค่าน้ำหนักของแต่ละจุดข้อมูลในอนุกรมเวลา

บทที่ 5 สรุปผลการวิจัย และข้อเสนอแนะ

5.1 สรุปผลการวิจัย

โครงข่ายประสาทเทียมให้ผลลัพธ์ที่มีประสิทธิภาพเนื่องจากโครงข่ายประสาทเทียมสามารถส่งค่าจากอินพุตไปยังเอาต์พุตได้โดยไม่ต้องมีสมมติฐานใด แต่อย่างไรก็ตามปัญหาความพอดีที่มากเกินไปของข้อมูลสอน และการเรียนที่มากเกินไปอาจทำให้โครงข่ายประสาทเทียมที่เราสร้างขึ้นไม่มีประสิทธิภาพเท่าที่ควร ในงานวิจัยนี้เราประยุกต์ใช้การทำให้อัตราการเรียนรู้ของเบสกับโครงข่ายประสาทเทียม ได้เป็นขั้นตอนวิธีที่มีชื่อว่าโครงข่ายประสาทเทียมอย่างถูกต้องของเบส นอกจากนั้นในงานวิจัยนี้เรายังประยุกต์ใช้เรเดียลเบซิสฟังก์ชันกับโครงข่ายประสาทเทียม ได้เป็นขั้นตอนวิธีที่มีชื่อว่าโครงข่ายประสาทเทียมแบบเรเดียลเบซิสฟังก์ชัน

ตลาดการซื้อขายอัตราแลกเปลี่ยนเป็นตลาดที่มีการพัฒนาการในการลงทุนเรื่อยมา นักลงทุนในแต่ละยุคสมัยก็จะมีวิธีการลงทุนที่แตกต่างกัน ยกตัวอย่างเช่น วิธีการลงทุนก่อนหน้าที่จะมีอินเทอร์เน็ต และการลงทุนหลังจากมีอินเทอร์เน็ต การลงทุนก่อนหน้าการมีอินเทอร์เน็ตนักลงทุนอาจเข้าถึงความรู้ที่ถูกต้องที่บรรยายเกี่ยวกับพฤติกรรมที่แท้จริงของตลาดได้ยาก ไม่มีกลุ่มสังคมออนไลน์ให้ได้แย้งกันในมุมมองต่าง ๆ เกี่ยวกับการลงทุน รวมทั้งวิธีการซื้อขายที่ต้องผ่านนายหน้าโดยการโทรศัพท์หรือการเจอหน้า ซึ่งนายหน้าอาจส่งผลโดยตรงต่อการตัดสินใจลงทุนของเรา และความถี่ในการทำธุรกรรมของนักลงทุน ส่วนการลงทุนหลังจากมีอินเทอร์เน็ต นักลงทุนสามารถเข้าถึงความรู้ได้ง่าย และยังสามารถทำธุรกรรมต่าง ๆ ได้ด้วยตนเองโดยไม่ต้องโทรศัพท์หรือเจอหน้ากับนายหน้า ด้วยเหตุผลดังที่กล่าวมา ทำให้เห็นได้ว่าตลาดการซื้อขายมีวิวัฒนาการจากพฤติกรรมที่เปลี่ยนไปของนักลงทุน ทั้งในแง่ของข้อมูลข่าวสารที่นักลงทุนได้รับ และในแง่ของวิธีการซื้อขาย ซึ่งจะเห็นได้ว่าคงเป็นการดีที่เราสร้างแบบจำลองโดยอ้างอิงจากข้อมูลที่เกิดขึ้นที่ระยะเวลาที่ใกล้กับปัจจุบัน แต่อย่างไรก็ตามการทำแบบนั้นจะทำให้เราสูญเสียข้อมูลในอดีตไปจำนวนมาก ซึ่งข้อมูลเหล่านั้นก็ยังคงมีความสำคัญและมีความรู้ที่ซ่อนอยู่ที่รอใช้ประโยชน์จากข้อมูลเหล่านั้น ในงานวิจัยนี้เราประยุกต์ใช้ฟังก์ชันความแรงของเวลาอย่างสุ่มกับโครงข่ายประสาทเทียมอย่างถูกต้องของเบสและโครงข่ายประสาทเทียมแบบเรเดียลเบซิสฟังก์ชัน ความสามารถของฟังก์ชันความแรงของเวลาอย่างสุ่มคือการพิจารณาความสำคัญของแต่ละจุดข้อมูลที่เกิดขึ้นในกนรูปกรมเวลา

มุมมองของเวลาต่ออนุกรมเวลาของอัตราแลกเปลี่ยนคู่สกุลเงินนั้นเป็นเรื่องที่มีความสำคัญในการพิจารณาเป็นอย่างยิ่ง ในชุดข้อมูลเดียวกันเพียงแต่เราปรับมุมมองของเวลาในการมองดูข้อมูลชุดนั้นก็จะทำให้เราตีความข้อมูลชุดนั้นแตกต่างกัน ยกตัวอย่างเช่น ถ้าเรามองดูข้อมูลในช่วงระยะเวลาหนึ่งสัปดาห์ย้อนหลังอาจมองได้ว่าพฤติกรรมของข้อมูลมีทิศทางเป็นแนวโน้มขึ้น แต่

ถ้าเรามองในช่วงเวลาหนึ่งเดือนย้อนหลังอาจมองได้ว่าไม่มีทิศทางไปด้านใดด้านหนึ่ง หรือถ้ามองในช่วงระยะเวลาหนึ่งปีย้อนหลังอาจมองได้ว่าพฤติกรรมของข้อมูลมีทิศทางเป็นแนวโน้มลง จะเห็นว่าเป็นประโยชน์กับนักลงทุนมากถ้าเรามีขั้นตอนวิธีที่สามารถพิจารณาอนุกรมเวลาที่เรามีอยู่ได้อย่างครบถ้วนทุกมุมของเวลา ในงานวิจัยนี้เราประยุกต์ใช้การแยกส่วนประกอบของรูปแบบเชิงประจักษ์ในการเตรียมข้อมูลให้กับขั้นตอนวิธีที่นำเสนอในงานชิ้นนี้ การแยกส่วนประกอบของรูปแบบเชิงประจักษ์มีความสามารถในการสกัดข้อมูลจากอนุกรมเวลาต้นแบบให้กลายเป็นอนุกรมเวลาย่อยหลาย ๆ ชุด ซึ่งเมื่อเรานำอนุกรมเวลาย่อยหลาย ๆ ชุดมารวมกันก็จะได้เป็นอนุกรมเวลาต้นแบบ

5.2 ข้อเสนอแนะ

ข้อเสนอแนะต่อไปนี้เป็นแนวทางในการวิจัยที่จะนำเสนอเพื่อพัฒนาขั้นตอนวิธีการเรียนรู้ของเครื่องสำหรับการใช้งานวิเคราะห์ตลาดอัตราแลกเปลี่ยนเพื่อให้มีประสิทธิภาพที่สูงยิ่งขึ้น ในงานวิจัยนี้มีประกอบย่อยที่ต้องพิจารณาอยู่ด้วยกัน 3 ส่วนได้แก่ 1) วิธีการเตรียมชุดข้อมูล 2) วิธีการสร้างแบบจำลอง 3) วิธีการออกแบบระบบจำลองการซื้อขาย

วิธีการเตรียมข้อมูลที่เราใช้ในงานวิจัยนี้อ้างอิงมาจากวิธีการเตรียมข้อมูลของ [7] ซึ่งมีการเก็บข้อมูลทุกวัน ณ เวลาเปิดตลาด ซึ่งจุดที่ใช้เก็บข้อมูลนี้เป็นจุดเดียวกันกับจุดที่เราจะเข้าทำการซื้อขายในการใช้งานจริง นั่นหมายความว่าในการใช้งานจริง เราก็จะเข้าทำการซื้อขาย ณ เวลาเปิดตลาดเช่นกัน เราสามารถพัฒนางานวิจัยในอนาคตต่อด้วยการเปลี่ยนการตั้งค่าเริ่มต้นการซื้อขายและการเตรียมข้อมูลให้สอดคล้องกับวิธีการลงทุนในตลาดอัตราแลกเปลี่ยนให้มากขึ้น และเลือกคุณลักษณะที่มีสมมติฐานจากความเข้าใจกลไกของการเก็งกำไรของตลาด นอกจากนี้วิธีการเตรียมเอาต์พุตเป้าหมายก็เป็นประเด็นที่สามารถพัฒนาต่อไปได้อีกเพื่อให้สอดคล้องกับพฤติกรรมของการลงทุนในตลาดอัตราแลกเปลี่ยนให้มากยิ่งขึ้น

วิธีการสร้างแบบจำลองที่เราใช้ในงานวิจัยนี้มีพื้นฐานมาจากขั้นตอนวิธีโครงข่ายประสาทเทียมทั้งหมด งานวิจัยในอนาคตสามารถถูกพัฒนาได้ด้วยการเปลี่ยนขั้นตอนวิธีในการวิเคราะห์เป็นขั้นตอนวิธีอื่น ๆ ในการเรียนรู้ของเครื่อง สิ่งสำคัญในการเลือกขั้นตอนวิธีในการใช้งาน ผู้ทำงานวิจัยในอนาคตควรมีความเข้าใจในขั้นตอนวิธีนั้นอย่างแท้จริงและลึกซึ้งถึงในระดับของสมมติฐานของขั้นตอนวิธีนั้น ๆ เพราะนั่นเป็นเพียงวิธีเดียวที่จะเข้าใจได้ว่าขั้นตอนวิธีที่เราเลือกมีข้อดีข้อเสียอย่างไร และเหมาะสมกับข้อมูลในลักษณะใดเป็นพิเศษ เพราะการใช้เครื่องมือให้เหมาะสมกับงานเป็นสิ่งสำคัญอย่างยิ่ง นอกจากนี้การทำความเข้าใจคุณลักษณะเฉพาะตัวของข้อมูลที่เราทำการวิเคราะห์ก็มีความสำคัญเช่นกัน

จากการวิเคราะห์ผลลัพธ์ที่ได้มาจากระบบจำลองการซื้อขาย ผู้จัดทำเห็นได้ว่าในหลาย ๆ ครั้งคำสั่งซื้อขายของเรานั้นทำกำไรแต่เราไม่ทำการปิดคำสั่งซื้อขาย เมื่อมีเหตุการณ์บางอย่างเกิดขึ้นในตลาดทำให้

ตลาดผันผวนและกลับทิศทาง จากเดิมที่คำสั่งซื้อขายของเราที่ได้กำไรก็กลายเป็นขาดทุนและปิดคำสั่งซื้อขายที่จุดตัดขาดทุน ระบบจำลองการซื้อขายสามารถพัฒนาเพิ่มเติมได้ด้วยการเลื่อนจุดขาดทุนให้ขาดทุนน้อยลงหรือเลื่อนจุดขาดทุนให้ได้กำไร เมื่อคำสั่งซื้อขายของเราทำกำไร วิธีการนี้จะช่วยปกป้องเงินในบัญชีของเราจากความไม่แน่นอนของตลาดได้มากยิ่งขึ้น



บรรณานุกรม

1. *Triennial Central Bank Survey of foreign exchange and OTC derivatives markets in 2016*. [cited 2018 May 9]; Available from: <https://www.bis.org/pub/rpfx16.htm>.
2. Wang, J. and J.J.N.N. Wang, *Forecasting stochastic neural network based on financial empirical mode decomposition*. 2017. **90**: p. 8-20.
3. Ticknor, J.L.J.E.S.w.A., *A Bayesian regularized artificial neural network for stock market forecasting*. 2013. **40**(14): p. 5501-5506.
4. Singh, M., *17 Proven Currency Trading Strategies: How to Profit in the Forex Market*. 2012: John Wiley & Sons.
5. Refenes, A.N., A. Zapranis, and G.J.N.n. Francis, *Stock performance modeling using neural networks: a comparative study with regression models*. 1994. **7**(2): p. 375-388.
6. Niu, H. and J.J.S.C. Wang, *Financial time series prediction by a random data-time effective RBF neural network*. 2014. **18**(3): p. 497-508.
7. Martinez, L.C., et al. *From an artificial neural network to a stock market day-trading system: A case study on the bm&f bovespa*. in *2009 International Joint Conference on Neural Networks*. 2009. IEEE.
8. *Backpropagation*.
9. Marquardt, D.W.J.J.o.t.s.f.l. and A. Mathematics, *An algorithm for least-squares estimation of nonlinear parameters*. 1963. **11**(2): p. 431-441.
10. MacKay, D.J.J.N.c., *Bayesian interpolation*. 1992. **4**(3): p. 415-447.
11. Wilamowski, B.M. and H.J.I.t.o.n.n. Yu, *Improved computation for Levenberg–Marquardt training*. 2010. **21**(6): p. 930-937.
12. Cavalcante, R.C., et al., *Computational intelligence and financial markets: A survey and future directions*. 2016. **55**: p. 194-211.
13. Yao, J. and C.L.J.N. Tan, *A case study on using neural networks to perform technical forecasting of forex*. 2000. **34**(1-4): p. 79-98.
14. Foresee, F.D. and M.T. Hagan. *Gauss-Newton approximation to Bayesian*

- learning*. in *Proceedings of International Conference on Neural Networks (ICNN'97)*. 1997. IEEE.
15. Liao, Z. and J.J.E.S.w.A. Wang, *Forecasting model of global stock index by stochastic time effective neural network*. 2010. **37**(1): p. 834-841.
 16. Liu, F. and J.J.N. Wang, *Fluctuation prediction of stock market index by Legendre neural network with random time strength function*. 2012. **83**: p. 12-21.
 17. Wang, J. and J.J.N. Wang, *Forecasting stock market indexes using principle component analysis and stochastic time effective neural networks*. 2015. **156**: p. 68-78.
 18. Chandar, S.K., et al., *Prediction of stock market price using hybrid of wavelet transform and artificial neural network*. 2016. **9**(8): p. 1-5.
 19. Nikfarjam, A., E. Emadzadeh, and S. Muthaiyah. *Text mining approaches for stock market prediction*. in *2010 The 2nd international conference on computer and automation engineering (ICCAE)*. 2010. IEEE.
 20. Schumaker, R.P., et al., *Evaluating sentiment in financial news articles*. 2012. **53**(3): p. 458-464.
 21. Gidofalvi, G., C.J.D.o.C.S. Elkan, and U.o.C. Engineering, San Diego, *Using news articles to predict stock price movements*. 2001.
 22. Groth, S.S. and J.J.D.S.S. Muntermann, *An intraday market risk management approach based on textual analysis*. 2011. **50**(4): p. 680-691.
 23. Nassirtoussi, A.K., et al., *Text mining of news-headlines for FOREX market prediction: A Multi-layer Dimension Reduction Algorithm with semantics and sentiment*. 2015. **42**(1): p. 306-324.



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

ประวัติผู้เขียน

ชื่อ-สกุล	ฉฤณ ชินประสาทศักดิ์
วัน เดือน ปี เกิด	1 พฤษภาคม 2537
สถานที่เกิด	กรุงเทพมหานคร



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY