

โครงร่างวิทยานิพนธ์  
(THESIS PROPOSAL)

ชื่อเรื่อง (ภาษาไทย)	โครงข่ายประสาทเทียมสำหรับพยากรณ์ราคาสูงสุดและราคาต่ำสุดบนตลาดอัตราแลกเปลี่ยน
ชื่อเรื่อง (ภาษาอังกฤษ)	Neural Network for Forecasting High Price and Low Price on Foreign Exchange Market
เสนอโดย	นายชฎณ ชินประสาทศักดิ์
รหัสนิสิต	5970119821
หลักสูตร	วิศวกรรมศาสตรมหาบัณฑิต
ภาควิชา	วิศวกรรมคอมพิวเตอร์
คณะ	วิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
สถานที่ติดต่อ	928/10 ถนนพระราม 6 ซอย 21 เขตราชเทวี แขวงถนนเพชรบุรี กรุงเทพฯ
โทรศัพท์	0865244463
อีเมลล์	krinnirk1151@gmail.com
อาจารย์ที่ปรึกษา	ผศ. ดร. นัทที นิภานันท์
คำสำคัญ (ภาษาไทย)	การเรียนรู้ของเครื่อง, โครงข่ายประสาทเทียม, การทำให้ถูกต้องของเบสส์, การแยกส่วนประกอบของรูปแบบเชิงประจักษ์, ฟังก์ชันความแรงของเวลาอย่างนุ่ม, โครงข่ายประสาทเทียมแบบความแรงของเวลาอย่างนุ่ม, เรเดียลเบซิสฟังก์ชัน, โครงข่ายประสาทเทียมแบบเรเดียลเบซิสฟังก์ชัน, อัตราแลกเปลี่ยน, การพยากรณ์
คำสำคัญ (ภาษาอังกฤษ)	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

## สารบัญ

	หน้า
1. ที่มาและความสำคัญของปัญหา .....	3
2. วัตถุประสงค์ .....	4
3. ทฤษฎีที่เกี่ยวข้อง .....	4
4. งานวิจัยที่เกี่ยวข้อง .....	14
5. แนวคิดและวิธีการดำเนินงาน .....	18
6. ขอบเขตการดำเนินงาน .....	25
7. ประโยชน์ที่คาดว่าจะได้รับ .....	25
8. รายการอ้างอิง .....	26

## 1. ที่มาและความสำคัญของปัญหา

ตลาดอัตราแลกเปลี่ยนเป็นตลาดการเงินที่ใหญ่ที่สุดในโลกด้วยปริมาณการซื้อขายต่อวันที่มากกว่า 5.1 ล้านล้านล้าน เหรียญดอลลาร์สหรัฐ (ณ วันที่ 11 ธันวาคม 2559) [10] เป็นมูลค่ามากกว่า 23 เท่าของมูลค่าการซื้อขายเฉลี่ยต่อวันของตลาดทุนโลกและมากกว่า 40 เท่าของผลประกอบการประจำปีของผลิตภัณฑ์มวลรวมโลก การพยากรณ์อัตราแลกเปลี่ยนเป็นสิ่งที่ทำนายนักวิจัยทั่วโลกเนื่องจากผลประโยชน์ที่น่าสนใจในการลงทุน [3] อย่างไรก็ตามการพยากรณ์อัตราแลกเปลี่ยนมีความซับซ้อนมากเนื่องจากสถานะแวดล้อมที่เต็มไปด้วยสัญญาณรบกวนและความผันผวนที่สูง [2] ความซับซ้อนของการเคลื่อนไหวของอัตราแลกเปลี่ยนมีความเกี่ยวข้องกับหลายปัจจัยได้แก่ เศรษฐกิจ, การเมือง, ภัยธรรมชาติ และการเก็งกำไร โดยเฉลี่ยแล้วมากกว่า 90% ของปริมาณการซื้อขายในแต่ละวันในตลาดอัตราแลกเปลี่ยนคือการเก็งกำไร [9] เทคนิคทางสถิติแบบดั้งเดิมสำหรับการพยากรณ์ได้มาถึงขีดจำกัดในการประยุกต์ใช้งานกับข้อมูลที่ไม่เป็นเชิงเส้น เช่นอัตราแลกเปลี่ยนคู่สกุลเงิน [8] ปัญญาประดิษฐ์เข้ามามีบทบาทในการวิเคราะห์และพยากรณ์ข้อมูลที่มีความซับซ้อนเกินกว่าความสามารถทางสถิติจะแก้ได้ ผู้จัดทำมีความสนใจในการใช้ปัญญาประดิษฐ์เพื่อพยากรณ์อัตราแลกเปลี่ยนคู่สกุลเงิน ขั้นตอนวิธีในการวิเคราะห์ข้อมูลของปัญญาประดิษฐ์มีอยู่ด้วยกันหลายวิธี เช่น โครงข่ายประสาทเทียม (Artificial Neural Network), ต้นไม้ตัดสินใจ (Decision Tree), การเรียนรู้ของเบย์ (Bayesian Learning), ขั้นตอนวิธีเชิงพันธุกรรม (Genetic Algorithm) ฯลฯ ในงานวิจัยนี้ผู้จัดทำมีความสนใจใช้โครงข่ายประสาทเทียมในการพยากรณ์ข้อมูล เนื่องจากความสามารถของโครงข่ายประสาทเทียมที่สามารถประมาณฟังก์ชันต่อเนื่องไม่เชิงเส้นใด ๆ ก็ได้โดยไม่ต้องกำหนดรูปแบบอย่างเป็นทางการให้กับแบบจำลอง [4]

ในงานวิจัยนี้ผู้จัดทำวัดประสิทธิภาพของโครงข่ายประสาทเทียม (Artificial Neural Network) จากงานวิจัยต้นแบบ 4 ขั้นตอนวิธี และโครงข่ายประสาทเทียมที่นำเสนอ 3 ขั้นตอนวิธี ในการพยากรณ์อัตราแลกเปลี่ยนรายวันของคู่สกุลเงิน EUR/USD, USD/JPY, GBP/USD และ USD/THB 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. ขั้นตอนผสมผสานระหว่างข้อมูลแบบสุ่มเชิงเวลาที่มีประสิทธิภาพกับโครงข่ายประสาทเทียมแบบเรเดียลเบซิสฟังก์ชัน (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 ถูกตีพิมพ์ในงานวิจัยที่มีจำนวนผู้อ้างอิงเยอะและงานวิจัยเหล่านี้อยู่ในวารสารที่มีดัชนีเฮิร์ช (Hirsch Index) (H Index) สูง และผู้จัดทำได้นำเสนอโครงข่ายประสาทเทียมขึ้นมา 3 ขั้นตอนวิธี ได้แก่ 1. ขั้นตอนผสมผสานระหว่างการแยกส่วนประกอบของรูปแบบเชิงประจักษ์, ข้อมูลแบบสุ่มเชิงเวลาที่มีประสิทธิภาพ และโครงข่ายประสาทเทียมแบบเรเดียลเบซิสฟังก์ชัน (Empirical Mode Decomposition Random Data-time Effective Radial Basis Function Neural Network) (EMD-RBFRT) 2. ขั้นตอนผสมผสานระหว่างการแยกส่วนประกอบของรูปแบบเชิงประจักษ์, การทำให้ถูกต้องของเบย์, ข้อมูลแบบสุ่มเชิงเวลาที่มีประสิทธิภาพ และโครงข่ายประสาทเทียมแบบเรเดียลเบซิสฟังก์ชัน (Empirical Mode Decomposition Bayesian Regularized Random Data-time Effective Radial Basis Function Neural Network) (EMD-BR-RBFRT) 3. ขั้นตอนผสมผสานระหว่างการแยกส่วน

ประกอบของรูปแบบเชิงประจักษ์, การทำให้ถูกต้องของเบส และโครงข่ายประสาทเทียมแบบความแรงของเวลาอย่างสุ่ม (Empirical Mode Decomposition Bayesian Regularized Stochastic Time Strength Neural Network) (EMD-BR-STNN) ในการพยากรณ์อัตราแลกเปลี่ยนคู่สกุลเงินด้วยเหตุผล 3 ประการ 1) การใช้ EMD อาจให้ผลลัพธ์การพยากรณ์ที่แม่นยำมากขึ้น เพราะการใช้ EMD-STNN ให้ผลลัพธ์การพยากรณ์ที่แม่นยำกว่า STNN บนข้อมูลตลาดหุ้น 2) การใช้ RBFRT อาจให้ผลลัพธ์การพยากรณ์ที่แม่นยำมากขึ้น เพราะการใช้ RBFRT ให้ผลลัพธ์การพยากรณ์ที่แม่นยำกว่า STNN บนข้อมูลตลาดหุ้น 3) การใช้การทำให้ถูกต้องของเบส (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), ค่าเฉลี่ยของค่าตลาดเคลื่อนสมบูรณ์ (Mean Absolute Error) (MAE) และค่าเฉลี่ยของร้อยละความผิดพลาดสมบูรณ์ (Mean Absolute Percentage Error) (MAPE) ไม่ได้บ่งชี้ถึงประสิทธิภาพที่ได้จากการลงทุนจริง [1] ดังนั้นในงานวิจัยนี้เราจะทำการสร้างระบบจำลองการซื้อขาย (Trading System) ขึ้นมาเพื่อวัดประสิทธิภาพของโครงข่ายประสาทเทียมแต่ละขั้นตอนวิธีเมื่อนำผลลัพธ์ไปใช้ในการลงทุน ระบบจำลองการซื้อขายประกอบด้วย 3 ส่วนหลักได้แก่ กลยุทธ์การลงทุน, วิธีการจัดการความเสี่ยง และหลักการบริหารเงิน


## 2. วัตถุประสงค์

สร้างโครงข่ายประสาทเทียมจากงานวิจัยต้นแบบ 4 ขั้นตอนวิธี และโครงข่ายประสาทเทียมที่นำเสนอ 3 ขั้นตอนวิธี ในการพยากรณ์อัตราแลกเปลี่ยนของคู่สกุลเงิน EUR/USD, USD/JPY, GBP/USD และ USD/THB โดยใช้อินพุตเป็นตัวบ่งชี้ทางเทคนิค (Technical Indicator) และวัดผลโครงข่ายประสาทเทียมด้วยระบบจำลองการซื้อขายที่มีกลยุทธ์การลงทุน, วิธีจัดการความเสี่ยง และหลักการบริหารเงิน


## 3. ทฤษฎีที่เกี่ยวข้อง

### 3.1 โครงข่ายประสาทเทียม (Artificial Neural Network)

โครงข่ายประสาทเทียม (Artificial Neural Network) เป็นการจำลองทางคณิตศาสตร์ที่เลียนแบบการทำงานของสมองมนุษย์ เซลล์ประสาท (neuron) ในสมองคนเราประกอบด้วยนิวเคลียส (nucleus) ตัวเซลล์ (cell body) โยประสาทนำเข้า (dendrite) แกนประสาทนำออก (axon) [25, 5] ดังแสดงในรูปภาพ 3.1



รูปภาพที่ 3.1 แสดงเซลล์ประสาทซึ่งประกอบด้วยใยประสาทนำเข้า, ตัวเซลล์ และ แกนประสาทนำออก เดนไดรท์ทำหน้าที่รับสัญญาณไฟฟ้าเคมีซึ่งส่งมาจากเซลล์ประสาทใกล้เคียง เซลล์ประสาทตัวหนึ่ง ๆ จะเชื่อมต่อกับเซลล์ตัวอื่น ๆ เมื่อสัญญาณไฟฟ้าเคมีที่รับเข้ามาเกินค่าค่าหนึ่ง เซลล์จะถูกกระตุ้นและส่งสัญญาณไปทางแกนประสาทนำออกไปยังเซลล์อื่น ๆ ต่อไป โครงข่ายประสาทเทียมมีหน่วยย่อยที่เล็กที่สุดเรียกว่าเพอร์เซปตรอน (Perceptron) เปรียบเสมือนกับเซลล์ประสาท 1 เซลล์ในสมอง ในการเลียนแบบการทำงานของสมองมนุษย์นักคณิตศาสตร์ได้สร้างโมเดลที่มีการเชื่อมต่อกันของเพอร์เซปตรอนหลาย ๆ ตัวขึ้นเรียกว่าโครงข่ายประสาทเทียม (Artificial Neural Network) ดังแสดงในรูปภาพที่ 3.2



รูปภาพที่ 3.2 แสดงตัวอย่างโครงข่ายประสาทเทียม

ปมแต่ละปมคือเพอร์เซปตรอนแต่ละตัวและเส้นเชื่อมคือค่าน้ำหนักที่สัมพันธ์กันของปม 2 ปม จำนวนชั้นของโครงข่ายประสาทเทียมสามารถมีได้มากกว่า 3 ชั้นนั่นหมายความว่าโครงข่ายประสาทเทียมสามารถมีชั้นซ่อน (Hidden Layer) ได้มากกว่า 1 ชั้น เพอร์เซปตรอนรับอินพุตเป็นเวกเตอร์จำนวนจริงแล้วคำนวณหาผลรวมเชิงเส้น (Linear Combination) แบบถ่วงน้ำหนักของอินพุต  $(x_1, x_2, \dots, x_n)$  โดยที่ค่า  $w_1, w_2, \dots, w_n$  เป็นค่าน้ำหนักของอินพุตและให้เอาต์พุต ( $o$ ) เป็นผลรวมเชิงเส้น ถ้าผลรวมที่ได้มีค่าเกินค่าขีดแบ่ง  $\theta$  และเป็น 0 ถ้าไม่เกิน  $b$  เป็นความลำเอียง (Bias) และ  $x_0$  เป็นอินพุตเทียมที่กำหนดให้มีค่าเป็น 1 เสมอ ในตัวอย่างนี้เราใช้ฟังก์ชันกระตุ้น (Activation Function) ชนิดที่เรียกว่า Rectified Linear Unit (ReLU) ค่าขีดแบ่ง  $\theta$  ในตัวอย่างนี้คือ 0 เราสามารถแสดงเอาต์พุต ( $o$ ) ในรูปของฟังก์ชันของอินพุต  $\vec{x}$  ได้ดังสมการที่ 3.1

$$o(\vec{x}) = \begin{cases} z & \text{if } z > 0 \\ 0 & \text{if } z \leq 0 \end{cases} \quad (3.1)$$

โดยที่  $z = bx_0 + w_1x_1 + \dots + w_nx_n$

มีความเป็นไปได้มากที่เอาต์พุตซึ่งได้จากโครงข่ายประสาทเทียมและเอาต์พุตจริงจะไม่เท่ากัน เราสามารถหาค่าความผิดพลาดที่เกิดขึ้นจากโครงข่ายประสาทเทียมได้จากฟังก์ชันค่าผิดพลาด (Cost Function)

เรานิยามฟังก์ชันค่าผิดพลาด (Cost Function)  $E(\vec{w})$  ดังสมการที่ 3.2

$$E(\vec{w}) = \frac{1}{2} \sum_{p \in P} (t_p - a_p)^2 \quad (3.2)$$

โดยที่  $P$  เป็นเซตของตัวอย่างสอน  $t_p$  เป็นเอาต์พุตเป้าหมายของตัวอย่าง  $p$  และ  $a_p$  เป็นเอาต์พุตของเพอร์เซปตรอนสำหรับตัวอย่าง  $p$  ฟังก์ชันค่าผิดพลาดการสอน  $E(\vec{w})$  เป็นฟังก์ชันของ  $\vec{w}$  ซึ่งจะมีค่า  $\vec{w}$  บางตัวที่ทำให้ฟังก์ชันความผิดพลาดมีค่าต่ำสุดระดับท้องถิ่นหรือต่ำสุดระดับสากล ในที่นี้เราจะอธิบายวิธีปรับค่า  $\vec{w}$  เพื่อให้ได้ความผิดพลาดที่น้อยที่สุด 2 วิธี ได้แก่ ขั้นตอนการส่งค่าย้อนกลับ (Backpropagation Algorithm) และ ขั้นตอนของเลเวนเบิร์ก-มาร์ควาร์ด (Levenberg-Marquardt Algorithm)

### 3.2 ขั้นตอนการส่งค่าย้อนกลับ (Backpropagation Algorithm)

ขั้นตอนการส่งค่าย้อนกลับ (Backpropagation Algorithm) เป็นขั้นตอนวิธีที่ถูกใช้ในโครงข่ายประสาทเทียมเพื่อคำนวณความชันของกราฟความผิดพลาดและค่าน้ำหนัก ซึ่งความชันนี้จำเป็นสำหรับการปรับค่าน้ำหนักของโครงข่ายประสาทเทียมในหลักการการเคลื่อนลงตามความชัน (Gradient Descent) [6] ซึ่งสามารถอธิบายได้ดังสมการที่ 3.3

$$\vec{w}_{k+1} = \vec{w}_k - \eta \nabla E(\vec{w}_k) \quad (3.3)$$

โดยที่


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

$\vec{w}_k$  เป็นเวกเตอร์ค่าน้ำหนักในรอบที่  $k$

$\eta$  เป็นอัตราการเรียนรู้

ตัวอย่าง

พิจารณาเครือข่ายประสาทเทียมดังแสดงในรูปภาพที่ 3.3



รูปภาพที่ 3.3 แสดงตัวอย่างโครงข่ายประสาทเทียมที่มีการเปลี่ยนค่าน้ำหนักที่ส่งจากปมที่ 1 ไปปมที่ 4

การเปลี่ยนแปลงค่าน้ำหนักที่ส่งจากปมที่ 1 ไปปมที่ 4 ( $w_{14}$ ) ทำให้ฟังก์ชันค่าผิดพลาดมีการเปลี่ยนแปลง และเราสามารถหาอัตรา

การเปลี่ยนแปลงของฟังก์ชันค่าผิดพลาด 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

$$z_4 = b_4 + w_{14}a_1 + w_{24}a_2 + w_{34}a_3$$

$$a_4 = \sigma(z_4)$$

$$z_7 = b_7 + w_{47}a_4 + w_{57}a_5 + w_{67}a_6$$

$$a_7 = \sigma(z_7)$$

$$z_8 = b_8 + w_{48}a_4 + w_{58}a_5 + w_{68}a_6$$

$$a_8 = \sigma(z_8)$$

สามารถเขียนเป็นสมการโดยใช้กฎลูกโซ่ (Chain Rule) ได้ดังนี้

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

### 3.3 ขั้นตอนวิธีเลเวนเบิร์ก-มาร์ควาร์ดต์ (Levenberg-Marquardt Algorithm)

ขั้นตอนวิธีเลเวนเบิร์ก-มาร์ควาร์ดต์ (Levenberg-Marquardt Algorithm) เป็นอีกขั้นตอนวิธีที่ใช้ในการปรับค่าน้ำหนักของโครงข่ายประสาทเทียม ซึ่งวิธีการนี้ผสมผสานข้อดีด้านความเร็วในการปรับค่าน้ำหนักของขั้นตอนวิธีเกาส์-นิวตัน (Gauss-Newton Algorithm) และความมีเสถียรภาพของขั้นตอนวิธีการส่งค่าย้อนกลับ (Backpropagation Algorithm)

เพื่อความสะดวกในการอธิบายการปรับค่าน้ำหนักโดยขั้นตอนวิธีเลเวนเบิร์ก-มาร์ควาร์ดต์ ขอนิยามฟังก์ชันค่าผิดพลาดใหม่ (Cost Function)  $E(\vec{w})$  ดังสมการที่ 3.4

$$E(\vec{w}) = \frac{1}{2} \sum_{p=1}^P \sum_{m=1}^M e_{p,m}^2 \quad (3.4)$$

โดยที่

$p$  เป็นดัชนีของตัวอย่างมีค่าตั้งแต่ 1 ถึง  $P$

$m$  เป็นดัชนีของเอาต์พุตมีค่าตั้งแต่ 1 ถึง  $M$

$e_{p,m}$  เป็นผลต่างของเอาต์พุตเป้าหมายและเอาต์พุตของโครงข่ายประสาทเทียมที่  $m$  ในตัวอย่างที่  $p$  ซึ่งสามารถนิยามได้ดังสมการที่ 3.5

$$e_{p,m} = t_{p,m} - a_{p,m} \quad (3.5)$$

โดยที่

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

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

การปรับค่าน้ำหนักของขั้นตอนเลเวนเบิร์ก-มาร์ควาร์ด (Levenberg-Marquardt Algorithm) อธิบายดังสมการที่ 3.6

$$\vec{w}_{k+1} = \vec{w}_k - (J_k^T + J_k + \lambda I)^{-1} J_k \vec{e}_k \quad (3.6)$$

โดยที่

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

$\vec{w}_k$  เป็นเวกเตอร์ค่าน้ำหนักในรอบที่  $k$

$J_k$  เป็นจาโคเบียนเมทริกซ์ในรอบที่  $k$

$\vec{e}_k$  เป็นเวกเตอร์ผลต่างระหว่างเอาต์พุตเป้าหมายและเอาต์พุตของโครงข่ายประสาทเทียมในรอบที่  $k$

เรานิยามจาโคเบียนเมทริกซ์  $J$  ได้ดังสมการที่ 3.7

$$J = \begin{bmatrix} \frac{\partial e_{1,1}}{\partial w_1} & \frac{\partial e_{1,1}}{\partial w_2} & \cdots & \frac{\partial e_{1,1}}{\partial w_N} \\ \frac{\partial e_{1,2}}{\partial w_1} & \frac{\partial e_{1,2}}{\partial w_2} & \cdots & \frac{\partial e_{1,2}}{\partial w_N} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_{1,M}}{\partial w_1} & \frac{\partial e_{1,M}}{\partial w_2} & \cdots & \frac{\partial e_{1,M}}{\partial w_N} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_{p,1}}{\partial w_1} & \frac{\partial e_{p,1}}{\partial w_2} & \cdots & \frac{\partial e_{p,1}}{\partial w_N} \\ \frac{\partial e_{p,2}}{\partial w_1} & \frac{\partial e_{p,2}}{\partial w_2} & \cdots & \frac{\partial e_{p,2}}{\partial w_N} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_{p,M}}{\partial w_1} & \frac{\partial e_{p,M}}{\partial w_2} & \cdots & \frac{\partial e_{p,M}}{\partial w_N} \end{bmatrix} \quad (3.7)$$

โดยที่  $N$  เป็นจำนวนค่าน้ำหนักทั้งหมดในโครงข่ายประสาทเทียม

และนิยามเวกเตอร์ผลต่างระหว่างเอาต์พุตเป้าหมายและเอาต์พุตของโครงข่ายประสาทเทียม  $\vec{e}$  ได้ดังสมการที่ 3.8



$$e = \begin{bmatrix} e_{1,1} \\ e_{1,2} \\ \vdots \\ e_{1,M} \\ \vdots \\ e_{P,1} \\ e_{P,2} \\ \vdots \\ e_{P,M} \end{bmatrix} \quad (3.8)$$

### 3.4 โครงข่ายประสาทเทียมอย่างถูกต้องของเบส์ (Bayesian Regularized Artificial Neural Network)

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

ใน โครงข่ายประสาทเทียมอย่างถูกต้องของเบส์ (Bayesian Regularized Artificial Neural Network) มีการกำหนดฟังก์ชันค่าผิดพลาดใหม่ดังสมการที่ 3.9

$$F(\vec{w}) = \beta E_D(\vec{w}) + \alpha E_W(\vec{w}) \quad (3.9)$$

โดยที่

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

$$E_W(\vec{w}) = \sum_{n=1}^N w_n^2$$

$\beta$  และ  $\alpha$  คือสัมประสิทธิ์ที่เราต้องการหาเพื่อทำให้โครงข่ายประสาทเทียมมีความถูกต้องมากที่สุด

เราสามารถหา  $\alpha$  และ  $\beta$  ด้วย 5 ขั้นตอนต่อไปนี้

- 1) กำหนดค่าเริ่มต้นของ  $\alpha$ ,  $\beta$  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  $\alpha$  และ  $\beta$  สำหรับฟังก์ชันค่าผิดพลาดใหม่  $\alpha = \frac{\gamma}{2E_W(\vec{w})}$  และ  $\beta = \frac{n - \gamma}{2E_D(\vec{w})}$
- 5) ทำซ้ำขั้นตอนที่ 2 ถึง 4 จนกว่า  $\alpha$  และ  $\beta$  ลู่เข้า

### 3.5 การแยกส่วนประกอบของรูปแบบเชิงประจักษ์ (Empirical mode decomposition) (EMD)

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

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

เราสามารถอธิบายวิธีการสกัดความผันผวนด้วย 6 ขั้นตอนต่อไปนี้

- 1) หาจุดสูงสุดระดับท้องถิ่นและจุดต่ำสุดระดับท้องถิ่นทั้งหมดของอนุกรมเวลา  $X(t)$
- 2) เชื่อมจุดสูงสุดระดับท้องถิ่นด้วยคิวบิกสไปไลน์ (Cubic Spline) เพื่อกำหนดกรอบบน (Upper Envelope)  $U(t)$  เชื่อมจุดต่ำสุดระดับท้องถิ่นด้วยคิวบิกสไปไลน์ (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) บรรยายได้ดังสมการที่ 3.10

$$R_M(t) = X(t) - \sum_{i=1}^M C_i(t), \quad R_i(t) = R_{i-1}(t) - C_i(t) \quad (3.10)$$

### 3.6 โครงข่ายประสาทเทียมแบบความแรงของเวลาอย่างสุ่ม (Stochastic Time Strength Neural Network) (STNN)

โครงข่ายประสาทเทียมแบบความแรงของเวลาอย่างสุ่ม (Stochastic Time Strength Neural Network) (STNN) เป็นโครงข่ายประสาทเทียมที่มีการพิจารณาค่าน้ำหนักของแต่ละจุดข้อมูลที่เพิ่มขึ้นในอนุกรมเวลา โดยมีการกำหนดฟังก์ชันค่าผิดพลาดใหม่ดังสมการที่ 3.11

$$E(t_n) = \frac{1}{N} \sum_{n=1}^N \rho(t_n)(d_{t_n} - y_{t_n})^2 \quad (3.11)$$

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  $t_n$  ซึ่งนิยามดังสมการที่

3.12

$$\rho(t_n) = \frac{1}{\beta} \exp \left\{ \int_{t_0}^{t_n} \mu(t) dt + \int_{t_0}^{t_n} \sigma(t) dB(t) \right\} \quad (3.12)$$

โดยที่

$\beta (> 0)$  เป็น สัมประสิทธิ์ความแรงของเวลา (Time Strength Coefficient)

$\mu(t)$  เป็น ฟังก์ชันแนวโน้ม (Drift Function)

$\sigma(t)$  เป็น ฟังก์ชันความผันผวน (Volatility Function)

$B(t)$  เป็น การเคลื่อนที่แบบไรต์สทาง (Standard Brownian Motion)

ซึ่งนิยาม  $\mu(t)$  และ  $\sigma(t)$  ได้สมการที่ 3.13 และ 3.14 ตามลำดับ

$$\mu(t) = \frac{1}{(c-t)^2} \quad (3.13)$$

$$\sigma(t) = \left[ \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2 \right]^{\frac{1}{2}} \quad (3.14)$$

โดยที่

$c$  เป็นตัวแปรซึ่งมีขนาดเท่ากับจำนวนของตัวอย่างที่ใช้สอน

$t$  เป็นเวลา

$\bar{x}$  เป็นค่าเฉลี่ยของตัวอย่างข้อมูลอินพุต

$x_i$  เป็นอินพุตเวกเตอร์ตัวที่  $i$

สำหรับการปรับค่าน้ำหนักสามารถทำได้โดยใช้ขั้นตอนการส่งค่าย้อนกลับ (Backpropagation Algorithm)

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

ขั้นตอนผสมผสานระหว่างการแยกส่วนประกอบของรูปแบบเชิงประจักษ์และขั้นตอนโครงข่ายประสาทเทียมแบบความแรงของเวลาอย่างสุ่ม (Empirical Mode Decomposition Stochastic Time Strength Neural Network) (EMD-STNN) เป็นกระบวนการที่ผสมผสานระหว่างการแยกส่วนประกอบของรูปแบบเชิงประจักษ์ (EMD) และโครงข่ายประสาทเทียมแบบความแรงของเวลาอย่างสุ่ม (STNN) โดยที่ EMD ทำหน้าที่สกัดข้อมูลของอนุกรมเวลาหลัก  $X(t)$  ออกเป็นฟังก์ชันรูปแบบที่แท้จริง (Intrinsic Mode Function) (IMF) หลายชุด และส่วนเหลือ (Residual) หลังจากนั้นใช้ IMF และ Residual เหล่านี้เป็นอินพุตให้

กับ STNN ในการพยากรณ์ ซึ่งจะได้ผลลัพธ์การพยากรณ์เป็นจำนวนชุดเท่ากับจำนวนชุดของ IMF และ Residual ที่ได้จาก EMD ในขั้นตอนสุดท้ายทำการรวมผลลัพธ์การพยากรณ์ทุกชุดให้เป็นชุดเดียวโดยใช้สมการที่ 3.15

$$\tilde{X}(t) = \sum_{i=1}^M \tilde{C}_i(t) \rho_i + \tilde{R}_M(t) \rho_{M+1}, \quad t = 1, \dots, N \quad (3.15)$$

โดยที่

$\tilde{X}(t)$  เป็นผลลัพธ์การพยากรณ์สุดท้ายของอนุกรมเวลาหลัก

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

$\rho_i$  เป็นสัมประสิทธิ์การรวมของผลลัพธ์การพยากรณ์สำหรับ IMF แต่ละชุด

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

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

3.8 ขั้นตอนผสมผสานระหว่างข้อมูลแบบสุ่มเชิงเวลาที่มีประสิทธิภาพกับโครงข่ายประสาทเทียมแบบเรเดียลเบซิสฟังก์ชัน (Random Data-time Effective Radial Basis Function Neural Network) (RBFRT) เป็นโครงข่ายประสาทเทียมที่มีฟังก์ชันกระตุ้น (Activation Function) ในชั้นซ่อน (Hidden Layer) เป็นเรเดียลเบซิสฟังก์ชัน (Radial Basis Function) ซึ่งสามารถคำนวณเอาต์พุตของโครงข่ายประสาทเทียมได้ด้วยสมการที่ 3.16

$$f(x) = w_0 + \sum_{i=1}^h w_i \phi(||x - c_i||) \quad (3.16)$$

โดยที่

$x$  เป็นอินพุตเวกเตอร์

$h$  เป็นจำนวนของนิวรอนในชั้นซ่อน

$c_i$  เป็นเวกเตอร์ศูนย์กลางของปมที่  $i$  ในชั้นซ่อน

$\phi$  เป็นเรเดียลเบซิสฟังก์ชัน (Radial Basis Function) ซึ่งนิยามได้ดังสมการที่ 3.17

$$\phi(||x - c_i||) = \exp \left\{ -||x - c_i||^2 / 2\beta_i^2 \right\} \quad (3.17)$$

โดยที่

$\beta_i$  เป็นความกว้างของศูนย์กลางตัวที่  $i$

ในขั้นเริ่มแรกเราสุ่มค่าให้กับค่าน้ำหนัก, เวกเตอร์ศูนย์กลาง และความกว้างของศูนย์กลาง หลังจากนั้นเราทำการปรับค่าเหล่านี้โดยใช้ขั้นตอนวิธีการส่งค่าย้อนกลับ (Backpropagation Algorithm) ซึ่งสามารถหาอัตราการเปลี่ยนแปลงของค่าน้ำหนัก, เวกเตอร์ศูนย์กลาง และความกว้างของศูนย์กลางได้ด้วยสมการที่ 3.18, 3.19 และ 3.20 ตามลำดับ

$$\Delta w_i = -\eta_1 \frac{\partial E(\vec{w})}{\partial w_i} = n_1 e_{t_n} \rho(t_n) \phi(||x - c_i||) \quad (3.18)$$

$$\Delta c_i = -\eta_2 \frac{\partial E(\vec{w})}{\partial c_i} = n_2 e_{t_n} w_i \rho(t_n) \frac{\phi(||x - c_i||)}{\beta_i^2} (x - c_i) \quad (3.19)$$

$$\Delta \beta_i = -\eta_3 \frac{\partial E(\vec{w})}{\partial \beta_i} = n_3 e_{t_n} w_i \rho(t_n) \frac{\phi(||x - c_i||)}{\beta_i^3} ||x - c_i|| \quad (3.20)$$

โดยที่

$\eta_1, \eta_2, \eta_3$  เป็นอัตราการเรียนรู้

$E(\vec{w})$  เป็นฟังก์ชันค่าผิดพลาด ซึ่งนิยามดังสมการที่ 2.11

$w_i$  เป็นค่าน้ำหนักตัวที่  $i$

$c_i$  เป็นเวกเตอร์ศูนย์กลางของปมที่  $i$  ในชั้นซ่อน

$\beta_i$  เป็นความกว้างของศูนย์กลางตัวที่  $i$

$t_n$  เป็นเวลาของตัวอย่าง  $n$

$\epsilon_{t_n}$  เป็นค่าผิดพลาดที่เอาต์พุตที่เวลา  $t_n$

$\rho(t_n)$  เป็นฟังก์ชันข้อมูลแบบสุ่มเชิงเวลาที่มีประสิทธิภาพ (Random Data-time Effective Function) ที่เวลา  $t_n$

ซึ่งนิยาม  $\epsilon_{t_n}$  และ  $\rho(t_n)$  ได้สมการที่ 3.21 และ 3.22 ตามลำดับ

$$\epsilon_{t_n} = d_{t_n} - y_{t_n} \quad (3.21)$$

$$\rho(t_n) = \frac{1}{\beta} \exp \left\{ \int_{t_0}^{t_n} \mu(t) dt + \int_{t_0}^{t_n} \sigma(t) dB(t) \right\} \quad (3.22)$$

โดยที่

$\beta (> 0)$  เป็น สัมประสิทธิ์ความแรงของเวลา (Time Strength Coefficient)

$\mu(t)$  เป็น ฟังก์ชันแนวโน้ม (Drift Function)

$\sigma(t)$  เป็น ฟังก์ชันความผันผวน (Volatility Function)

$B(t)$  เป็น การเคลื่อนที่แบบไรต์สทาง (Standard Brownian Motion)

ซึ่งนิยาม  $\mu(t)$  และ  $\sigma(t)$  ได้สมการที่ 3.23 และ 3.14 ตามลำดับ

$$\mu(t) = \frac{1}{(t + a)^2} \quad (3.23)$$

โดยที่

$a$  เป็นตัวแปรซึ่งมีขนาดเท่ากับจำนวนของตัวอย่างที่ใช้สอน

$t$  เป็นเวลา

เราสามารถปรับค่าน้ำหนัก, เวกเตอร์ศูนย์กลาง และความกว้างของศูนย์กลาง ในแต่ละรอบของการสอนได้โดยใช้สมการที่ 3.24, 3.25 และ 3.26 ตามลำดับ

$$w_i(l + 1) = w_i(l) + \Delta w_i = w_i(l) + \eta_1 \epsilon_{t_n} \rho(t_n) \phi_i \quad (3.24)$$

$$c_i(l + 1) = c_i(l) + \Delta c_i = c_i(l) + \eta_2 \epsilon_{t_n} w_i \rho(t_n) \frac{\phi_i}{\beta_i^2} (x - c_i) \quad (3.25)$$

$$\beta_i(l + 1) = \beta_i(l) + \Delta \beta_i = \beta_i(l) + \eta_3 \epsilon_{t_n} w_i \rho(t_n) \frac{\phi_i}{\beta_i^3} ||x - c_i|| \quad (3.26)$$

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  $l$

#### 4. งานวิจัยที่เกี่ยวข้อง

การพยากรณ์อัตราแลกเปลี่ยนเป็นสิ่งที่ทำให้นักวิจัยทั่วโลกเนื่องจากผลประโยชน์ที่น่าสนใจในการลงทุน [3] งานวิจัยที่พยายามพยากรณ์อนุกรมเวลาทางการเงินสามารถแบ่งได้เป็น 2 กลุ่มหลัก ๆ คือกลุ่มที่ใช้วิธีทางสถิติและกลุ่มที่ใช้วิธีทางการเรียนรู้ของเครื่อง (Machine Learning) [11, 18] กลุ่มแรกใช้วิธีทางสถิติดั้งเดิมซึ่งมีสมมติฐานว่าอนุกรมเวลาที่ทำการศึกษาถูกสร้างขึ้นมาจากขั้นตอนเชิงเส้น [12, 18] และพยายามจำลองกฎที่สร้างอนุกรมเวลาเพื่อพยากรณ์ราคาในอนาคตของอนุกรม อย่างไรก็ตามอนุกรมเวลาทางการเงินมีความซับซ้อนสูง, เต็มไปด้วยสัญญาณรบกวน, มีการเปลี่ยนแปลงอยู่เสมอ, ไม่เชิงเส้น และไม่เป็นระเบียบโดยธรรมชาติ [13, 18] กลุ่มที่สองใช้วิธีการเรียนรู้ของเครื่อง (Machine Learning) [14, 18] กล่าวว่าการประยุกต์ใช้วิธีการเรียนรู้ของเครื่องประสบความสำเร็จในการจำลองและพยากรณ์อนุกรมเวลาทางการเงิน เทคนิคการเรียนรู้ของเครื่องหลายเทคนิคสามารถที่จะจับความสัมพันธ์แบบไม่เชิงเส้นระหว่างปัจจัยที่สำคัญที่ไม่จำเป็นต้องมีความรู้เกี่ยวกับข้อมูลอินพุตมาก่อน [15, 18] ท่ามกลางเทคนิคเหล่านี้ โครงข่ายประสาทเทียม (Artificial Neural Network) ถูกใช้งานอย่างกว้างขวางที่สุดในการพยากรณ์อนุกรมเวลา เนื่องจากโครงข่ายประสาทเทียมเป็นวิธีการที่ขับเคลื่อนด้วยข้อมูล (Data-driven) และปรับตัวด้วยตัวเอง (Self-adaptive) ซึ่งสามารถจับพฤติกรรมไม่เชิงเส้นของอนุกรมเวลาโดยไม่ต้องมีสมมติฐานทางสถิติเกี่ยวกับข้อมูล [16, 17, 18] จากข้อดีที่ได้กล่าวมาทำให้โครงข่ายประสาทเทียมหลายชนิดและขั้นตอนผสมผสานระหว่างโครงข่ายประสาทเทียมถูกนำมาใช้ในการพยากรณ์อนุกรมเวลาทางการเงิน [15, 18]

งานวิจัยที่เกี่ยวข้องสามารถแบ่งได้ออกเป็น 3 กลุ่มได้แก่ งานวิจัยด้านการวิเคราะห์ทางเทคนิค, งานวิจัยด้านการวิเคราะห์ปัจจัยพื้นฐาน และงานวิจัยด้านกลยุทธ์การลงทุน

##### 4.1 งานวิจัยต้นแบบ

[1] นำเสนอการใช้โครงข่ายประสาทเทียมในการพยากรณ์ราคาสูงสุดและราคาต่ำสุดของวันปัจจุบันบนข้อมูลหุ้นของสองบริษัทตัวหลักของตลาดหลักทรัพย์บราซิล (BM&F BOVESPA) โดยใช้อินพุตที่แตกต่างกันสามชุด ผู้เขียนได้นำเสนอระบบจำลองการซื้อขายรายวันเพื่อเปลี่ยนเอาต์พุตของโครงข่ายประสาทเทียมไปสู่การตัดสินใจทางการลงทุนซึ่งชี้ให้เห็นการลงทุนเห็นช่วงเวลาที่ดีที่สุดในการซื้อขายและทำกำไร ผู้เขียนวัดประสิทธิภาพของโครงข่ายประสาทเทียมสองวิธีได้แก่การใช้ ค่าเฉลี่ยของร้อยละความผิดพลาดสัมบูรณ์ (Mean Absolute Percentage Error) (MAPE) และวัดผลตอบแทนต่อปี (Annualized Return) โครงข่ายประสาทเทียมถูกนำมาเปรียบเทียบกับประสิทธิภาพกับ 4 เกณฑ์มาตรฐาน ผลลัพธ์แสดงให้เห็นว่าโครงข่ายประสาทเทียมให้ค่าเฉลี่ย

ของร้อยละความผิดพลาดสมมุติฐานน้อยกว่าของเกณฑ์มาตรฐาน 50% และให้ผลตอนแทนต่อปีสองเท่าของเงินลงทุน [2] นำเสนอ  
โครงข่ายประสาทเทียมอย่างถูกต้องของเบส์ (Bayesian Regularized Artificial Neural Network) ในการพยากรณ์ราคาปิดของ  
หนึ่งวันในอนาคตบนข้อมูลหุ้นของบริษัทไมโครซอฟท์ (Microsoft Corp) และบริษัทกลุ่มโกลแมนแซชส์ (Golman Sachs Group)  
โดยราคาตลาด (Market Price) และตัวชี้วัดทางเทคนิค (Technical Indicator) ถูกใช้เป็นอินพุตให้กับโครงข่ายประสาทเทียม  
โครงข่ายประสาทเทียมอย่างถูกต้องของเบส์ช่วยลดปัญหาความพอดีที่มากเกินไปของข้อมูลที่ใช้สอน (Overfitting) และการเรียนที่  
มากเกินไป (Overtraining) โดยการกำหนดกฎความน่าจะเป็นให้กับค่าน้ำหนักของโครงข่าย ซึ่งกำจัดความซับซ้อนส่วนเกินของ  
โครงข่ายอย่างอัตโนมัติ ช่วยเพิ่มประสิทธิภาพการพยากรณ์และความทั่วไปของโครงข่าย [3] นำเสนอขั้นตอนผสมผสานระหว่าง  
การแยกส่วนประกอบของรูปแบบเชิงประจักษ์กับโครงข่ายประสาทเทียมแบบความแรงของเวลาอย่างสุ่ม (Empirical Mode  
Decomposition Stochastic Time Strength Neural Network) (EMD-STNN) เพื่อพยากรณ์ราคาปิดของหนึ่งวันในอนาคต  
ของ NYSE, DAX, FTSE และ HSI การแยกส่วนประกอบของรูปแบบเชิงประจักษ์ (Empirical Mode Decomposition) (EMD)  
เป็นขั้นตอนในการแยกส่วนประกอบของรูปแบบที่ฝังอยู่ในอนุกรม โครงข่ายประสาทเทียมแบบความแรงของเวลาอย่างสุ่ม  
(Stochastic Time Strength Neural Network) เป็นโครงข่ายประสาทเทียมที่มีการพิจารณาค่าน้ำหนักของแต่ละจุดข้อมูลที่เกิน  
ขึ้นในอนุกรมเวลาของฟังก์ชันค่าผิดพลาด หลักการทำงานของ (EMD-STNN) ประกอบด้วยสามขั้นตอน ในขั้นตอนแรกคือการใช้  
EMD ในการแยกรูปแบบที่ฝังอยู่ในอนุกรมออกมาเป็นชุด ๆ หลังจากนั้นใช้ STNN พยากรณ์ราคาปิดของอนุกรมย่อยแต่ละชุด ขั้น  
ตอนสุดท้ายคือการนำผลลัพธ์การพยากรณ์ของอนุกรมย่อยแต่ละชุดมารวมกันเพื่อให้ได้ผลลัพธ์การพยากรณ์สุดท้าย ประสิทธิภาพ  
ของ EMD-STNN ดีกว่าแบบจำลองแบบดั้งเดิมเช่น โครงข่ายประสาทเทียมแบบส่งค่าย้อนกลับ (BPNN), โครงข่ายประสาทเทียม  
แบบความแรงของเวลาอย่างสุ่ม (STNN) และซัพพอร์ตเวกเตอร์แมชชีน (SVM) อย่างชัดเจน และค่าสัมประสิทธิ์ความสัมพันธ์ (R)  
ระหว่างเอาต์พุตเป้าหมายและเอาต์พุตที่ได้จากแบบจำลอง มากกว่า 0.99 [4] นำเสนอขั้นตอนผสมผสานระหว่างข้อมูลแบบสุ่มเชิง  
เวลาที่มีประสิทธิภาพกับโครงข่ายประสาทเทียมแบบเรเดียลเบซิสฟังก์ชัน (Random Data-Time Effective Radial Basis  
Function Neural Network) (RBFRT) ในการพยากรณ์ราคาปิดของหนึ่งวันในอนาคตของน้ำมันดิบ (Crude Oil), SSE, N225  
และ DAX ซึ่ง RBFRT ใช้โครงข่ายประสาทเทียมแบบเรเดียลเบซิสฟังก์ชัน (Radial Basis Function Neural Network) ในการ  
สร้างแบบจำลอง โดยฟังก์ชันค่าผิดพลาดที่ใช้มีการให้ค่าน้ำหนักกับแต่ละจุดเวลาที่เกิดขึ้นในอนุกรมเวลา ผลลัพธ์การทดลองแสดง  
ให้เห็นว่าประสิทธิภาพของ RBFRT ดีกว่าโครงข่ายประสาทเทียมแบบเรเดียลเบซิสฟังก์ชันที่ไม่มีการให้ค่าน้ำหนักกับแต่ละจุดเวลา  
ในฟังก์ชันค่าผิดพลาด และค่าสัมประสิทธิ์ความสัมพันธ์ (R) ระหว่างเอาต์พุตเป้าหมายและเอาต์พุตที่ได้จากแบบจำลอง มากกว่า  
0.99

#### 4.2 งานวิจัยด้านการวิเคราะห์ทางเทคนิค

งานวิจัยด้านการวิเคราะห์ทางเทคนิคผู้จัดทำได้ให้ความสำคัญกับโครงข่ายประสาทเทียม เพราะในช่วง 10 ปีที่ผ่านมา  
โครงข่ายประสาทเทียมมีชื่อเสียงเป็นอย่างมากในการพยากรณ์ตลาดทางการเงิน [18] [19] ได้นำเสนอหลักฐานว่าโครงข่าย  
ประสาทเทียมมีความสามารถในการพยากรณ์อัตราแลกเปลี่ยนคู่สกุลเงินได้ ข้อมูลอนุกรมเวลาและตัวบ่งชี้ทางเทคนิค (Technical  
Indicator) เช่น ค่าเฉลี่ยเคลื่อนที่ (Moving Average) ถูกใช้เป็นอินพุตให้กับโครงข่ายประสาทเทียมเพื่อจับกฎการเคลื่อนที่ของ  
อัตราแลกเปลี่ยน อัตราแลกเปลี่ยนคู่สกุลเงิน AUD/USD, CHF/USD, DEM/USD, GBP/USD และ JPY/USD ถูกพยากรณ์โดย

โครงข่ายประสาทเทียมที่ผ่านการเรียนแล้ว การวิเคราะห์ช่วงของการปรับขนาดแบบดั้งเดิม (Traditional Rescaled Range Analysis) ถูกนำมาทดสอบประสิทธิภาพของแต่ละคู่อัตราแลกเปลี่ยนก่อนที่จะนำข้อมูลย้อนหลังมาสอนโครงข่ายประสาทเทียม ผลลัพธ์แสดงให้เห็นว่าโดยปราศจากการใช้ข้อมูลอื่น ๆ ของตลาด โครงข่ายประสาทเทียมก็สามารถให้การพยากรณ์ที่เป็นประโยชน์ได้และสามารถที่จะทำกำไรได้บนข้อมูลที่นอกเหนือจากกลุ่มตัวอย่างด้วยตัวบ่งชี้ทางเทคนิคพื้นฐาน [20] 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) ผลลัพธ์ของการประยุกต์ใช้งานชี้ให้เห็นว่าโครงข่ายประสาทเทียมที่ได้มีประสิทธิภาพในการทำให้เป็นทั่วไปอย่างดีเยี่ยม [21] นำเสนอฟังก์ชันประสิทธิภาพของเวลาอย่างสุ่มใหม่ (New Stochastic Time Effective Function) เพื่อจำลองโครงข่ายประสาทเทียมแบบประสิทธิภาพของเวลาอย่างสุ่ม (Stochastic Time Effective Neural Network) ความมีประสิทธิภาพของแบบจำลองได้ถูกวิเคราะห์ด้วยการทดลองบนข้อมูลดัชนีตลาด HSI, DJI และ IXIC และ SP500 และความถูกต้องของตัวแปรความแปรปรวนของการเคลื่อนที่แบบไร้ทิศทาง (Brownian Motion) ได้ถูกทดสอบ นอกจากนี้ยังได้แสดงผลการพยากรณ์โดยใช้โครงข่ายประสาทเทียมแบบประสิทธิภาพของเวลาอย่างสุ่ม (Stochastic Time Effective Neural Network) [22] 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 วัดประสิทธิภาพของแบบจำลองด้วยค่าเฉลี่ยของร้อยละความผิดพลาดสัมบูรณ์ (Mean Absolute Percentage Error) (MAPE) และวิธีการถดถอยเชิงเส้น ผลลัพธ์ที่ออกมาแสดงให้เห็นว่าขั้นตอนวิธีนี้ให้ความแม่นยำที่มากขึ้นในการพยากรณ์ [23] 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 [24] นำเสนอขั้นตอนผสมผสานการแปลงเวฟเล็ตแบบไม่ต่อเนื่อง (Discrete Wavelet Transform) กับระหว่างโครงข่ายประสาทเทียมแบบส่งค่าย้อนกลับ (Backpropagation Neural Network) เพื่อพยากรณ์ราคาปิดของหุ้นในตลาดหลักทรัพย์อินเดีย ขั้นตอนวิธีนี้ในขั้นแรกใช้การแปลงเวฟเล็ตแบบไม่ต่อเนื่อง (Discrete Wavelet Transform) เพื่อสกัด



ข้อมูลย้อนหลัง ต่อจากนั้นใช้สัมประสิทธิ์การประมาณ (Approximation Coefficient) และสัมประสิทธิ์ส่วนย่อย (Detail Coefficient) เป็นอินพุตให้กับโครงข่ายประสาทเทียมแบบส่งค่าย้อนกลับ (Backpropagation Neural Network) เพื่อพยากรณ์ราคาของหุ้นในอนาคต ผลลัพธ์การจำลองแสดงให้เห็นว่าการใช้ขั้นตอนวิธีที่นำเสนอให้ผลลัพธ์ที่แม่นยำมากกว่าเมื่อเปรียบเทียบกับโครงข่ายประสาทเทียมที่ใช้อินพุตเป็นข้อมูลที่ไม่ผ่านการแปลงเวฟเล็ตแบบไม่ต่อเนื่อง

#### 4.3 งานวิจัยด้านการวิเคราะห์ปัจจัยพื้นฐาน

[34] ได้นำเสนอส่วนประกอบของระบบการพยากรณ์และทำการเปรียบเทียบขั้นตอนในการเลือกคุณลักษณะของข่าว, ขั้นตอนในการให้ค่าน้ำหนักคุณลักษณะของข่าว, คุณลักษณะทั้งหมดที่ใช้, แหล่งข่าว, การเลือกช่วงเวลาที่ได้รับผลกระทบจากข่าวที่ออก, รูปแบบในการแบ่งกลุ่มเป้าหมาย, จำนวนกลุ่มคุณลักษณะเป้าหมาย และขั้นตอนวิธีที่ใช้แบ่งกลุ่มของคุณลักษณะเป้าหมายของแต่ละงานวิจัย [36] ทำการวัดสภาพอารมณ์ของข่าวและน้ำเสียงของผู้เขียนข่าว เพื่อตอบคำถามในงานวิจัยสองข้อคือ ข่าวการคาดการณ์/ข่าวที่รายงานผลตามจริง มีผลกระทบต่อการพยากรณ์ราคาไหม และ น้ำเสียงของผู้เขียนในเชิงบวก/เชิงลบ มีผลต่อการพยากรณ์ราคาไหม เพื่อตอบคำถามสองข้อนี้ ผู้เขียนได้ทำการทดลองสามชุด 1) ใช้เอาต์พุตที่ได้จากวิธีการคำนวณที่เหมาะสม (Proper nouns) และราคาของหุ้นขณะที่ข่าวออกเป็นอินพุตให้กับซัพพอร์ตเวกเตอร์รีเกรสชัน (Support Vector Regression) ในการพยากรณ์ราคาของหุ้นหลังจากที่ข่าวออกเป็นเวลา 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 [37] ซึ่งค้นพบว่าในช่วงเวลาอยู่ 20 นาทีก่อนข่าวออกและหลังข่าวออกในการเปลี่ยนแปลงราคาของหุ้น การเปลี่ยนแปลงราคาก่อนข่าวออก 20 นาทีถูกเชื่อว่าเป็นผลลัพธ์มาจากนักลงทุนที่รู้ข่าวข้อมูลของข่าวก่อนที่จะมีการประกาศข่าว และการเปลี่ยนแปลงราคาหลังข่าวออก 20 นาทีเป็นผลลัพธ์จากการที่นักลงทุนได้รับข่าวไม่พร้อมกัน ทำให้ตัดสินใจในการลงทุนไม่พร้อมกัน [38] 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) และตัวเรียนรู้ของเบส์อย่างง่าย (Naive Bayes) ผลลัพธ์จากการทดลองแสดงให้เห็นว่า Support Vector Machine ให้ผลลัพธ์การพยากรณ์ที่ดีที่สุด [40] นำเสนอวิธีการพยากรณ์ทิศทางการเคลื่อนไหวระหว่างวันของตลาดอัตรแลกเปลี่ยน ผู้เขียนนำเสนอ 3 ขั้นตอนการวิเคราะห์ข้อความ (Text Mining) 1) การวิเคราะห์ทางภาษาศาสตร์ 2) วิเคราะห์อารมณ์ของข่าวเพื่อระบุความรู้สึกของนักลงทุนต่อตลาด 3) การลดมิติของ

คุณสมบัติของข่าวที่ถูกสกัด ขั้นตอนทั้งสามถูกออกแบบมาเพื่อรองรับกระแสของข้อความที่เข้ามาจำนวนมาก และทำการวิเคราะห์แบบจำลองทันทีที่มีข้อมูลใหม่เข้ามา [18]

#### 4.4 งานวิจัยด้านกลยุทธ์การลงทุน

[1] ได้นำเสนอการวัดประสิทธิภาพของแบบจำลองการลงทุนที่พยากรณ์ราคาสูงสุดและราคาต่ำสุดของวันด้วยการสร้างระบบจำลองการซื้อขายขึ้นมา ระบบจำลองการซื้อขายนี้จะพิจารณาราคาปิดของกรอบเวลา 15 นาที เพื่อนำไปในการลงทุน กำหนดให้ *close* เป็นราคาปิดของกรอบเวลา 15 นาที, *min* เป็นราคาต่ำสุดที่ได้จากการพยากรณ์ และ *max* เป็นราคาสูงสุดที่ได้จากการพยากรณ์ กฎการลงทุนที่ผู้เขียนนำเสนอสามารถสรุปเป็นกฎได้ 6 ข้อดังนี้ 1) ซื้อ เมื่อ  $close \leq min$ , ขาย เมื่อ  $close \geq max$  2) ซื้อ เมื่อ  $close \leq min$ , ขายในนาที่สุดท้ายของวัน 3) ซื้อ เมื่อ  $close \leq min$ , ขายที่จุดหยุดการขาดทุน 4) ขาย เมื่อ  $close \geq max$ , ซื้อ เมื่อ  $close \leq min$  5) ขาย เมื่อ  $close \geq max$ , ซื้อในนาที่สุดท้ายของวัน 6) ขาย เมื่อ  $close \geq max$ , ซื้อที่จุดหยุดการขาดทุน โดยจุดหยุดขาดทุนคือจุดที่ทำให้เกิดการขาดทุนในการลงทุนที่ผิดพลาด 0.5% ของเงินในบัญชี [36] ทำการวัดประสิทธิภาพของแบบจำลองการลงทุนที่พยากรณ์ราคาในอีก 20 นาทีข้างหน้า ด้วยการใช้ระบบจำลองการลงทุนที่พิจารณาการร้อยละการเปลี่ยนแปลงของราคาหุ้นในเวลาปัจจุบันและราคาที่ได้จากการพยากรณ์ในอีก 20 นาทีข้างหน้า ถ้าร้อยละการเปลี่ยนแปลงมากกว่า 1% ระบบจะทำการซื้อหรือขายหุ้นที่ราคาปัจจุบันด้วยจำนวนเงิน 1,000 ดอลลาร์สหรัฐ และปิดการซื้อขายในอีก 20 นาที

### 5. แนวคิดและวิธีดำเนินงาน

1. ศึกษางานวิจัยที่เกี่ยวข้องกับการพยากรณ์อนุกรมเวลาทางการเงิน
2. เลือกงานวิจัยต้นแบบด้านการพยากรณ์อนุกรมเวลาทางการเงิน
3. ศึกษาทฤษฎีในงานวิจัยต้นแบบ
4. ศึกษาวิธีการวัดผลในงานวิจัยต้นแบบ
5. สร้างแบบจำลองเพื่อพยากรณ์ราคาสูงสุดและต่ำสุดของคู่สกุลเงิน EUR/USD, USD/JPY, GBP/USD และ USD/THB
6. วัดผล, เปรียบเทียบ และสรุปผลที่ได้
7. จัดทำเอกสารวิทยานิพนธ์

#### 5.1 ศึกษางานวิจัยที่เกี่ยวข้องกับการพยากรณ์อนุกรมเวลาทางการเงิน

ศึกษางานวิจัยที่เกี่ยวข้องกับการพยากรณ์อนุกรมเวลาทางการเงินโดยใช้การเรียนรู้ของเครื่อง และให้ความสนใจเป็นพิเศษกับงานวิจัยการพยากรณ์บนตลาดหุ้นโดยใช้โครงข่ายประสาทเทียม และงานวิจัยบนตลาดอัตราแลกเปลี่ยนโดยใช้โครงข่ายประสาทเทียม

## 5.2 เลือกรงานวิจัยต้นแบบด้านการพยากรณ์อนุกรมเวลาทางการเงิน

เลือกรงานวิจัยต้นแบบโดยพิจารณาเงื่อนไข 3 ประการ 1. ความแม่นยำของผลลัพธ์การพยากรณ์ 2. ใช้ตัวบ่งชี้ทางเทคนิค (Technical Indicator) เป็นอินพุต 3. งานวิจัยถูกตีพิมพ์ในวารสารที่มีดัชนีเฮิร์สส์ (H Index) สูง และมีผู้อ้างอิงเป็นจำนวนมาก

## 5.3 ศึกษาทฤษฎีในงานวิจัยต้นแบบ

ศึกษาทฤษฎีในงานวิจัยต้นแบบ ซึ่งประกอบด้วย 9 ทฤษฎีที่สำคัญ ได้แก่ 1. โครงข่ายประสาทเทียม (Artificial Neural Network) 2. ขั้นตอนการส่งค่าย้อนกลับ (Backpropagation Algorithm) 3. ขั้นตอนวิธีเลเวนเบิร์ก-มาร์ควาร์ด (Levenberg-Marquardt Algorithm) 4. โครงข่ายประสาทเทียมอย่างถูกต้องของเบส์ (Bayesian Regularized Artificial Neural Network) 5. การแยกส่วนประกอบของรูปแบบเชิงประจักษ์ (Empirical mode decomposition) (EMD) 6. โครงข่ายประสาทเทียมแบบความแรงของเวลาอย่างสุ่ม (Stochastic Time Strength Neural Network) (STNN) 7. ฟังก์ชันความแรงของเวลาอย่างสุ่ม (Stochastic Time Strength Function) 8. โครงข่ายประสาทเทียมแบบเรเดียลเบซิสฟังก์ชัน (Radial Basis Function Neural Network) (RBFRT) 9. เรเดียลเบซิสฟังก์ชัน (Radial Basis Function)

## 5.4 ศึกษาวิธีการวัดผลในงานวิจัยต้นแบบ

ศึกษาวิธีการวัดผลในงานวิจัยต้นแบบซึ่งแปลงผลลัพธ์การพยากรณ์เป็นการตัดสินใจทางการลงทุนในระบบจำลองการซื้อขาย ซึ่งสามารถวัดผลลัพธ์การพยากรณ์เป็นกำไรหรือขาดทุนในการลงทุนจริง

## 5.5 สร้างแบบจำลองเพื่อพยากรณ์ราคาสูงสุดและต่ำสุดของคู่สกุลเงิน EUR/USD, USD/JPY, GBP/USD และ USD/THB

5.5.1 ดาวน์โหลดข้อมูลย้อนหลังของอัตราแลกเปลี่ยนค่าสกุลเงิน EUR/USD, USD/JPY, GBP/USD และ USD/THB รายวันและราย 15 นาที ข้อมูลย้อนหลังรายวันจะถูกนำมาใช้เพื่อสร้างแบบจำลอง ในขณะที่ข้อมูลย้อนหลังราย 15 นาทีจะถูกนำมาใช้ในการสร้างระบบจำลองการซื้อขาย

5.5.2 สร้างแบบจำลองด้วยโครงข่ายประสาทเทียมจากงานวิจัยต้นแบบ 4 วิธี เพื่อพยากรณ์อัตราแลกเปลี่ยนคู่สกุลเงิน EUR/USD, USD/JPY, GBP/USD และ USD/THB

5.5.2.1 สร้างแบบจำลองด้วยโครงข่ายประสาทเทียมแบบส่งค่าย้อนกลับ (Backpropagation Neural Network) 1 แบบจำลอง เพื่อพยากรณ์อัตราแลกเปลี่ยนของคู่สกุลเงิน EUR/USD, USD/JPY, GBP/USD และ USD/THB โดยมีเอาต์พุต 2 ปม คือราคาสูงสุดและราคาต่ำสุดของวันปัจจุบัน และมีการตั้งค่าเบื้องต้นดังตารางที่ 5.1

อินพุต	ราคาสูงสุด และราคาต่ำสุด ตลอด 5 วันที่ผ่านมา
	Exponential Moving Average ของราคาสูงสุดและต่ำสุด ในช่วง 5 วัน
	Upper Band และ Lower Band ของราคาปิด ในช่วง 5 วัน

	ราคาเปิดของวันที่พยากรณ์
การทำให้ปกติ (normalization)	ค่าของอินพุตแต่ละตัวหารด้วยค่าของอินพุตที่สูงที่สุดคูณสอง ซึ่งจะได้ค่าที่ออกมาอยู่ในช่วง [0, 0.5]
โครงสร้าง โครงข่ายประสาทเทียม	15 x รากที่สองของผลคูณระหว่างจำนวนปม ในชั้นอินพุตกับจำนวนปม ในชั้นเอาต์พุต x 2
อัตราการเรียนรู้	0.001
ฟังก์ชันกระตุ้นสำหรับชั้นซ่อน	Rectified Linear Unit (ReLU)
ฟังก์ชันกระตุ้นสำหรับชั้นเอาต์พุต	Rectified Linear Unit (ReLU)
ค่าน้ำหนัก	สุ่มค่าจากในช่วง (0, 1)
ฟังก์ชันค่าผิดพลาด	$E(\vec{w}) = \frac{1}{2} \sum_{p=1}^P \sum_{m=1}^M e_{p,m}^2$
เงื่อนไขหยุดสอน	จำนวนรอบการสอนมากกว่าจำนวนรอบที่กำหนด หรือ ค่าของฟังก์ชันค่าผิดพลาดน้อยกว่าค่าที่กำหนด

ตารางที่ 5.1 แสดงการตั้งค่าเบื้องต้นของแบบจำลองโครงข่ายประสาทเทียมแบบส่งค่าย้อนกลับสำหรับพยากรณ์ราคาสูงสุดและราคาต่ำสุดของวันปัจจุบัน

5.5.2.2 สร้างแบบจำลองด้วยโครงข่ายประสาทเทียมอย่างถูกต้องของเบส์ (Bayesian Regularized Artificial Neural Network) 1 แบบจำลอง เพื่อพยากรณ์อัตราแลกเปลี่ยนของคู่สกุลเงิน EUR/USD, USD/JPY, GBP/USD และ USD/THB โดยมีเอาต์พุต 2 ปมคือราคาสูงสุดและราคาต่ำสุดของวันปัจจุบัน และมีการตั้งค่าเบื้องต้นดังตารางที่ 5.2 เราทำการปรับโครงสร้างของโครงข่ายประสาทเทียมจากงานต้นแบบในชั้นเอาต์พุต ในงานวิจัยต้นแบบของเรา โครงข่ายประสาทเทียมมีเอาต์พุต 1 ปม คือราคาปิด แต่โครงข่ายประสาทเทียมที่เราสร้างมีเอาต์พุต 2 ปม คือ ราคาสูงสุด และราคาต่ำสุด เราไม่เปลี่ยนอินพุตของโครงข่ายประสาทเทียม เพราะอินพุตของงานวิจัยต้นแบบประกอบด้วยตัวบ่งชี้ทางเทคนิค (technical indicator) หลายตัวซึ่งเชื่อว่าเพียงพอต่อการพยากรณ์

อินพุต	ราคาเปิด, ราคาสูงสุด และราคาต่ำสุดของวันที่ผ่านมา
	Exponential Moving Average ของราคาสูงสุด ในช่วง 5 วันและ 10 วัน
	Relative Strength Index (RSI)
	Willian R%, Stochastic K% และ Stochastic D%
การทำให้ปกติ (normalization)	Mapminmax ซึ่งจะได้ค่าที่ออกมาอยู่ในช่วง [-1, 1]
โครงสร้าง โครงข่ายประสาทเทียม	9 x จำนวนปมที่ทำให้ตัวแปรที่มีประสิทธิภาพสูง x 2
อัตราการเรียนรู้	0.001
ฟังก์ชันกระตุ้นสำหรับชั้นซ่อน	Tangent Sigmoid Function
ฟังก์ชันกระตุ้นสำหรับชั้นเอาต์พุต	Identity Map
ค่าน้ำหนัก	สุ่มค่าจากในช่วง (0, 1)
ฟังก์ชันค่าผิดพลาด	$F(\vec{w}) = \beta E_D(\vec{w}) + \alpha E_W(\vec{w})$

เงื่อนไขหยุดสอน	จำนวนรอบการสอนมากกว่าจำนวนรอบที่กำหนด หรือ ค่าของฟังก์ชันค่าผิดพลาดน้อยกว่าค่าที่กำหนด
-----------------	--

ตารางที่ 5.2 แสดงการตั้งค่าเบื้องต้นของแบบจำลองโครงข่ายประสาทเทียมอย่างถูกต้องของเบสสำหรับพยากรณ์ราคาสูงสุดและราคาต่ำสุดของหนึ่งวันในอนาคต

5.5.2.3 สร้างแบบจำลองด้วยขั้นตอนผสมผสานระหว่างการแยกส่วนประกอบของรูปแบบเชิงประจักษ์กับขั้นตอนโครงข่ายประสาทเทียมแบบความแรงของเวลาอย่างสุ่ม (Empirical Mode Decomposition Stochastic Time Strength Neural Network) (EMD-STNN) 2 แบบจำลอง เพื่อพยากรณ์อัตราแลกเปลี่ยนของคู่สกุลเงิน EUR/USD, USD/JPY, GBP/USD และ USD/THB

โดยที่แบบจำลองที่หนึ่งใช้ข้อมูลอนุกรมเวลาของราคาสูงสุดและมีเอาต์พุต 1 ปมคือราคาสูงสุดของวันปัจจุบัน และแบบจำลองที่สองใช้ข้อมูลอนุกรมเวลาของราคาต่ำสุดและมีเอาต์พุต 1 ปมคือราคาต่ำสุดของวันปัจจุบัน และมีการตั้งค่าเบื้องต้นดังตารางที่ 5.3

เหตุผลที่เราสร้าง EMD-STNN 2 แบบจำลอง เพราะเราต้องการรักษาคุณสมบัติของงานวิจัยต้นแบบไว้ ในงานวิจัยต้นแบบใช้อินพุตเป็นอนุกรมเวลาของราคาปิด และมีเอาต์พุตเป็นราคาปิดของวันปัจจุบัน งานของเราต้องการพยากรณ์ราคาสูงสุดและราคาต่ำสุด จึงทำการสร้าง EMD-STNN 2 แบบจำลอง โดยที่แบบจำลองที่พยากรณ์ราคาสูงสุดก็จะใช้อินพุตเป็นอนุกรมเวลาของราคาสูงสุด และแบบจำลองที่พยากรณ์ราคาต่ำสุดก็จะใช้อินพุตเป็นอนุกรมเวลาของราคาต่ำสุด

อินพุต	ข้อมูลย้อนหลังตลอด 4 วันที่ผ่านมา
การทำให้ปกติ (normalization)	Min-Max Normalization ซึ่งจะได้ออกมาอยู่ในช่วง [0, 1]
โครงสร้างโครงข่ายประสาทเทียม	4 x จำนวนปมที่ทำให้ชุดตรวจสอบผิดพลาดน้อยที่สุด (ค่าที่ใกล้เคียงสองเท่าของจำนวนปมในชั้นอินพุตบวกหนึ่ง) x 1
อัตราการเรียนรู้	0.001
ฟังก์ชันกระตุ้นสำหรับชั้นซ่อน	Sigmoid Function
ฟังก์ชันกระตุ้นสำหรับชั้นเอาต์พุต	Identity Map
ค่าน้ำหนัก	สุ่มค่าจากในช่วง (-1, 1)
ฟังก์ชันค่าผิดพลาด	$E(t_n) = \frac{1}{N} \sum_{n=1}^N \rho(t_n)(d_{t_n} - y_{t_n})^2$
เงื่อนไขหยุดสอน	จำนวนรอบการสอนมากกว่าจำนวนรอบที่กำหนด หรือ ค่าของฟังก์ชันค่าผิดพลาดน้อยกว่าค่าที่กำหนด

ตารางที่ 5.3 แสดงการตั้งค่าเบื้องต้นของแบบจำลองที่หนึ่งของขั้นตอนผสมผสานระหว่างการแยกส่วนประกอบของรูปแบบเชิงประจักษ์กับขั้นตอนโครงข่ายประสาทเทียมแบบความแรงของเวลาอย่างสุ่มสำหรับพยากรณ์ราคาสูงสุดของวันปัจจุบันหรือราคาต่ำสุดของวันปัจจุบัน

5.5.2.4 สร้างแบบจำลองด้วยขั้นตอนผสมผสานระหว่างข้อมูลแบบสุ่มเชิงเวลาที่มีประสิทธิภาพกับโครงข่ายประสาทเทียมแบบเรเดียลเบซิสฟังก์ชัน (Random Data-time Effective Radial Basis Function Neural Network) (RBFRT) 2 แบบจำลอง เพื่อพยากรณ์อัตราแลกเปลี่ยนของคู่สกุลเงิน EUR/USD, USD/JPY, GBP/USD และ USD/THB โดยที่แบบจำลองที่หนึ่งใช้ข้อมูลอนุกรมเวลาของราคาสูงสุดและมีเอาต์พุต 1 ปมคือราคาสูงสุดของวันปัจจุบัน และแบบจำลองที่สองใช้ข้อมูลอนุกรมเวลาของราคาต่ำสุดและมีเอาต์พุต 1 ปมคือราคาต่ำสุดของวันปัจจุบัน และมีการตั้งค่าเบื้องต้นดังตารางที่ 5.4

เหตุผลที่เราสร้าง RBFRT 2 แบบจำลอง เพราะเราต้องการรักษาคุณสมบัติของงานวิจัยต้นแบบไว้ ในงานวิจัยต้นแบบใช้อินพุตเป็นราคาปิดย้อนหลัง 4 วัน และมีเอาต์พุตเป็นราคาปิดของวันปัจจุบัน งานของเราต้องการพยากรณ์ราคาสูงสุดและราคาต่ำสุด จึงทำการสร้าง RBFRT 2 แบบจำลอง โดยที่แบบจำลองที่พยากรณ์ราคาสูงสุดก็จะใช้อินพุตเป็นอนุกรมเวลาของราคาสูงสุด และแบบจำลองที่พยากรณ์ราคาต่ำสุดก็จะใช้อินพุตเป็นอนุกรมเวลาของราคาต่ำสุด

อินพุต	ข้อมูลย้อนหลังตลอด 4 วันที่ผ่านมา
การทำให้ปกติ (normalization)	Min-Max Normalization ซึ่งจะได้ค่าที่ออกมาอยู่ในช่วง [0, 1]
โครงสร้างโครงข่ายประสาทเทียม	4 x 15 x 1
อัตราการเรียนรู้ของค่าน้ำหนัก	0.001
อัตราการเรียนรู้ของศูนย์กลาง	0.001
อัตราการเรียนรู้ของความกว้าง	0.001
ฟังก์ชันกระตุ้นสำหรับชั้นซ่อน	Radial Basis Function
ฟังก์ชันกระตุ้นสำหรับชั้นเอาต์พุต	Identity Map
ค่าน้ำหนัก	สุ่มค่าจากในช่วง (-0.1, 0.1)
เวกเตอร์ศูนย์กลาง	สุ่มค่าจากในช่วง (0, 1)
ความกว้าง	สุ่มค่าจากในช่วง (0.1, 0.3)
ฟังก์ชันค่าผิดพลาด	$E(t_n) = \frac{1}{N} \sum_{n=1}^N \rho(t_n)(d_{t_n} - y_{t_n})^2$
เงื่อนไขหยุดสอน	จำนวนรอบการสอนมากกว่าจำนวนรอบที่กำหนด หรือ ค่าของฟังก์ชันค่าผิดพลาดน้อยกว่าค่าที่กำหนด

ตารางที่ 5.4 แสดงการตั้งค่าเบื้องต้นของแบบจำลองที่หนึ่งของขั้นตอนผสมผสานระหว่างข้อมูลแบบสุ่มเชิงเวลาที่มีประสิทธิภาพกับโครงข่ายประสาทเทียมแบบเรเดียลเบซิสฟังก์ชันสำหรับพยากรณ์ราคาสูงสุดของวันปัจจุบันหรือราคาต่ำสุดของวันปัจจุบัน

5.5.3 สร้างแบบจำลองด้วยโครงข่ายประสาทเทียมที่นำเสนอ 3 ขั้นตอนวิธี เพื่อพยากรณ์อัตราแลกเปลี่ยนคู่สกุลเงิน EUR/USD, USD/JPY, GBP/USD และ USD/THB

5.5.3.1 ด้วยขั้นตอนผสมผสานระหว่างการแยกส่วนประกอบของรูปแบบเชิงประจักษ์, ข้อมูลแบบสุ่มเชิงเวลาที่มีประสิทธิภาพ และโครงข่ายประสาทเทียมแบบเรเดียลเบซิสฟังก์ชัน (Empirical Mode Decomposition Random Data-time

Effective Radial Basis Function Neural Network) (EMD-RBFRT) 2 แบบจำลอง เพื่อพยากรณ์อัตราแลกเปลี่ยนของคู่สกุลเงิน EUR/USD, USD/JPY, GBP/USD และ USD/THB

โดยที่แบบจำลองที่หนึ่งใช้ข้อมูลอนุกรมเวลาของราคาสูงสุดและมีเอาต์พุต 1 ปมคือราคาสูงสุดของวันปัจจุบัน

และแบบจำลองที่สองใช้ข้อมูลอนุกรมเวลาของราคาต่ำสุดและมีเอาต์พุต 1 ปมคือราคาต่ำสุดของวันปัจจุบัน และมีการตั้งค่าเบื้องต้นดังตารางที่ 5.4

5.5.3.2 ด้วยขั้นตอนผสมผสานระหว่างการแยกส่วนประกอบของรูปแบบเชิงประจักษ์, การทำให้ถูกต้องของเบส, ข้อมูลแบบสุ่มเชิงเวลาที่มีประสิทธิภาพ และโครงข่ายประสาทเทียมแบบเบเรเดียลเบสฟังก์ชัน (Empirical Mode Decomposition Bayesian Regularized Random Data-time Effective Radial Basis Function Neural Network) (EMD-BR-RBFRT) 2 แบบจำลอง เพื่อพยากรณ์อัตราแลกเปลี่ยนของคู่สกุลเงิน EUR/USD, USD/JPY, GBP/USD และ USD/THB

โดยที่แบบจำลองที่หนึ่งใช้ข้อมูลอนุกรมเวลาของราคาสูงสุดและมีเอาต์พุต 1 ปมคือราคาสูงสุดของวันปัจจุบัน

และแบบจำลองที่สองใช้ข้อมูลอนุกรมเวลาของราคาต่ำสุดและมีเอาต์พุต 1 ปมคือราคาต่ำสุดของวันปัจจุบัน และมีการตั้งค่าเบื้องต้นดังตารางที่ 5.4 แต่ใช้ฟังก์ชันค่าผิดพลาดเป็น  $E(t_n) = \beta \sum_{n=1}^N \rho(t_n)(d_{t_n} - y_{t_n})^2 + \alpha E_W$

$$E(t_n) = \beta \sum_{n=1}^N \rho(t_n)(d_{t_n} - y_{t_n})^2 + \alpha E_W$$

5.5.3.3 ด้วยขั้นตอนผสมผสานระหว่างการแยกส่วนประกอบของรูปแบบเชิงประจักษ์, การทำให้ถูกต้องของเบส และโครงข่ายประสาทเทียมแบบความแรงของเวลาอย่างสุ่ม (Empirical Mode Decomposition Bayesian Regularized Stochastic Time Strength Neural Network ) (EMD-BR-STNN) 2 แบบจำลอง เพื่อพยากรณ์อัตราแลกเปลี่ยนของคู่สกุลเงิน EUR/USD, USD/JPY, GBP/USD และ USD/THB

โดยที่แบบจำลองที่หนึ่งใช้ข้อมูลอนุกรมเวลาของราคาสูงสุดและมีเอาต์พุต 1 ปมคือราคาสูงสุดของวันปัจจุบัน

และแบบจำลองที่สองใช้ข้อมูลอนุกรมเวลาของราคาต่ำสุดและมีเอาต์พุต 1 ปมคือราคาต่ำสุดของวันปัจจุบัน และมีการตั้งค่าเบื้องต้นดังตารางที่ 5.3 แต่ใช้ฟังก์ชันค่าผิดพลาดเป็น  $E(t_n) = \beta \sum_{n=1}^N \rho(t_n)(d_{t_n} - y_{t_n})^2 + \alpha E_W$

$$E(t_n) = \beta \sum_{n=1}^N \rho(t_n)(d_{t_n} - y_{t_n})^2 + \alpha E_W$$

## 5.6 วัดผล, เปรียบเทียบ และสรุปผลที่ได้

5.6.1 วัดประสิทธิภาพของแบบจำลองทั้ง 7 ขั้นตอนวิธีด้วย ค่าเฉลี่ยของค่าผิดพลาดยกกำลังสอง (Mean Squared Error) (MSE), ค่าเฉลี่ยของค่าคลาดเคลื่อนสมบูรณ์ (Mean Absolute Error) (MAE), ค่าเฉลี่ยของร้อยละความผิดพลาดสมบูรณ์ (Mean Absolute Percentage Error) (MAPE) และ ระบบจำลองการซื้อขาย (Trading System)

พิจารณาข้อมูลย้อนหลังการซื้อขายตั้งแต่วันที่ 12 พฤษภาคม 2548 จนถึง 24 เมษายน 2561 เห็นว่ามีจำนวนวันที่มีการซื้อขายอัตราแลกเปลี่ยนทั้งหมด 3,900 วัน ในที่นี้เราจะแบ่งข้อมูลทั้งหมดออกเป็นชุดข้อมูลสอนและชุดข้อมูลทดสอบโดยมีอัตราส่วนระหว่างชุดข้อมูลสอนและชุดข้อมูลทดสอบเป็น 80:20 ซึ่งได้ว่าข้อมูลตั้งแต่วันที่ 1 ถึง 3,100 เป็นชุดข้อมูลสอนและข้อมูลตั้งแต่วันที่ 3,101 ถึง 3,900 เป็นชุดข้อมูลทดสอบ

สำหรับขั้นตอนวิธีโครงข่ายประสาทเทียมแบบส่งค่าย้อนกลับจะทำการสอนด้วยชุดข้อมูลจำนวน 600 วันและทดสอบด้วยชุดข้อมูลจำนวน 200 วัน เพื่อให้มีการทดสอบประสิทธิภาพได้เหมือนกับแบบจำลองอื่นต้องมีการใช้ชุดทดสอบที่เหมือนกันคือ ตั้งแต่วันที่ 3,101 ถึง 3,900 ดังนั้นแบ่งการเรียนออกเป็น 4 ครั้งดังนี้

ครั้งที่ 1 ใช้ชุดข้อมูลสอนวันที่ 2,501 ถึง 3,100 และใช้ข้อมูลทดสอบวันที่ 3,101 - 3,300

ครั้งที่ 2 ใช้ชุดข้อมูลสอนวันที่ 2,701 ถึง 3,300 และใช้ข้อมูลทดสอบวันที่ 3,301 - 3,500

ครั้งที่ 3 ใช้ชุดข้อมูลสอนวันที่ 2,901 ถึง 3,500 และใช้ข้อมูลทดสอบวันที่ 3,501 - 3,700

ครั้งที่ 4 ใช้ชุดข้อมูลสอนวันที่ 3,101 ถึง 3,700 และใช้ข้อมูลทดสอบวันที่ 3,701 - 3,900

เนื่องจากผลลัพธ์ที่ได้จากโครงข่ายประสาทเทียมเป็นผลลัพธ์ระดับท้องถิ่น การวัดประสิทธิภาพของขั้นตอนวิธีทั้ง 6 วิธีจึงไม่สามารถเลือกเฉพาะผลลัพธ์ครั้งใดครั้งหนึ่งเพื่อนำมาเปรียบเทียบประสิทธิภาพกันได้ ในงานวิจัยนี้เราทำการจำลองทุกขั้นตอนวิธีจำนวน 100 ครั้งและนำประสิทธิภาพเฉลี่ยของ MSE, MAE, MAPE และ Trading Strategy ของแต่ละขั้นตอนวิธีมาเปรียบเทียบกัน ในการวัดผลเราไม่ใช้ K-fold cross validation เพราะใน EMD-STNN, RBFRT, EMD-RBFRT, EMD-BR-RBFRT และ EMD-BR-STNN มีการให้ค่าน้ำหนักกับแต่ละจุดของข้อมูลที่เกิดขึ้นในอนุกรมเวลา ดังนั้นการใช้ K-fold cross validation จึงไม่เหมาะกับการวัดผล

สมการของค่าเฉลี่ยของค่าผิดพลาดยกกำลังสอง (Mean Squared Error) (MSE) บรรยายได้ดังสมการที่ 4.1

$$E(\bar{w}) = \frac{1}{NK} \sum_{n=1}^N \sum_{k=1}^K e_{n,k}^2 \quad (4.1)$$

สมการของค่าเฉลี่ยของค่าคลาดเคลื่อนสมบูรณ์ (Mean Absolute Error) (MAE) บรรยายได้ดังสมการที่ 4.2

$$E(\bar{w}) = \frac{1}{NK} \sum_{n=1}^N \sum_{k=1}^K |e_{n,k}| \quad (4.2)$$

สมการของค่าเฉลี่ยของร้อยละความผิดพลาดสมบูรณ์ (Mean Absolute Percentage Error) (MAPE) บรรยายได้ดังสมการที่ 4.3

$$E(\bar{w}) = \frac{1}{NK} \sum_{n=1}^N \sum_{k=1}^K \frac{|e_{n,k}|}{t_{n,k}} \quad (4.3)$$

โดยที่

$n$  เป็นดัชนีของตัวอย่างมีค่าตั้งแต่ 1 ถึง  $N$

$k$  เป็นดัชนีของตัวอย่างมีค่าตั้งแต่ 1 ถึง  $K$

$e_{n,k}$  เป็นผลต่างของเอาต์พุตเป้าหมายและเอาต์พุตของโครงข่ายประสาทเทียมที่  $k$  ในตัวอย่างที่  $n$  ซึ่งสามารถนิยามได้ดังสมการที่ 4.4

$$e_{n,k} = t_{n,k} - a_{n,k} \quad (4.4)$$

โดยที่

$t_{n,k}$  เป็นเอาต์พุตเป้าหมายที่  $k$  ในตัวอย่างที่  $n$

$a_{n,k}$  เป็นเอาต์พุตของโครงข่ายประสาทเทียมที่  $k$  ในตัวอย่างที่  $n$



5.6.1.1 สร้างระบบจำลองการซื้อขาย (Trading System) ระบบจำลองการซื้อขายประกอบด้วย 3 ส่วนหลักได้แก่ กลยุทธ์การลงทุน, วิธีการจัดการความเสี่ยง และหลักการบริหารเงิน

ระบบจำลองการซื้อขายในงานวิจัยนี้ใช้ราคาปิดที่กรอบเวลา 15 นาทีในการพิจารณาการลงทุน

ให้  $close$  เป็นราคาปิดของกรอบเวลา 15 นาที

$min$  เป็นราคาต่ำสุดที่ได้จากการพยากรณ์

$max$  เป็นราคาสูงสุดที่ได้จากการพยากรณ์

กลยุทธ์การลงทุนสามารถสรุปเป็นกฎได้ 6 ข้อดังนี้

- 1) ซื้อ เมื่อ  $close \leq min$ , ขาย เมื่อ  $close \geq max$
- 2) ซื้อ เมื่อ  $close \leq min$ , ขายในนาที่สุดท้ายของวัน
- 3) ซื้อ เมื่อ  $close \leq min$ , ขายที่จุดหยุดการขาดทุน
- 4) ขาย เมื่อ  $close \geq max$ , ซื้อ เมื่อ  $close \leq min$
- 5) ขาย เมื่อ  $close \geq max$ , ซื้อในนาที่สุดท้ายของวัน
- 6) ขาย เมื่อ  $close \geq max$ , ซื้อที่จุดหยุดการขาดทุน

ระบบจำลองการซื้อขายมีการจัดการความเสี่ยงตามและการบริหารเงินคือตั้งจุดหยุดขาดทุนไว้ที่ 0.5% ของเงินในบัญชี และในการซื้อขายแต่ละครั้งจะซื้อขายด้วยจำนวนเงินทั้งหมด [1]

5.6.2 สร้างตารางเปรียบเทียบประสิทธิภาพเฉลี่ยของแต่ละขั้นตอนวิธี

## 6. ขอบเขตการดำเนินงาน

1. ใช้ข้อมูลอัตราแลกเปลี่ยนของคู่สกุลเงิน EUR/USD, USD/JPY, GBP/USD และ USD/THB ตั้งแต่วันที่ 5 พฤษภาคม 2548 ถึง 24 เมษายน 2561 เท่านั้น
2. ทำการวัดผลด้วยค่าเฉลี่ยของค่าผิดพลาดยกกำลังสอง (Mean Squared Error) (MSE), ค่าเฉลี่ยค่าคลาดเคลื่อนสมบูรณ์ (Mean Absolute Error) (MAE), ค่าเฉลี่ยร้อยละความผิดพลาดสมบูรณ์ (Mean Absolute Percentage Error) (MAPE) และระบบจำลองการซื้อขาย (Trading System) ที่มีกลยุทธ์การลงทุน, วิธีการจัดการความเสี่ยง และหลักการบริหารเงิน ดังกล่าวในแนวคิดและวิธีดำเนินงานเท่านั้น
3. ใช้ขั้นตอนวิธีในการพยากรณ์ดังกล่าวในแนวคิดและวิธีดำเนินงานเท่านั้น
4. ใช้อินพุตเป็นตัวบ่งชี้ทางเทคนิค (Technical Indicator) เท่านั้น

## 7. ประโยชน์ที่คาดว่าจะได้รับ

ได้โครงข่ายประสาทเทียม (Neural Network) ที่เหมาะสมในการพยากรณ์อัตราแลกเปลี่ยนคู่สกุลเงิน EUR/USD, USD/JPY, GBP/USD และ USD/THB

## 8. เอกสารอ้างอิง

- [1] Martinez L. C. (2009). From an Artificial Neural Network to a Stock Market Day Trading System: A Case Study on BM&F Bovespa, IEEE, Atlanta, Georgia, USA.
- [2] Ticknor J. L. (2013). A Bayesian regularized artificial neural network for stock market forecasting. *Expert Systems with Applications*, 40(14), 5501–5506.
- [3] Wang J., & Wang J. (2017). Forecasting stochastic neural network based on financial empirical mode decomposition. *Neural Networks*, 90, 8-20.
- [4] Niu H., & Wang J. (2014). Financial time series prediction by a random data-time effective RBF neural network. *Soft Computing*, 18, 497-508
- [5] Artificial Intelligence - Neural Networks. Retrieved April 24, 2018, from [https://www.tutorialspoint.com/artificial\\_intelligence/artificial\\_intelligence\\_neural\\_networks.htm](https://www.tutorialspoint.com/artificial_intelligence/artificial_intelligence_neural_networks.htm)
- [6] Backpropagation. Retrieved April 24, 2018, from <https://en.wikipedia.org/wiki/Backpropagation>
- [7] Kondratenko V. V., & Kuperin Y. A. (2003). Using Recurrent Neural Networks To Forecasting of Forex. St. Petersburg State University.
- [8] A.N. Refenes, A. Zaprani (1994). G. Francis, Stock performance modeling using neural networks: a comparative study with regression models, *Neural Network*, 5, 961-970.
- [9] Singh M. (2013). 17 Proven Currency Trading Strategies: How to Profit in the Forex Market. John Wiley & Sons Singapore, 252 p.
- [10] Triennial Central Bank Survey of foreign exchange and OTC derivatives markets in 2016. Retrieved May 9, 2018, from <https://www.bis.org/publ/rpfx16.htm>
- [11] Wang, J.-Z., Wang, J.-J., Zhang, Z.-G., & Guo, S.-P. (2011). Forecasting stock indices with back propagation neural network. *Expert Systems with Applications*, 38(11), 14346–14355.
- [12] Kumar, D., & Murugan, S. (2013). Performance analysis of Indian stock market index using neural network time series model. In *International conference on pattern recognition, informatics and mobile engineering* (pp. 72–78). IEEE.
- [13] Si, Y.-W., & Yin, J. (2013). OBST-based segmentation approach to financial time series. *Engineering Applications of Artificial Intelligence*, 26(10), 2581–2596.
- [14] Lee, M.-C. (2009). Using support vector machine with a hybrid feature selection method to the stock trend prediction. *Expert Systems with Applications*, 36(8), 10896–10904.
- [15] Atsalakis, G. S., & Valavanis, K. P. (2009). Surveying stock market forecasting techniques–Part II: Soft computing methods. *Expert Systems with Applications*, 36(3), 5932–5941.
- [16] Lu, C. J., Lee, T. S., & Chiu, C. C. (2009). Financial time series forecasting using independent component analysis and support vector regression. *Decision Support Systems*, 47(2), 115–125.
- [17] Tay, F. E., & Cao, L. (2001). Application of support vector machines in financial time series forecasting. *Omega*, 29(4), 309–317.

- [18] Cavalcante R. C., Brasileiro R. C., Souza V. L.F., & Nobrega J. P. (2016). Computational Intelligence and Financial Markets- A Survey and Future Directions. *Expert System With Applications*, 55, 194-211.
- [19] Yao J., & Tan C. L. (2000). A case study on using neural networks to perform technical forecasting of forex. *Neurocomputing*, 34, 79-98.
- [20] Forsee F. D., & Hagan M. T. (1997). Gauss-Newton approximation to bayesian learning. In IEEE *international conference on neural networks* (Vols. 1-4, pp. 1930-1935). Houston, TX, USA, <http://dx.doi.org/10.1109/ICNN.1997.614194>.
- [21] Liao Z., & Wang J. (2010). Forecasting model of global stock index by stochastic time effective neural network. *Expert Systems with Applications*, 37, 834-841.
- [22] Liu F., & Wang J. (2012). Fluctuation prediction of stock market index by Legendre neural network with random time strength function. *Neurocomputing*, 83, 12-21.
- [23] Wang J., & Wang J. (2015). Forecasting stock market indexes using principle component analysis and stochastic time effective neural networks, *Neurocomputing*, 156, 68-78.
- [24] Mahadevan S., Chandar S. K., & Sivanandam S. N. (2016). Prediction of Stock Market Price using Hybrid of Wavelet Transform and Artificial Neural Network, *Indian Journal of Science and Technology*, 9(8).
- [25] Boonserm K. (2005). Artificial Intelligence. Retrieved April 24, 2018, from <https://www.cp.eng.chula.ac.th/~boonserm/teaching/ai1.0.2.pdf>
- [26] Marquardt D. W. (1963). An algorithm for least-squares estimation of nonlinear parameters. *Journal of the Society for Industrial and Applied Mathematics*. 11(2), 431-441.
- [27] David J. C. Mackay (1992). Bayesian Interpolation. *Neural Computation*, 4, 415-447
- [28] Yu H., & Wilamowski B. M. (2010). Levenberg-Marquardt Training. Auburn University.
- [29] Watson G. A. (1997). Numerical Analysis. Springer-Verlag New York Heidelberg Berlin, 213 p.
- [30] Hagan M. T., & Menhaj M. B. (1994). Training feedforward networks with the Marquardt algorithm. in IEEE *transactions on neural network* (Vols. 5, No. 6, pp. 989-993).
- [31] Suratgar A. A., Tavakoli M. B., & Hoseinabadi A. (2005). Modified Levenberg-Marquardt method for neural networks training. *World Academy of Science, Engineering and Technology*, 6.
- [32] Shi A. (2010). Stochastic Process and their Applications in Financial Pricing.
- [33] Wang J., & Wang J. (2016). Forecasting energy market indices with recurrent neural networks: Case study of crude oil price fluctuations. *Energy*, 102, 365-374
- [34] Nikfarjam A., Emadzadeh E., & Muthaiyah S. (2010). Text mining approaches for stock market prediction. In *International conference on computer and automation engineering* (pp. 256-260). IEEE.
- [35] Wang, B., Huang, H., & Wang, X. (2012). A novel text mining approach to financial time series forecasting. *Neurocomputing*, 83, 136-145.
- [36] Schumaker, R. P., Zhang, Y., Huang, C.-N., & Chen, H. (2012). Evaluating sentiment in financial news articles. *Decision Support Systems*, 53(3), 458-464.

- [37] G. Gidofalvi, Using News Articles to Predict Stock Price Movements, Department of Computer Science and Engineering, University of California, San Diego, 2001.
- [38] Groth, S. S., & Muntermann, J. (2011). An intraday market risk management approach based on textual analysis. *Decision Support Systems*, 50(4), 680–691.
- [39] V.Lavrenko,M.Schmill,etal.,Language models for financial news recommendation, International Conference on Information and Knowledge Management, Washington, DC, 2000.
- [40] Nassirtoussi, A. K., Aghabozorgi, S., Wah, T. Y., & Ngo, D. C. L. (2015). Text mining of news-headlines for FOREX market prediction: A Multi-layer Dimension Reduction Algorithm with semantics and sentiment. *Expert Systems with Applications*, 42(1), 306–324.