

การพัฒนาแบบจำลองเพื่อทำนายทิศทางของการเปลี่ยนแปลงราคาในตลาด  
แลกเปลี่ยนเงินตราต่างประเทศสำหรับการซื้อขายตัวเลือกไบนารี  
โดยใช้การเรียนรู้เชิงลึก



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรดุษฎีบัณฑิต  
สาขาวิชาวิศวกรรมโทรคมนาคมและคอมพิวเตอร์  
มหาวิทยาลัยเทคโนโลยีสุรนารี  
ปีการศึกษา 2562

**DEVELOPMENT OF MODELS TO PREDICT  
THE DIRECTION OF PRICE CHANGES IN FOREIGN  
EXCHANGE MARKET FOR BINARY OPTIONS  
TRADES USING DEEP LEARNING**



**Watthana Pongsena**

**A Thesis Submitted in Partial Fulfillment of the Requirements for the  
Degree of Doctor of Philosophy in Telecommunication and  
Computer Engineering  
Suranaree University of Technology  
Academic Year 2019**

การพัฒนาแบบจำลองเพื่อทำนายทิศทางของการเปลี่ยนแปลงราคาในตลาดแลกเปลี่ยน  
เงินตราต่างประเทศสำหรับการซื้อขายตัวเลือกไบนารีโดยใช้การเรียนรู้เชิงลึก

มหาวิทยาลัยเทคโนโลยีสุรนารี อนุมัติให้นำวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษา  
ตามหลักสูตรปริญญาคุณวุฒิบัณฑิต

คณะกรรมการสอบวิทยานิพนธ์

กีระชาติ.

(อ. ดร.กีระชาติ สุขสุทธิ)

ประธานกรรมการ

กิตติศักดิ์ กสิ

(รศ. ดร.กิตติศักดิ์ เกิดประสพ)

กรรมการ (อาจารย์ที่ปรึกษาวิทยานิพนธ์)

นิตยา

(รศ. ดร.นิตยา เกิดประสพ)

กรรมการ

มนต์ทิพย์ภา

(รศ. ดร.มนต์ทิพย์ภา อุฑารสกุล)

กรรมการ

ประ โยชน์ คำสวัสดิ์

(ผศ. ร.อ. ดร.ประ โยชน์ คำสวัสดิ์)

กรรมการ

กนต์ธร ชำนิประศาสน์

(รศ. ร.อ. ดร.กนต์ธร ชำนิประศาสน์)

รองอธิการบดีฝ่ายวิชาการและพัฒนาความเป็นสากล

พรศิริ

(รศ. ดร.พรศิริ จงกล)

คณบดีสำนักวิชาวิศวกรรมศาสตร์

วรรณะ พงษ์เสนา : การพัฒนาแบบจำลองเพื่อทำนายทิศทางของการเปลี่ยนแปลงราคาในตลาดแลกเปลี่ยนเงินตราต่างประเทศสำหรับการซื้อขายตัวเลือกไบนารีโดยใช้การเรียนรู้เชิงลึก (DEVELOPMENT OF MODELS TO PREDICT THE DIRECTION OF PRICE CHANGES IN FOREIGN EXCHANGE MARKET FOR BINARY OPTIONS TRADES USING DEEP LEARNING) อาจารย์ที่ปรึกษา : รองศาสตราจารย์ ดร.กิตติศักดิ์ เกิดประสพ, 146 หน้า.

การซื้อขายแลกเปลี่ยนเงินตราต่างประเทศหรือฟอเร็กซ์ (Foreign Exchange, Forex) เป็นการลงทุนในรูปแบบของการเก็งกำไรที่มีสภาพคล่องสูง (High-Liquidity) ซึ่งดึงดูดให้นักลงทุนจำนวนมากเข้ามาลงทุนและทำให้ตลาดแห่งนี้มีมูลค่าการลงทุนมากกว่าห้าล้านล้านดอลลาร์สหรัฐต่อวัน ส่งผลให้ฟอเร็กซ์เป็นตลาดทางการเงินที่มีขนาดใหญ่ที่สุดในโลก ในปัจจุบันทางโบรกเกอร์ (Broker) ได้นำเอาข้อมูลราคาอ้างอิงของสกุลเงินคู่ต่าง ๆ ในตลาดฟอเร็กซ์ ราคาอ้างอิงสกุลเงินดิจิทัล (Cryptocurrency) และราคาหุ้น (Stock) มาใช้เป็นช่องทางในการสร้างรูปแบบใหม่ของการลงทุนแบบเก็งกำไรที่เรียกว่า การซื้อขายตัวเลือกไบนารี (Binary Options) ในอดีตนักลงทุนนิยมใช้ตัวชี้วัดทางเทคนิค (Technical Indicators) ร่วมกับทฤษฎีการวิเคราะห์ความเคลื่อนไหวของราคา (Price Action) เป็นตัวช่วยในการตัดสินใจสำหรับการลงทุนแบบเก็งกำไรทั้งสองรูปแบบ แต่เนื่องจากค่าของตัวชี้วัดทางเทคนิคเหล่านั้นมีการเปลี่ยนแปลงอยู่ตลอดเวลาทำให้การคาดการณ์ในด้านทิศทางการเคลื่อนไหวของราคามีความแม่นยำต่ำ ยากต่อการทำกำไร เป็นสาเหตุให้เกิดการคิดค้นและพัฒนาโมเดลสำหรับการทำนายทิศทางการเคลื่อนไหวของราคาโดยใช้วิธีการทางด้านปัญญาประดิษฐ์ เช่นทฤษฎีการเรียนรู้ของเครื่อง (Machine Learning) และการเรียนรู้เชิงลึก (Deep Learning) โมเดลที่ถูกสร้างขึ้นจากทฤษฎีเหล่านี้สามารถทำนายทิศทางการเคลื่อนไหวของราคาสกุลเงินในตลาดฟอเร็กซ์ได้อย่างเหมาะสมและมีประสิทธิภาพ อย่างไรก็ตามการลงทุนในตัวเลือกไบนารีนั้นมีความแตกต่างจากฟอเร็กซ์ในด้านการคำนวณ กำไรขาดทุนและการกำหนดระยะเวลาในการลงทุน ซึ่งการลงทุนในฟอเร็กซ์นั้นไม่มีการกำหนดระยะเวลาในการลงทุน ในขณะที่การลงทุนตัวเลือกไบนารีนั้นนักลงทุนจะต้องระบุระยะเวลาในการลงทุนแต่ละครั้ง ทำให้โมเดลที่มีอยู่นั้นไม่เหมาะสมสำหรับนักลงทุนในการซื้อขายตัวเลือกไบนารี ในงานวิจัยนี้ผู้วิจัยได้พัฒนาเครื่องมือสำหรับช่วยนักลงทุนในการตัดสินใจเพื่อเก็งกำไรในการซื้อขายตัวเลือกไบนารี โดยใช้ทฤษฎีการเรียนรู้เชิงลึก อีกทั้งได้นำเสนอกลยุทธ์ที่ใช้ในการเทรดและกลยุทธ์ที่ใช้ในการตัดขาดทุนที่เหมาะสมสำหรับใช้ในการซื้อขายตัวเลือกไบนารี โดยเครื่องมือและกลยุทธ์ต่าง ๆ ที่นำเสนอในงานวิจัยนี้ได้ผ่านการทดสอบและพิสูจน์แล้วว่าสามารถใช้สร้างผลกำไรให้กับนักลงทุนในการซื้อขายตัวเลือกไบนารี ได้จริง

สาขาวิชา วิศวกรรมคอมพิวเตอร์  
ปีการศึกษา 2562


ลายมือชื่อนักศึกษา วิกรม พงษ์เสนา  
ลายมือชื่ออาจารย์ที่ปรึกษา ศาสตราจารย์ ดร. กิตติศักดิ์ เกิดประสพ

WATTHANA PONGSENA : DEVELOPMENT OF MODELS TO PREDICT  
THE DIRECTION OF PRICE CHANGES IN FOREIGN EXCHANGE  
MARKET FOR BINARY OPTIONS TRADES USING DEEP LEARNING.  
THESIS ADVISOR : ASSOC. PROF. KITTISAK KERDPRASOP, Ph.D.,  
146 PP.

FOREX/BINARY OPTION TRADES/LONG SHORT-TERMMEMORY/  
CONVOLUTIONAL NUERAL NETWORK/DEEP LEARNING

Foreign Exchange or Forex is a high-liquidity market that attracts many investors to invest in this market. With the investment value of over five trillion US dollars per day makes Forex being the largest financial market in the world. Nowadays, the brokers have used the reference price of various currency pairs in the Forex, Cryptocurrency, and Stock Price to create a new type of speculative investment called Binary Options. In the past, investors used the Price Action theory and Technical Indicators as a decision-making tool for both speculative investments. Nonetheless, since the values of those technical indicators are constantly changing, this leads to the low accuracy of the predictions and the difficulty to use them to make profits in real-world trading. This causes the invention and development of models for predicting the direction of price movements using artificial intelligence theories, such as Machine Learning and Deep Learning. The created models created using these theories are able to accurately and efficiently predict the direction of the price movement in the Forex market. However, investment in Binary Options differs from Forex in terms of profit and loss calculations and investment timing. There is no time limit for investing in Forex while investing in Binary Options, the investors must specify the duration of

each investment ticket. This makes the existing models unsuitable for investors in Binary Options. Therefore, this research proposes the development of a powerful decision-making tool for investors to invest in Binary Options using Deep Learning. Moreover, this research presents trading and cut-loss strategies, which are particularly suitable for Binary Options trading. The tools and strategies presented in this research have been tested and proven to be profitable for investors in real-world trading in Binary Options.



School of Computer Engineering

Academic Year 2019

Student's Signature

วิมล นนทสิน

Advisor's Signature

ดร. นนทสิน

## กิตติกรรมประกาศ

วิทยานิพนธ์นี้สำเร็จลุล่วงด้วยดี ผู้วิจัยขอกราบขอบพระคุณ บุคคล และกลุ่มบุคคลต่าง ๆ ที่กรุณาให้คำปรึกษา แนะนำ ช่วยเหลือ อย่างดียิ่ง ทั้งในด้านวิชาการ และด้านการดำเนินงานวิจัย อาทิเช่น

- รองศาสตราจารย์ ดร.กิตติศักดิ์ เกิดประสพ อาจารย์ที่ปรึกษาวิทยานิพนธ์
- รองศาสตราจารย์ ดร.นิตยา เกิดประสพ, ผู้ช่วยศาสตราจารย์ ดร.พิชโยทัย มัทธนาภีวัฒน์, อาจารย์ ดร.ศรัญญา กาญจนวัฒนา และอาจารย์ ดร.สุภาพร บุญฤทธิ์ อาจารย์ประจำสาขาวิชาวิศวกรรมคอมพิวเตอร์ สำนักวิชาวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี ซึ่งเป็นผู้ให้คำปรึกษาในการดำเนินการวิจัย
- ดร.ประกายคอย ดิษยบุตร ที่ให้กำลังใจและให้คำปรึกษามาโดยตลอด
- นายอนุพงษ์ บรรจงการ และนางสาวอนุสรรา หิรัญนากุล เพื่อร่วมเรียนในระดับปริญญาเอก ที่คอยให้กำลังใจและให้คำปรึกษาในการดำเนินงานวิจัยมาโดยตลอด
- นายปิยพงศ์ หนูทอง รุ่นพี่สาขาสาขาวิชาวิศวกรรมคอมพิวเตอร์ สำนักวิชาวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี ที่คอยให้คำปรึกษา และเป็นผู้ร่วมทดสอบประสิทธิภาพของเครื่องมือและกลยุทธต่าง ๆ ที่ได้นำเสนอในงานวิจัย
- ขอขอบพระคุณกระทรวงวิทยาศาสตร์และเทคโนโลยี (สวทช.) ที่สนับสนุนทุนการศึกษาและทุนในการทำวิจัย
- ขอขอบพระคุณมหาวิทยาลัยราชภัฏศรีสะเกษ ที่ให้โอกาสได้ลาศึกษาต่อในระดับปริญญาเอก

สุดท้ายนี้ ขอกราบขอบพระคุณบิดา มารดา และบุคคลในครอบครัว ที่ให้การเลี้ยงดูอบรมส่งเสริมด้านการศึกษาเป็นอย่างดีตลอดมา จนทำให้ผู้วิจัยประสบความสำเร็จในชีวิตตลอดมา

วรรณะ พงษ์เสนา

# สารบัญ

หน้า

บทคัดย่อ (ภาษาไทย).....	ก
บทคัดย่อ (ภาษาอังกฤษ).....	ข
กิตติกรรมประกาศ.....	ง
สารบัญ.....	จ
สารบัญตาราง.....	ฉ
สารบัญรูป.....	ฎ

## บทที่

<b>1</b>	<b>บทนำ.....</b>	<b>1</b>
1.1	ความสำคัญและที่มาของปัญหาการวิจัย.....	1
1.2	วัตถุประสงค์ของการวิจัย.....	5
1.3	ขอบเขตของการวิจัย.....	5
1.4	ประโยชน์ที่ได้รับ.....	6
<b>2</b>	<b>ปริทัศน์วรรณกรรมและงานวิจัยที่เกี่ยวข้อง.....</b>	<b>8</b>
2.1	ข้อมูลแบบอนุกรมเวลา.....	8
2.1.1	ลักษณะของข้อมูลแบบอนุกรมเวลา.....	8
2.1.2	ข้อมูลย้อนหลังของการแลกเปลี่ยนเงินตราต่างประเทศ.....	10
2.1.3	การลงทุนในตลาดการแลกเปลี่ยนเงินตราต่างประเทศ.....	11
2.1.4	การซื้อขายตัวเลือกไบนารี.....	12
2.2	การทำนายข้อมูลทางการเงินแบบอนุกรมเวลา.....	13
2.3	ตัวชี้วัดทางเทคนิค.....	14
2.3.1	ตัวชี้วัดทางเทคนิคแบบโมเมนตัม.....	14
2.3.2	ตัวชี้วัดทางเทคนิคแบบความผันผวน.....	14
2.3.3	ตัวชี้วัดทางเทคนิคแบบแนวโน้มหรือทิศทาง.....	15
2.3.4	ตัวชี้วัดทางเทคนิคแบบปริมาณ.....	15
2.4	โมเดลการทำนายโดยใช้หลักการเรียนรู้ของเครื่อง.....	15



## สารบัญ (ต่อ)

หน้า

2.4.1	เครื่องเวกเตอร์สนับสนุน .....	15
2.4.2	โครงข่ายประสาทเทียม .....	19
2.5	โมเดลการทำนายโดยใช้หลักการเรียนรู้เชิงลึก .....	24
2.5.1	โครงข่ายประสาทเทียมคอนโวลูชัน .....	24
2.5.2	โครงข่ายประสาทเทียมแบบวนซ้ำ .....	31
2.5.3	หน่วยความจำระยะสั้นระยะยาว .....	36
2.6	ค่าเฉลี่ยเคลื่อนที่ .....	39
2.6.1	ค่าเฉลี่ยเคลื่อนที่อย่างง่าย .....	39
2.6.2	ค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนัก .....	40
2.6.3	ค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนักซับซ้อน .....	40
2.7	มาตรวัดประสิทธิภาพของโมเดล .....	41
2.7.1	ความแม่นยำโดยรวม .....	41
2.7.2	ความแม่นยำที่สนใจเฉพาะส่วนที่ทำนาย .....	41
2.7.3	ค่าระลอกหรือความครอบคลุมของการทำนาย .....	42
2.7.4	ค่าเฉลี่ยระหว่าง Precision และ Recall .....	42
2.8	งานวิจัยที่เกี่ยวข้อง .....	42
<b>3</b>	<b>วิธีดำเนินงานวิจัย .....</b>	<b>52</b>
3.1	กรอบแนวคิดงานวิจัย .....	52
3.2	วิธีดำเนินงานวิจัย .....	54
3.2.1	การเตรียมข้อมูล การแปลงข้อมูลและการกำหนดคำนิยามให้กับข้อมูล .....	55
3.2.2	การพัฒนาและการเพิ่มประสิทธิภาพโมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไป .....	61
3.2.3	กลยุทธ์สำหรับการลงทุนในตัวเลือกไบนารี .....	76
3.2.4	การวัดประสิทธิภาพด้านการเงินของโมเดลในการซื้อขายตัวเลือกไบนารี .....	80

## สารบัญ (ต่อ)

หน้า

3.3	เครื่องมือที่ใช้สำหรับการวิจัย.....	81
<b>4</b>	<b>ผลการศึกษาและการวิเคราะห์ผล.....</b>	<b>82</b>
4.1	ผลการทดสอบประสิทธิภาพโมเดลพื้นฐานสำหรับทำนายแนวโน้มการเปลี่ยนแปลง ของราคาอ้างอิงในช่วงเวลาถัดไป.....	82
4.2	ผลการทดสอบประสิทธิภาพโมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของ ราคาอ้างอิงในช่วงเวลาถัดไปเมื่อผ่านกระบวนการเพิ่มประสิทธิภาพโดยการกำหนด ค่าพารามิเตอร์ต่าง ๆ ให้เหมาะสม.....	84
4.2.1	การกำหนดความยาวของข้อมูลอินพุตที่เหมาะสมสำหรับ การสร้างโมเดล.....	85
4.2.2	การกำหนดจำนวนข้อมูลที่เหมาะสมสำหรับการเรียนรู้ของโมเดล.....	86
4.2.3	การกำหนดระยะเวลาที่เหมาะสมเพื่อการปรับปรุงโมเดลให้ทันสมัย.....	87
4.3	ผลการทดสอบประสิทธิภาพโมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของ ราคาอ้างอิงในช่วงเวลาถัดไปเมื่อผ่านกระบวนการเพิ่มประสิทธิภาพโดยการใช้ ผู้เชี่ยวชาญในการจำแนกข้อมูลตามลักษณะแนวโน้มการเคลื่อนไหวของราคา แต่ละประเภท.....	90
4.4	การพัฒนาโมเดลสำหรับใช้เป็นเครื่องมืออัตโนมัติในการจำแนกประเภทแนวโน้ม การเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนดโดยใช้อัลกอริทึมทางด้าน ปัญญาประดิษฐ์.....	96
4.5	การเปรียบเทียบประสิทธิภาพโมเดลสำหรับการทำนายแนวโน้มการเปลี่ยนแปลง ของราคาอ้างอิงในช่วงเวลาถัดไปที่ถูกสร้างขึ้นจากข้อมูลที่ผ่านการคัดแยกโดยใช้ ปัญญาประดิษฐ์และหลักการวิเคราะห์ทางเทคนิค.....	97
4.6	ผลการวัดประสิทธิภาพด้านการเงินในการซื้อขายตัวเลือกไปนารี.....	103
4.6.1	ผลการทดสอบแบบย้อนกลับ.....	103
4.6.2	ผลการทดสอบแบบไปข้างหน้า.....	116
4.7	การอภิปรายผลการทดลอง.....	118

## สารบัญ (ต่อ)

หน้า

5 ผลการศึกษาและการวิเคราะห์ผล.....	122
5.1 สรุปผลการวิจัย .....	122
5.2 ข้อเสนอแนะ .....	129
รายการอ้างอิง .....	131
ภาคผนวก บทความวิจัยที่ได้รับการตีพิมพ์เผยแพร่ .....	140
ประวัติผู้เขียน .....	146



## สารบัญตาราง

ตารางที่		หน้า
2.1	ตัวอย่างข้อมูลย้อนหลังของการแลกเปลี่ยนเงินตราต่างประเทศของคู่เงิน EURUSD .....	11
2.2	ลำดับของจำนวนหลักของหน่วยต่าง ๆ แยกตามประเภทของบัญชีเทรด.....	12
2.3	ตาราง Confusion Matrix.....	43
2.4	อธิบายรายละเอียดตัวอย่างที่ปรากฏในการทบทวนวรรณกรรม.....	44
2.5	งานวิจัยต่าง ๆ ที่เกี่ยวข้องกับการวิเคราะห์ข้อมูลตลาดซื้อขายเงินตราต่างประเทศและการซื้อขายตัวเลือกไบนารี (เรียงตามลำดับเหตุการณ์).....	46
3.1	ตารางแสดงจำนวนเงินที่ใช้ลงทุนและผลกำไรตอบแทนในการซื้อขายแต่ละรอบ .....	78
4.1	สรุปผลการทดสอบประสิทธิภาพ โมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไปโดยใช้มาตรวัดต่าง ๆ .....	84
4.2	สรุปผลการทดสอบประสิทธิภาพ โมเดลที่มีการกำหนดความยาวของข้อมูลนำเข้าที่เหมาะสมสำหรับการสร้างโมเดล .....	85
4.3	สรุปผลการทดสอบประสิทธิภาพ โมเดลที่มีการกำหนดจำนวนข้อมูลสำหรับการเรียนรู้ของโมเดลที่หลากหลาย.....	86
4.4	สรุปผลการทดสอบประสิทธิภาพ โมเดลเพื่อการหาระยะเวลาที่เหมาะสมสำหรับการปรับปรุงโมเดลให้ทันสมัย.....	89
4.5	ผลการทดสอบประสิทธิภาพโมเดลสำหรับทำนายข้อมูลที่มีลักษณะเป็นแนวโน้มแบบขาขึ้นอย่างต่อเนื่อง (LSTM <sub>UP</sub> ) .....	94
4.6	ผลการทดสอบประสิทธิภาพโมเดลสำหรับทำนายข้อมูลที่มีลักษณะเป็นแนวโน้มแบบผันผวน (LSTM <sub>SW</sub> ).....	94
4.7	ผลการทดสอบประสิทธิภาพโมเดลสำหรับทำนายข้อมูลที่มีลักษณะเป็นแนวโน้มแบบผันผวน (LSTM <sub>DN</sub> ).....	95
4.8	ผลลัพธ์การเปรียบเทียบประสิทธิภาพความแม่นยำในการทำนายรายวันของโมเดล LSTM <sub>UP</sub> + TCM <sub>CNN</sub> และ โมเดล LSTM <sub>UP</sub> + TCM <sub>EMA</sub> .....	100
4.9	ผลลัพธ์การเปรียบเทียบประสิทธิภาพในการทำนายรายวันของโมเดล LSTM <sub>SW</sub> + TCM <sub>CNN</sub> และ โมเดล LSTM <sub>SW</sub> + TCM <sub>EMA</sub> .....	101

## สารบัญตาราง (ต่อ)

ตารางที่	หน้า
4.10 ผลลัพธ์การเปรียบเทียบประสิทธิภาพในการทำนายรายวันของโมเดล LSTM <sub>DN</sub> + TCM <sub>CNN</sub> และ โมเดล LSTM <sub>DN</sub> + TCM <sub>EMA</sub> .....	102
4.11 ผลลัพธ์การเปรียบเทียบประสิทธิภาพในการทำนายรายเดือนของโมเดล LSTM ที่ใช้ข้อมูลในการเรียนรู้จากการจำแนกของ TCM <sub>CNN</sub> และ TCM <sub>EMA</sub> .....	103
4.12 สรุปผลการทดสอบประสิทธิภาพโมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลง ของราคาอ้างอิงในช่วงเวลาถัดไปโดยใช้ค่าจากมาตรวัดต่าง ๆ ในเดือน มกราคม พ.ศ. 2562 .....	105
4.13 จำนวนครั้งที่เทรดชนะ ณ คำสั่งซื้อต่าง ๆ และจำนวนครั้งของการตัดขาดทุนของ การจำลองการเทรดในเดือน มกราคม พ.ศ. 2562 .....	105
4.14 สรุปผลลัพธ์กำไรขาดทุนแต่ละวันของการทดสอบแบบย้อนกลับในเดือน มกราคม พ.ศ. 2562 .....	106
4.15 สรุปผลการทดสอบประสิทธิภาพโมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลง ของราคาอ้างอิงในช่วงเวลาถัดไปโดยใช้ค่าจากมาตรวัดต่าง ๆ ในเดือน กุมภาพันธ์ พ.ศ. 2562 .....	108
4.16 จำนวนครั้งที่เทรดชนะ ณ คำสั่งซื้อต่าง ๆ และจำนวนครั้งของการตัดขาดทุนของการจำลอง การเทรดในเดือน กุมภาพันธ์ พ.ศ. 2562 .....	108
4.17 สรุปผลลัพธ์กำไรขาดทุนแต่ละวันของการทดสอบแบบย้อนกลับในเดือน กุมภาพันธ์ พ.ศ. 2562 .....	109
4.18 สรุปผลการทดสอบประสิทธิภาพโมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลง ของราคาอ้างอิงในช่วงเวลาถัดไปโดยใช้ค่าจากมาตรวัดต่าง ๆ ในเดือน มีนาคม พ.ศ. 2562 .....	111
4.19 จำนวนครั้งที่เทรดชนะ ณ คำสั่งซื้อต่าง ๆ และจำนวนครั้งของการตัดขาดทุนของการจำลอง การเทรดในเดือน มีนาคม พ.ศ. 2562 .....	111
4.20 สรุปผลลัพธ์กำไรขาดทุนแต่ละวันของการทดสอบแบบย้อนกลับในเดือน มีนาคม พ.ศ. 2562 .....	112

## สารบัญตาราง (ต่อ)

ตารางที่	หน้า
4.21	สรุปผลการทดสอบประสิทธิภาพโมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของ ราคาอ้างอิงในช่วงเวลาถัดไปโดยใช้ค่าจากมาตรวัดต่าง ๆ เดือน เมษายน พ.ศ. 2562 .....114
4.22	จำนวนครั้งที่เทรดชนะ ณ คำสั่งซื้อต่าง ๆ และจำนวนครั้งของการตัดขาดทุนของการจำลอง การเทรดในเดือน เมษายน พ.ศ. 2562 .....114
4.23	สรุปผลลัพธ์กำไรขาดทุนแต่ละวันของการทดสอบแบบย้อนกลับในเดือน เมษายน พ.ศ. 2562 .....115
4.24	สรุปผลลัพธ์กำไรขาดทุนแต่ละวันของการทดสอบแบบไปข้างหน้าเริ่มตั้งแต่วันที่ 25 มิถุนายน ถึงวันที่ 31 กรกฎาคม พ.ศ. 2562 .....117
5.1	ผลสรุปประสิทธิภาพความแม่นยำของโมเดลที่ได้รับการพัฒนาและเพิ่มประสิทธิภาพ ด้วยวิธีการต่าง ๆ ในงานวิจัยนี้ .....124
5.2	สรุปผลการทดสอบประสิทธิภาพโมเดลสำหรับใช้เป็นเครื่องมืออัตโนมัติในการจำแนก ประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนดโดยใช้อัลกอริทึม ทางด้านปัญญาประดิษฐ์.....126
5.3	สรุปผลลัพธ์การเปรียบเทียบประสิทธิภาพความแม่นยำในการทำนายของโมเดล LSTM ที่ใช้ข้อมูลในการเรียนรู้จากการจำแนกโดยใช้ผู้เชี่ยวชาญ TCM <sub>CNN</sub> และ TCM <sub>EMA</sub> .....127
5.4	สรุปความแม่นยำของโมเดลที่ได้รับการพัฒนาและเพิ่มประสิทธิภาพด้วยวิธีการต่าง ๆ ที่นำเสนอในงานวิจัยนี้ด้วยการทดสอบแบบย้อนกลับ .....128
5.5	สรุปความแม่นยำของโมเดลที่ได้รับการพัฒนาและเพิ่มประสิทธิภาพด้วยวิธีการต่าง ๆ ที่ นำเสนอในงานวิจัยนี้ด้วยการทดสอบแบบไปข้างหน้า.....128

## สารบัญรูป

รูปที่	หน้า
2.1 ตัวอย่างกราฟเส้นที่แสดงชุดข้อมูลแบบอนุกรมเวลาของการซื้อขายแลกเปลี่ยนเงินตราต่างประเทศสำหรับคู่เงิน EURUSD.....	9
2.2 การแบ่งแยกข้อมูลแบบเชิงเส้น (ก) และไม่เป็นเชิงเส้น (ข).....	16
2.3 ตัวอย่างการแบ่งข้อมูลออกเป็น 2 กลุ่มของ SVM โดยใช้เส้น Maximum-Margin Hyperplane.....	17
2.4 หลักการทำงานของฟังก์ชัน Kernel .....	18
2.5 หลักการทำงานของโครงข่ายประสาทเทียม .....	19
2.6 ตัวอย่างโครงข่ายประสาทเทียมอย่างง่าย .....	20
2.7 เซลล์ประสาททางชีวภาพ (ก) เปรียบเทียบกับเซลล์ประสาทเทียม (ข).....	21
2.8 Topology ของโครงข่ายประสาทเทียม (ก) Feed-forward Neural Network (FNN) และ (ข) Recurrent Neural Network (RNN).....	23
2.9 ตัวอย่างลักษณะโครงสร้างของโครงข่ายประสาทแบบคอนโวลูชัน .....	24
2.10 ตัวอย่างผลการทำนายของโครงข่ายประสาทแบบคอนโวลูชัน.....	25
2.11 พื้นที่ย่อยที่มีคุณลักษณะ (Feature) ที่สำคัญอยู่ในบริเวณนั้น .....	25
2.12 ตัวอย่างของ Filter ที่มีขนาด 3×3 สำหรับหาเส้นตรงทแยงสีขาว.....	26
2.13 รูปทางซ้ายคือ Filter ที่เลื่อนไปบนรูปภาพอินพุตทีละ 1 พิกเซล ส่วนรูปทางด้านขวาคือผลลัพธ์การคำนวณซึ่งออกมาเป็น Feature Map .....	27
2.14 ตัวอย่างของการสร้าง Feature Map โดยกำหนดค่า Stride เท่ากับ 2.....	28
2.15 ตัวอย่างการสร้าง Feature Map ซึ่งมีการกำหนดค่า Stride และ Padding เท่ากับ 1.....	29
2.16 ตัวอย่างภาพที่เป็นวัตถุเดียวกันแต่ถูกย่อขนาดให้มีขนาดเล็กลง .....	30
2.17 ตัวอย่างรูปภาพแมว 2 รูปที่ใช้เทคนิคการคัดแยกแบบหยาบและละเอียด .....	30
2.18 ตัวอย่าง Max Pooling ที่กำหนด Filter ขนาด 2×2 พิกเซลและค่า Stride เท่ากับ 2.....	31
2.19 โครงสร้างของโครงข่ายประสาทแบบไปข้างหน้า.....	32
2.20 ความแตกต่างระหว่างข้อมูลที่ไหลในโครงข่ายประสาทเทียมแบบวนซ้ำ (ก) และโครงข่ายประสาทเทียมแบบไปข้างหน้า (ข).....	33
2.21 การทำงานของ Forward Propagation และ Backward Propagation.....	34

## สารบัญรูป (ต่อ)

รูปที่	หน้า
2.22	โครงข่ายประสาทแบบวนซ้ำที่ถูกลากออก .....35
2.23	โครงสร้างของโครงข่ายความจำระยะสั้นระยะยาว .....36
2.24	โครงสร้างของโมเดล LSTM สำหรับการทำนายลำดับแบบหนึ่งต่อหนึ่ง .....37
2.25	โครงสร้างของโมเดล LSTM สำหรับการทำนายลำดับแบบหนึ่งต่อหลาย .....38
2.26	โครงสร้างของโมเดล LSTM สำหรับการทำนายลำดับแบบหลายต่อหนึ่ง .....38
2.27	โครงสร้างของโมเดล LSTM สำหรับการทำนายลำดับแบบหลายต่อหลาย .....39
3.1	กระบวนการดำเนินงานวิจัย .....54
3.2	ตัวอย่างข้อมูลย้อนหลังการซื้อขายเงินตราต่างประเทศของคู่เงิน EURUSD คาบเวลา ราย 5 นาที.....55
3.3	ตัวอย่างชุดข้อมูลที่เพิ่มคอลัมน์สำหรับระบุทิศทางเคลื่อนไหวของราคา.....56
3.4	ตัวอย่างของขั้นตอนการแปลงข้อมูลสำหรับใช้เป็นข้อมูลนำเข้าเพื่อสร้างโมเดลสำหรับ ทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาที่ถัดไป .....57
3.5	การใช้หลักการหน้าต่างบานเลื่อนในการตัดข้อมูลออกมาเป็นชุดข้อมูลย่อย ๆ .....58
3.6	ตัวอย่างชุดข้อมูลที่ถูกตัดออกมาให้อยู่ในรูปแบบชุดข้อมูลย่อย ๆ โดยใช้หลักการ หน้าต่างบานเลื่อน .....58
3.7	ตัวอย่างข้อมูลรูปภาพที่สร้างขึ้นจากชุดข้อมูลย่อย ๆ หลังจากการใช้หลักการหน้าต่าง บานเลื่อน .....59
3.8	ตัวอย่างของรูปภาพที่ถูกกำหนดคลาสเป้าหมายโดยผู้เชี่ยวชาญ .....60
3.9	ตัวอย่างข้อมูลอนุกรมเมื่อมีการกำหนดคลาสเป้าหมายในส่วนของคุณค่า Trend.....61
3.10	ตัวอย่างรูปแบบของปัญหาที่ต้องการทำนายโดยใช้อัลกอริทึม LSTM .....62
3.11	กระบวนการพัฒนาโมเดล LSTM พื้นฐาน .....63
3.12	ตัวอย่างภาพแนวโน้มความเคลื่อนไหวของราคาสามารถทั้ง 3 ประเภทได้แก่ Upward Trend, Sideways และ Downward Trend .....65



## สารบัญรูป (ต่อ)

รูปที่	หน้า
3.13	กระบวนการวิจัยและขั้นตอนของการเพิ่มประสิทธิภาพให้กับโมเดล โดยการจำแนกข้อมูลและสร้างโมเดลตามลักษณะแนวโน้มการเคลื่อนไหวของราคาแต่ละประเภท.....67
3.14	กระบวนการพัฒนาโมเดลสำหรับการจำแนกประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนดโดยใช้โครงข่ายประสาทแบบคอนโวลูชัน.....69
3.15	การพัฒนาโมเดลสำหรับการจำแนกประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนดโดยใช้โครงข่ายประสาทแบบคอนโวลูชัน .....70
3.16	กระบวนการพัฒนาโมเดลบนพื้นฐานของทฤษฎีการเรียนรู้ของเครื่อง.....71
3.17	กระบวนการพัฒนาและทดสอบประสิทธิภาพโมเดลสำหรับการทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไปโดยการใช้โมเดล TCM <sub>CNN</sub> ในการคัดแยกข้อมูลแทนที่การใช้ผู้เชี่ยวชาญ.....72
3.18	กระบวนการพัฒนาและทดสอบประสิทธิภาพโมเดลสำหรับการทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไปโดยการใช้โมเดล TCM <sub>EMA</sub> ในการคัดแยกข้อมูลแทนที่การใช้ผู้เชี่ยวชาญ.....75
3.19	ขั้นตอนในการกำหนดสัญญาณในการซื้อขายตัวเลือกไปนารี .....77
4.1	Confusion Matrix แสดงผลการทดสอบประสิทธิภาพโมเดลพื้นฐานสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไป .....83
4.2	กราฟสรุปผลการทดสอบประสิทธิภาพโมเดลเพื่อการหาระยะเวลาที่เหมาะสมเพื่อทำการปรับปรุงโมเดลให้ทันสมัย .....90
4.3	ตัวอย่างรูปภาพข้อมูลประเภทแนวโน้มแบบขาขึ้นอย่างต่อเนื่องที่ถูกจำแนกโดยผู้เชี่ยวชาญ .....91
4.4	ตัวอย่างรูปภาพข้อมูลประเภทแนวโน้มแบบผันผวนที่ถูกจำแนกโดยผู้เชี่ยวชาญ .....91
4.5	ตัวอย่างรูปภาพข้อมูลประเภทแนวโน้มแบบขาลงอย่างต่อเนื่องที่ถูกจำแนกโดยผู้เชี่ยวชาญ .....92
4.6	ผลการทดสอบประสิทธิภาพโมเดลสำหรับใช้เป็นเครื่องมืออัตโนมัติในการจำแนกประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนดโดยใช้อัลกอริทึมทางด้านปัญญาประดิษฐ์.....96

## สารบัญรูป (ต่อ)

รูปที่	หน้า
4.7	Confusion Matrix แสดงผลการทดสอบแบบย้อนกลับในเดือน มกราคม พ.ศ. 2562.....104
4.8	กราฟแสดงจำนวนเงินคงเหลือจากการทดสอบแบบย้อนกลับแต่ละวันในเดือน มกราคม พ.ศ. 2562.....106
4.9	Confusion Matrix แสดงผลการทดสอบแบบย้อนกลับในเดือน กุมภาพันธ์ พ.ศ. 2562 ...107
4.10	กราฟแสดงจำนวนเงินคงเหลือจากการทดสอบแบบย้อนกลับแต่ละวันในเดือน กุมภาพันธ์ พ.ศ. 2562 .....109
4.11	Confusion Matrix แสดงผลการทดสอบแบบย้อนกลับในเดือน มีนาคม พ.ศ. 2562 .....110
4.12	กราฟแสดงจำนวนเงินคงเหลือจากการทดสอบแบบย้อนกลับแต่ละวันในเดือน มีนาคม พ.ศ. 2562 .....112
4.13	Confusion Matrix แสดงผลการทดสอบในเดือน เมษายน พ.ศ. 2562.....113
4.14	กราฟแสดงจำนวนเงินคงเหลือจากการทดสอบแบบย้อนกลับแต่ละวันเดือน เมษายน พ.ศ. 2562.....114
4.15	ผลการวัดประสิทธิภาพด้านการเงินของโมเดลในการซื้อขายตัวเลือกไปนารีแบบไป ข้างหน้า.....121

# บทที่ 1

## บทนำ

### 1.1 ความสำคัญและที่มาของปัญหาการวิจัย

การซื้อขายแลกเปลี่ยนเงินตราต่างประเทศหรือฟอเร็กซ์ (Foreign Exchange, Forex) เป็นตลาดที่มีการซื้อขายแลกเปลี่ยนสกุลเงินต่าง ๆ จากทั่วโลกและยังเป็นตลาดทางการเงินที่มีขนาดใหญ่ที่สุดในโลก (Pongsena et al., 2018) นับตั้งแต่ตลาดการลงทุนนี้ก่อตั้งขึ้นมีนักลงทุนจำนวนมากเข้ามาลงทุนในตลาดแห่งนี้ ทำให้มูลค่าการซื้อขายค่าเงินในตลาดแห่งนี้สูงถึงมากกว่าวันละ 5 ล้านล้านดอลลาร์สหรัฐฯ (Jacque, 2013) ในตลาดฟอเร็กซ์คู่ของสกุลเงินที่ถูกนำมาซื้อขายแลกเปลี่ยนสองสกุลจะถูกกำหนดเป็นราคาอ้างอิง (Quotation) ซึ่งค่าราคาอ้างอิงนี้แสดงถึงความสัมพันธ์ระหว่างสกุลเงินหลัก (Base Currency) และสกุลเงินที่ใช้เป็นข้อมูลอ้างอิงเรียกว่าสกุลเงินที่เคาน์เตอร์ (Counter Currency) (FX Accumulator, 2015) คู่สกุลเงินทั้งหมดในตลาดฟอเร็กซ์ได้รับการกำหนดสัญลักษณ์อย่างเป็นทางการโดยรหัส ISO ของสกุลเงินหลักและสกุลเงินที่เคาน์เตอร์ ตัวอย่างเช่น สัญลักษณ์ “EURUSD” เป็นสัญลักษณ์ของคู่สกุลเงินยูโรเทียบกับสกุลเงินดอลลาร์สหรัฐฯ โดยที่ “EUR” แสดงถึงสกุลเงินยูโร และ “USD” แสดงถึงสกุลเงินดอลลาร์สหรัฐฯ ในการพิจารณาราคาอ้างอิงของคู่สกุลเงิน EURUSD ที่มีมูลค่าการซื้อขายอยู่ที่ 1.5000 นั้นหมายความว่า 1 ยูโร สามารถแลกเปลี่ยนเป็นเงินดอลลาร์สหรัฐฯ ได้ 1.5 ดอลลาร์ และหากราคาอ้างอิงของคู่สกุลเงิน EURUSD เพิ่มขึ้นจาก 1.5000 เป็น 1.6000 นั้นหมายถึงมูลค่าสัมพัทธ์ของสกุลเงินยูโรเพิ่มขึ้น ทั้งนี้อาจเป็นเพราะว่าค่าของสกุลเงินยูโรมีความแข็งแกร่งขึ้นหรือค่าของสกุลเงินดอลลาร์สหรัฐฯอ่อนค่าลงหรืออาจเป็นไปได้ทั้งสองกรณี ในทางกลับกันหากราคาอ้างอิงของคู่สกุลเงิน EURUSD ลดลงจาก 1.5000 เป็น 1.4000 หมายถึงมูลค่าสัมพัทธ์ของสกุลเงินยูโรลดลง ซึ่งอาจเป็นเพราะค่าของสกุลเงินยูโรอ่อนค่าลงหรือค่าของสกุลเงินดอลลาร์สหรัฐฯแข็งค่าขึ้นหรืออาจเป็นไปได้ทั้งสองกรณี

การลงทุนในตลาดฟอเร็กซ์จะเป็นการลงทุนแบบเก็งกำไร ซึ่งมีความคล้ายคลึงกับการลงทุนในตลาดฟิวเจอร์ ที่ซึ่งนักลงทุนสามารถทำกำไรจากการซื้อขายได้ไม่ว่าราคาอ้างอิงของคู่สกุลเงินที่สนใจจะมีค่าเพิ่มขึ้นหรือลดลงก็ตามแตกต่างจากการลงทุนในตลาดหลักทรัพย์ที่นักลงทุนจะสามารถขายทำกำไรได้ก็ต่อเมื่อหลักทรัพย์ที่ลงทุนไปนั้นมีมูลค่าเพิ่มมากขึ้น ซึ่งการลงทุนในตลาดฟอเร็กซ์นั้น นักลงทุนจะเปิดคำสั่งซื้อ (Long หรือ Buy) ราคาอ้างอิงของคู่สกุลเงินที่

สนใจ หากเชื่อว่าราคาอ้างอิงของกลุ่มเงินจะมีค่าเพิ่มมากขึ้น ในทางตรงกันข้ามนักลงทุนจะส่งคำสั่งขาย (Short หรือ Sell) กลุ่มเงินที่สนใจ หากมั่นใจว่าราคาอ้างอิงของกลุ่มเงินนั้น ๆ จะมีค่าลดลง โดยที่การได้กำไรหรือขาดทุน ซึ่งเกิดจากคำสั่งซื้อหรือขายนั้น อธิบายได้ด้วยตัวอย่างเช่น หากนักลงทุนกำหนดค่า Lot เท่ากับ 0.1 (ลงทุน 1 ดอลลาร์ ต่อการเคลื่อนไหวของอัตราอ้างอิง 1 จุด) ในบัญชีซื้อขายแบบ Standard ถ้านักลงทุนส่งคำสั่งซื้อราคาอ้างอิงของกลุ่มเงิน EURUSD ที่ 1.0500 และเมื่อราคาอ้างอิงสูงไปที่ 1.0550 หมายความว่านักลงทุนได้ทำกำไรมา 50 จุด (pips) นักลงทุนจะได้กำไร 50 ดอลลาร์ แต่ในทางกลับกันหากราคาอ้างอิงลดลงไปที่ 1.0450 หมายความว่านักลงทุนขาดทุนไปจำนวน 50 จุด ซึ่งคิดเป็นจำนวนเงิน 50 ดอลลาร์

การซื้อขายตัวเลือกไบนารี (Binary Options) เป็นการลงทุนแบบเก็งกำไรที่มีหลักการคล้ายคลึงกับการลงทุนในตลาดฟอเร็กซ์ โดยที่ตัวเลือกไบนารีนั้นเป็นการเก็งกำไรโดยการเปิดโอกาสให้นำกราฟของราคาอ้างอิงจากหลาย ๆ แหล่งมาให้นักลงทุนเลือกใช้ในการลงทุนไม่ว่าจะเป็นราคาอ้างอิงของกลุ่มเงินในตลาดฟอเร็กซ์ หรือราคาหุ้นของบริษัทต่าง ๆ ทั่วโลก รวมไปถึงสกุลเงินดิจิทัลต่าง ๆ นักลงทุนในตัวเลือกไบนารีจะส่งคำสั่งเพื่อเก็งกำไรว่าราคาอ้างอิงของสิ่งที่สนใจจะเพิ่มขึ้นหรือลดลงภายในระยะเวลาที่นักลงทุนสามารถกำหนดเองได้ระหว่าง 1 นาที ไปจนถึง 1 วัน ในการลงทุนนั้นมีอัตรากำไร หรือขาดทุนอยู่ที่ประมาณ 0.85 ต่อ 1 ซึ่งหมายความว่าหากนักลงทุนวางเงินเพื่อเก็งกำไรจำนวน 100 บาท เมื่อเก็งถูกว่าราคาอ้างอิงจะเพิ่มขึ้นหรือลดลงไม่ว่าจะเท่าไรภายในเวลานี้ก็จะได้กำไร 85 บาท แต่ถ้าหากเก็งผิดจะขาดทุนจำนวน 100 บาท

ตั้งแต่ฟอเร็กซ์และตัวเลือกไบนารีกลายเป็นตลาดการเงินที่สำคัญของโลก นักวิจัยจำนวนมากได้ทำการคิดค้นและพัฒนาวิธีการรวมถึงกลยุทธ์เพื่อใช้ในการวิเคราะห์และการคาดการณ์การเคลื่อนไหวของราคาอ้างอิงของกลุ่มเงินในตลาด ซึ่งวิธีการดั้งเดิมที่นักลงทุนนิยมใช้คือการสังเกตรูปแบบของกราฟเพื่อวิเคราะห์ความเคลื่อนไหวของราคา (Price Action) (Lequeux, 2007; Anand et al., 2003, pp. 134-145) นอกจากนี้การวิเคราะห์พื้นฐาน (Fundamental Analysis, FA) เป็นอีกวิธีการที่มุ่งเน้นไปที่ข้อมูลทางเศรษฐกิจและการเงินเช่น ข่าว (News) รายงานทางการเงิน (Financial Reports) ประกาศเศรษฐกิจ (Economic Announcements) ปัจจัยทางสังคมและการเมือง (Social and Political Factors) (Van Griensven, 1998; Abarbanell and Bushee, 1997) เป็นต้น นอกจากนี้ยังมีวิธีที่ได้รับความนิยมมากที่สุดจากนักลงทุนคือ การวิเคราะห์ทางเทคนิค (Technical Analysis, TA) ซึ่งใช้ตัวชี้วัดทางเทคนิค (Technical Indicators) (Lo et al., 2000, pp. 1705-1765) ร่วมกับการวิเคราะห์ความเคลื่อนไหวของราคาเพื่อศึกษาการเคลื่อนไหวของราคาและคาดการณ์ทิศทางของตลาดในอนาคต (Pee, 2001; Franses and Van Griensven, 1998) ถึงแม้ว่าการวิเคราะห์ทางเทคนิคเป็นวิธีที่ง่ายที่สุดสำหรับนักลงทุนในการมองเห็นภาพการเคลื่อนไหวของราคาอ้างอิง

ของคู่สกุลเงินที่นักลงทุนสนใจในตลาด แต่ทว่าเนื่องจากค่าของตัวชี้วัดทางเทคนิคเหล่านั้นมีการเปลี่ยนแปลงค่าอยู่ตลอดเวลาทำให้การใช้งานในสถานการณ์จริงนั้นทำได้ยาก

ในช่วงสองทศวรรษที่ผ่านมาปัญญาประดิษฐ์ (Artificial Intelligence, AI) เป็นความก้าวหน้าทางเทคโนโลยีการคำนวณ ได้ถูกนำมาประยุกต์ใช้อย่างกว้างขวางในหลากหลายด้าน โดยเฉพาะอย่างยิ่งในด้านการเงินและการลงทุน งานวิจัยด้านนี้ส่วนใหญ่มุ่งเน้นไปในแนวทางของการนำอัลกอริทึมทางปัญญาประดิษฐ์ด้านการเรียนรู้ของเครื่อง เช่น เครื่องเวกเตอร์สนับสนุน (Support Vector Machine, SVM) (de Brito et al., 2014, pp. 596-613, Di, 2014) โครงข่ายประสาทเทียม (Artificial Neural Network, ANN) (Meyer and Wien, 2015; Czekalski et al., 2015, pp. 322-328) หรือ โครงข่ายประสาทเทียมแบบวนซ้ำ (Recurrent Neural Network, RNN) (Moghaddam et al., 2016) มาประยุกต์ใช้เพื่อสร้างเป็น โมเดลสำหรับการทำนาย ซึ่งโมเดลเหล่านี้สามารถใช้เป็นเครื่องมือช่วยในการตัดสินใจสำหรับการลงทุนในตลาดฟอเร็กซ์หรือตัวเลือกโบนารีได้ ตัวอย่างเช่น ในปี ค.ศ. 2003 ถึง 2004 งานวิจัยของ Kamruzzaman และ Sarker (Kamruzzaman and Sarker, 2003a; Kamruzzaman and Sarker, 2003b; Kamruzzaman and Sarker, 2004a; Kamruzzaman and Sarker, 2004b; Kamruzzaman et al., 2003) สรุปว่าโมเดลบนพื้นฐานของอัลกอริทึม SVM และ ANN สำหรับการพัฒนาโมเดลโดยใช้อัลกอริทึม ANN นั้นใช้ข้อมูลจากตัวบ่งชี้ค่าเฉลี่ยเคลื่อนที่ (Moving Average, MA) จาก 7 สกุลเงินประกอบด้วย USD, GBP, JPY, SGD, NZD, CHF และ AUD เป็นข้อมูลอินพุตสำหรับการเรียนรู้และทดสอบประสิทธิภาพ ผลการวิจัยพบว่าโมเดล ANN ให้ประสิทธิภาพที่ดีกว่าเมื่อเทียบกับประสิทธิภาพของโมเดล ARIMA นอกจากนี้พวกเขายังทำการประเมินประสิทธิภาพของโมเดลที่พัฒนาโดยใช้อัลกอริทึม SVM เพื่อใช้ในการพยากรณ์อัตราแลกเปลี่ยนสกุลเงินต่าง ๆ เทียบกับสกุลเงิน AUD และตรวจสอบผลกระทบของฟังก์ชันเคอร์เนล (Kernel Function) ที่แตกต่างกันสามแบบคือ เชิงเส้น (Linear), พื้นฐานรัศมีพหุนาม (Polynomial Radial Basis) และฟังก์ชัน โค้ง (Curve Function) ผลการทดลองพบว่าโมเดล SVM ที่ใช้ฟังก์ชัน พื้นฐานรัศมีพหุนามให้ผลลัพธ์ที่ดีที่สุด บทสรุปของการวิจัยนี้คล้ายกับข้อสรุปในงานวิจัยของ Cao และคณะ (2005) ซึ่งระบุว่า การกำหนดค่าพารามิเตอร์มีผลกระทบอย่างมีนัยสำคัญต่อประสิทธิภาพการทำงานของโมเดล SVM หลังจากนั้นอีก 2 ปี Eng และคณะ (2008) รายงานหลักฐานเชิงประจักษ์ว่าปัจจัยพื้นฐานทางเศรษฐกิจมีความสำคัญต่อการเคลื่อนไหวของอัตราแลกเปลี่ยนในต่างประเทศ อย่างไรก็ตามความสัมพันธ์ที่ซ่อนอยู่ของปัจจัยเหล่านี้ไม่มีผลต่อประสิทธิภาพการทำนายของโมเดลที่พัฒนาบนพื้นฐานของอัลกอริทึม ANN แม้ว่าจะใช้ค่าเหล่านั้นเป็นอินพุตก็ตาม นอกจากนี้ Eng และทีมวิจัยของเขายังได้สรุปว่าการปรับปรุงโมเดลในทุกไตรมาสอาจส่งผลให้การทำนาย ANN มีความแม่นยำมากขึ้น

เนื่องจากข้อมูลย้อนหลังของการซื้อขายเงินตราต่างประเทศนั้นเป็นข้อมูลแบบอนุกรมเวลาดังนั้นงานวิจัยหลายงานได้ทำการพัฒนาโมเดลโดยใช้อัลกอริทึมที่เหมาะสมกับข้อมูลแบบอนุกรมเวลา โดยในปีค.ศ. 2014 Stankeviciene และคณะ (2014) ได้พัฒนาโมเดลโดยใช้อัลกอริทึมโครงข่ายประสาทเทียมแบบวนซ้ำ (Recurrent Neural Network, RNN) เป็นหนึ่งในอัลกอริทึมของการเรียนรู้ด้วยเครื่อง (Machine Learning) ที่เหมาะสำหรับการวิเคราะห์ข้อมูลอนุกรมเวลา ซึ่งใช้ข้อมูลราคาสูงสุดและต่ำสุดรายวันสำหรับการฝึกสอนและทดสอบประสิทธิภาพของโมเดล ผลการทดสอบแสดงให้เห็นว่าโมเดลไม่สามารถใช้ในการทำนายแนวโน้มในอนาคตได้แม่นยำ ดังนั้นพวกเขาจึงปรับเปลี่ยนรูปแบบโดยการแปลงข้อมูลจากต้นฉบับไปเป็นค่าเบี่ยงเบนมาตรฐาน (Standard Deviation) ความเบ้ (Skewness) และ ความโค้ง (Kurtosis) เพื่อใช้เป็นข้อมูลนำเข้าสำหรับการเรียนรู้ให้กับโมเดล ซึ่งผลการทดลองพบว่าหลังจากการปรับปรุงโมเดลของพวกเขาประสิทธิภาพเพิ่มขึ้นอย่างมีนัยสำคัญ อย่างไรก็ตามความจริงที่ว่าโครงข่ายประสาทเทียมแบบวนซ้ำมีข้อจำกัดที่สำคัญคือ เมื่อเพิ่มความยาวของข้อมูลอินพุตจะทำให้ประสิทธิภาพของโมเดลลดลง ปัญหาที่เรียกว่า ปัญหาค่าเกรเดียนต์ที่หายไป (Vanishing Gradient Problem) (Hochreiter, 1998) ด้วยเหตุผลนี้จึงมีการพัฒนาอัลกอริทึมหน่วยความจำระยะสั้นระยะยาว (Long Short-Term Memory, LSTM) ซึ่งเป็นส่วนเสริมของโครงข่ายประสาทเทียมแบบวนซ้ำให้สามารถแก้ปัญหานี้ได้ จากนั้นในปีค.ศ. 2018 Huisu และคณะ (2018) ใช้โมเดลที่สร้างด้วยอัลกอริทึมหน่วยความจำระยะสั้นระยะยาว ผสานกับเทคนิคหน้าต่างบานเลื่อน (Sliding Window) เพื่อทำนายราคาของบิตคอยน์ (Bitcoin) โดยที่ข้อมูลอินพุตสำหรับการเรียนรู้ของโมเดล คือข้อมูลเศรษฐกิจมหภาค (Macroeconomic Data) อัตราส่วนสกุลเงินทั่วโลก (Global Currency Ratios) และข้อมูลบล็อกเชน (Blockchain Data) นอกจากนี้พวกเขายังเปรียบเทียบประสิทธิภาพของโมเดลหน่วยความจำระยะสั้นระยะยาวของพวกเขากับโมเดลที่สร้างขึ้นบนพื้นฐานของหลักการเรียนรู้ของเครื่องแบบอื่น ๆ เช่น เวกเตอร์สนับสนุนถดถอย (Support Vector Regression, SVR) การถดถอยเชิงเส้น (Linear Regression, LR) และโครงข่ายประสาทเทียม ซึ่งผลการวิจัยพบว่าโมเดลหน่วยความจำระยะสั้นระยะยาวที่ผสานกับเทคนิคหน้าต่างบานเลื่อนสามารถทำนายราคาบิตคอยน์ได้แม่นยำกว่าโมเดลอื่น ๆ อย่างไรก็ตามในการลงทุนด้านการซื้อขายตัวเลือกไบนารีนั้นยังไม่มียานวิจัยใดที่มีการพัฒนาโมเดลที่เฉพาะเจาะจงสำหรับช่วยนักลงทุนในการซื้อขายตัวเลือกไบนารี

ดังนั้นในงานวิจัยนี้ ผู้วิจัยจึงได้พัฒนาโมเดลสำหรับการทำนายแนวโน้มราคาอ้างอิงของคู่สกุลเงินในตลาดซื้อขายเงินตราต่างประเทศ ที่มีความเหมาะสมเพื่อใช้แบบเฉพาะเจาะจงสำหรับการลงทุนในการซื้อขายตัวเลือกไบนารี โดยโมเดลที่ถูกพัฒนาขึ้นสร้างบนพื้นฐานของอัลกอริทึมหน่วยความจำระยะสั้นระยะยาว ซึ่งมีงานวิจัยก่อนหน้านี้ที่ยืนยันแล้วว่าเหมาะสมกับข้อมูลที่เป็นข้อมูลอนุกรมเวลาและยังให้ประสิทธิภาพการทำนายที่สูงกว่าเมื่อเปรียบเทียบกับอัลกอริทึมแบบ

อื่น ๆ นอกจากนี้ผู้วิจัยได้นำเสนอวิธีการเพิ่มประสิทธิภาพให้กับโมเดลด้วยการกำหนดค่าที่เหมาะสมสำหรับพารามิเตอร์ต่าง ๆ ที่เกี่ยวข้อง พารามิเตอร์เหล่านี้เป็นปัจจัยที่ต้องพิจารณาเมื่อพัฒนาโมเดลหน่วยความจำระยะสั้นระยะยาว เช่น ความยาวอินพุตสำหรับการพัฒนาโมเดล จำนวนข้อมูลที่เหมาะสมสำหรับใช้ในการเรียนรู้ของโมเดลและความถี่ในการปรับปรุงโมเดลให้มีความทันสมัยเพื่อรักษาประสิทธิภาพด้านความแม่นยำในการทำนายให้กับ โมเดลเป็นต้น นอกจากนี้การพัฒนาเครื่องมือที่ช่วยทำนายทิศทางทางการเคลื่อนไหวของแนวโน้มราคาอ้างอิงแล้ว งานวิจัยนี้ยังนำเสนอกลยุทธ์ที่ใช้ในการกำหนดเงื่อนไขในการลงทุนรวมทั้งกลยุทธ์ที่ใช้ในการตัดขาดทุน ณ จุดที่เหมาะสมสำหรับการซื้อขายตัวเลือกไบนารี เพื่อให้ นักลงทุนสามารถใช้ในการสร้างผลกำไรในการซื้อขายตัวเลือกไบนารีได้อย่างมีประสิทธิภาพ

## 1.2 วัตถุประสงค์การวิจัย

1. เพื่อนำความรู้ด้านปัญญาประดิษฐ์ โดยเฉพาะ ทฤษฎีของการเรียนรู้เชิงลึกมาประยุกต์ใช้ในการวิเคราะห์และทำนายข้อมูลด้านการเงิน
2. เพื่อนำเสนอโมเดลที่สามารถใช้เป็นตัวช่วยในการทำนายทิศทางทางการเคลื่อนไหวของราคาอ้างอิงของคู่สกุลเงินในตลาดการซื้อขายแลกเปลี่ยนเงินตราต่างประเทศ
3. เพื่อนำโมเดลสำหรับทำนายทิศทางทางการเคลื่อนไหวของราคาอ้างอิงของคู่สกุลเงินในตลาดการซื้อขายแลกเปลี่ยนเงินตราต่างประเทศมาใช้เป็นตัวช่วยในการกำหนดทิศทางสำหรับการลงทุนในตัวเลือกไบนารี
4. เพื่อทดสอบความแม่นยำในการทำนายของโมเดลที่ใช้เป็นเครื่องมือสำหรับกำหนดทิศทางทางการลงทุนในการซื้อขายตัวเลือกไบนารี
5. เพื่อนำเสนอกลยุทธ์ที่ใช้ในการลงทุนในการซื้อขายตัวเลือกไบนารี
6. เพื่อนำเสนอกลยุทธ์ในการตัดขาดทุนที่เหมาะสมสำหรับการลงทุนในการซื้อขายตัวเลือกไบนารี
7. เพื่อทดสอบประสิทธิภาพกลยุทธ์ที่ใช้ในการลงทุนและกลยุทธ์ในการตัดขาดทุนในด้านของการสร้างผลกำไรให้กับนักลงทุนในการซื้อขายตัวเลือกไบนารี

## 1.3 ขอบเขตของการวิจัย

งานวิจัยได้นำความรู้ด้านปัญญาประดิษฐ์ โดยเฉพาะ ทฤษฎีของการเรียนรู้เชิงลึกมาประยุกต์เพื่อพัฒนาโมเดลที่สามารถทำนายทิศทางของการเปลี่ยนแปลงราคาในตลาดแลกเปลี่ยนเงินตราต่างประเทศ โดยโมเดลที่ได้จากงานวิจัยนี้สามารถใช้เป็นเครื่องมือช่วยในการตัดสินใจ

สำหรับการซื้อขายตัวเลือกไบนารี รวมทั้งได้นำเสนอกลยุทธ์ที่ใช้ในการลงทุนและกลยุทธ์ในการตัดขาดทุนที่มีความเหมาะสมสำหรับการลงทุนในการซื้อขายตัวเลือกไบนารี โดยเฉพาะ ซึ่งในส่วนของการดำเนินงานนั้น ได้มีการกำหนดขอบเขตของการวิจัยไว้ดังต่อไปนี้

1. ชุดข้อมูลที่ใช้ในการสร้างและทดสอบประสิทธิภาพของโมเดลในงานวิจัยนี้ คือข้อมูลย้อนหลังที่ประกอบด้วยราคาเปิดและราคาปิดของการซื้อขายแลกเปลี่ยนเงินตราต่างประเทศของคู่เงิน EURUSD ซึ่งเป็นคู่เงินที่นักลงทุนส่วนใหญ่นิยมซื้อขายกันและมีมูลค่าในการซื้อขายมากกว่าร้อยละ 60 ของมูลค่าการซื้อขายทั้งหมดในตลาด

2. อัลกอริทึมหลักที่ใช้ในการพัฒนาโมเดลในงานวิจัยนี้ คืออัลกอริทึมที่ถูกสร้างมาจากพื้นฐานของหลักการเรียนรู้เชิงลึก โดยจะต้องเป็นอัลกอริทึมที่เหมาะสมกับการวิเคราะห์ข้อมูลแบบอนุกรมเวลา

3. การเพิ่มประสิทธิภาพโมเดล คือการกำหนดค่าต่าง ๆ ที่เหมาะสมสำหรับการสร้างโมเดลทั้งในด้านการเตรียมข้อมูลที่จะถูกใช้เป็นข้อมูลนำเข้าสำหรับการสร้างโมเดล และค่าพารามิเตอร์ต่าง ๆ ที่ต้องกำหนดในอัลกอริทึมหลักที่ใช้สร้างโมเดล

4. การทดสอบประสิทธิภาพของโมเดลในด้านของความถูกต้องแม่นยำในการทำนายนั้น ใช้มาตรวัดคือ Accuracy, Precision, Recall และ F-Measure

5. การทดสอบประสิทธิภาพของเครื่องมือรวมทั้งกลยุทธ์ที่ใช้ในการลงทุนและการตัดขาดทุนในด้านการสร้างผลกำไรให้กับนักลงทุนสำหรับการซื้อขายตัวเลือกไบนารี ใช้วิธีการทดสอบแบบย้อนกลับ (Backward Test) และการทดสอบแบบไปข้างหน้า (Forward Test)

#### 1.4 ประโยชน์ที่จะได้รับ

1. ได้นำความรู้ด้านปัญญาประดิษฐ์ โดยเฉพาะทฤษฎีของการเรียนรู้เชิงลึกมาประยุกต์ใช้ในการวิเคราะห์และทำนายข้อมูลด้านการเงิน

2. ได้พัฒนาองค์ความรู้ใหม่ ทั้งในด้านการเตรียมข้อมูลที่จะถูกใช้เป็นข้อมูลนำเข้าสำหรับการสร้างโมเดล และค่าพารามิเตอร์ต่าง ๆ ที่เหมาะสม ซึ่งเป็นสิ่งจำเป็นในกระบวนการเพิ่มประสิทธิภาพในการทำนายให้กับโมเดล

3. ได้เครื่องมืออัตโนมัติที่ใช้สำหรับใช้จำแนกข้อมูลตามประเภทของแนวโน้มความเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนด ซึ่งเครื่องมือนี้สามารถใช้จำแนกประเภทของข้อมูลเพื่อใช้ในการสร้างโมเดลสำหรับทำนายแนวโน้มความเคลื่อนไหวของราคาอ้างอิงในคาบเวลาถัดไปแทนการใช้ผู้เชี่ยวชาญในการจำแนก


4. ได้โมเดลที่สามารถใช้ทำนายทิศทางและการเคลื่อนไหวของค่าเงินในตลาดการแลกเปลี่ยนเงินตราต่างประเทศได้อย่างแม่นยำ



5. ได้เครื่องมือที่สามารถทำนายทิศทางของการเปลี่ยนแปลงราคาในตลาดแลกเปลี่ยนเงินตราต่างประเทศสำหรับนักลงทุนเพื่อใช้เป็นตัวช่วยการตัดสินใจในการซื้อขายตัวเลือกไบนารี

6. ได้กลยุทธ์ที่ใช้ในการลงทุนและกลยุทธ์สำหรับการตัดขาดทุนที่เหมาะสมกับการลงทุนในการซื้อขายตัวเลือกไบนารี

7. เทคนิคที่ใช้สำหรับการพัฒนาโมเดลในงานวิจัยนี้ สามารถนำไปประยุกต์ใช้ในการสร้างโมเดลสำหรับการทำนายทิศทางและการเคลื่อนไหวของข้อมูลทางการเงินประเภทอื่น ๆ เพื่อเพิ่มโอกาสสำหรับการลงทุนในการซื้อขายตัวเลือกไบนารีได้ ยกตัวอย่างเช่น ข้อมูลหุ้น (Stock) ราคาอ้างอิงการซื้อขายทองคำ (Gold) และข้อมูลสกุลเงินดิจิทัล (Cryptocurrency) เป็นต้น



## บทที่ 2

### ปริทัศน์วรรณกรรมและงานวิจัยที่เกี่ยวข้อง

เนื้อหาในบทนี้เป็นการกล่าวถึง การศึกษาในหลักการ ทฤษฎี และงานวิจัยที่เกี่ยวข้อง สำหรับนำมาประยุกต์ใช้เพื่อพัฒนางานวิจัย ซึ่งประกอบด้วยเนื้อหาเกี่ยวกับข้อมูลแบบอนุกรมเวลา การทำนายข้อมูลแบบอนุกรมเวลา ตัวชี้วัดทางเทคนิค โมเดลสำหรับการทำนายข้อมูลอนุกรมเวลา โดยใช้หลักการเรียนรู้ของเครื่อง โมเดลสำหรับการทำนายข้อมูลอนุกรมเวลาโดยใช้หลักการเรียนรู้เชิงลึก มาตรการวัดประสิทธิภาพของโมเดลและงานวิจัยที่เกี่ยวข้องตามลำดับ

#### 2.1 ข้อมูลแบบอนุกรมเวลา

##### 2.1.1 ลักษณะของข้อมูลแบบอนุกรมเวลา

อนุกรมเวลา (Time Series) คือ กลุ่มของข้อมูลเชิงปริมาณที่จัดเก็บในช่วงเวลาหนึ่ง ข้อมูลอนุกรมเวลา (Time Series Data) คือ ชุดของข้อมูลที่เก็บรวบรวมตามช่วงระยะเวลาอย่างต่อเนื่องกัน (Brillinger, 1981) ตัวอย่างเช่น ข้อมูลยอดขายสินค้าที่เก็บรวบรวมต่อเนื่องเป็นระยะเวลาหลาย ๆ เดือน ข้อมูลรายได้ประชาชาติปีต่าง ๆ ที่เก็บรวบรวมต่อเนื่องกันไปเป็นระยะเวลาหลาย ๆ ปี เป็นต้น ข้อมูลอนุกรมเวลาอาจอยู่ในลักษณะที่เป็นข้อมูลรายปี รายไตรมาส หรือรายเดือนก็ได้ ทั้งนี้ขึ้นอยู่กับความเหมาะสมในการนำไปใช้ประโยชน์ (Ismail et al., 2008) ตัวอย่างเช่น ดัชนีการซื้อขายในตลาดหลักทรัพย์แต่ละวัน (Stock Index) รายได้มวลรวมประชาชาติ (Gross National Income, GNI) รายรับรายจ่ายในแต่ละปีของบริษัทแห่งหนึ่ง เป็นต้น มีการใช้สัญลักษณ์ต่าง ๆ กันสำหรับการวิเคราะห์อนุกรมเวลา สัญลักษณ์ที่พบบ่อยคือ การกำหนดโดยระบุเป็นกลุ่มของตัวแปร  $X$  หรือ  $Y$  ที่มีการระบุเวลาและมีการจัดทำดัชนีเป็นลายลักษณ์อักษร ดังแสดงในสมการที่ 2.1 และ 2.2

$$X = \{X_1, X_2, X_3, \dots, X_n\} \quad (2.1)$$

สมการที่พบบ่อยคือ

$$Y = \{Y_t : t \in T\}, \quad (2.2)$$

โดยที่ T คือชุดดัชนี

โดยทั่วไปชุดข้อมูลแบบอนุกรมเวลาสามารถนำเสนอในรูปแบบแผนภูมิเส้น เพื่อให้ง่ายต่อการตีความหรือการวิเคราะห์ รูปที่ 2.1 แสดงตัวอย่างของข้อมูลอนุกรมเวลาของการซื้อขายเงินตราต่างประเทศสำหรับคู่เงินดอลลาร์สหรัฐอเมริกเปรียบเทียบกับค่าเงินยูโร ชุดข้อมูลแบบอนุกรมเวลามักถูกใช้ในเชิงสถิติสำหรับการประมวลผลสัญญาณ (Signal Processing) การจดจำรูปแบบ (Pattern Recognition) การเงินทางคณิตศาสตร์ (Mathematical Finance) การพยากรณ์อากาศ การทำนายแผ่นดินไหว (Earthquake Prediction) วิศวกรรมควบคุม (Control Engineering) ดาราศาสตร์ (Astronomy) วิศวกรรมการสื่อสาร (Communications Engineering) และงานในสาขาวิทยาศาสตร์และวิศวกรรมประยุกต์ที่เกี่ยวข้องกับการวัดตามเวลา



รูปที่ 2.1 ตัวอย่างกราฟเส้นที่แสดงชุดข้อมูลแบบอนุกรมเวลาของการซื้อขายแลกเปลี่ยนเงินตราต่างประเทศสำหรับคู่เงิน EURUSD

โดยธรรมชาติชุดข้อมูลแบบอนุกรมเวลาจะมีการจัดเรียงตามลำดับเวลาที่ข้อมูลนั้น ๆ ถูกบันทึกไว้ สิ่งนี้ทำให้การวิเคราะห์ข้อมูลแบบอนุกรมเวลา (Time Series Data Analysis) นั้นมีความแตกต่างจากการวิเคราะห์ข้อมูลโดยทั่วไปที่ไม่ได้มีการจัดเรียงตัวตามช่วงเวลา เช่นการวิเคราะห์ข้อมูลเชิงพื้นที่ ซึ่งการสังเกตมักเกี่ยวข้องกับตำแหน่งที่ตั้งทางภูมิศาสตร์ (Geological Location) ยกตัวอย่างเช่นการระบุราคาบ้านตามที่ตั้งและลักษณะเฉพาะของบ้าน สำหรับข้อมูลแบบอนุกรมเวลานั้น เมื่อทำการสังเกตข้อมูลที่จัดเรียงตัวอยู่ในเวลาที่ใกล้ ๆ กันจะมีความเกี่ยวข้องกันมากกว่าข้อมูลที่จัดเรียงตัวอยู่ในเวลาที่ห่าง ๆ กัน นอกจากนี้การใช้ประโยชน์จากการวิเคราะห์ข้อมูลแบบอนุกรมเวลานั้นจะเป็นการวิเคราะห์แบบทางเดียว เนื่องจากบ่อยครั้งที่ข้อมูลที่เกิดขึ้นในอดีตนั้นจะสะท้อนให้เห็นแนวโน้มของข้อมูลที่จะเกิดขึ้นในอนาคต (Bernard and Thomas, 1990)

การวิเคราะห์ข้อมูลแบบอนุกรมเวลาประกอบด้วยวิธีการสำหรับการดึงข้อมูลเชิงสถิติรวมไปถึงคุณลักษณะที่มีความหมายออกมาจากชุดข้อมูลชุดนั้น ๆ เพื่อตีความหรือวิเคราะห์การคาดการณ์แบบอนุกรมเวลา (Time Series Prediction) คือการใช้โมเดล (Model) เพื่อคาดการณ์ค่าของข้อมูลที่จะเกิดขึ้นในอนาคตโดยมีการอ้างอิงจากค่าของข้อมูลที่สังเกตก่อนหน้านี้ ในขณะที่การวิเคราะห์การถดถอย (Regression Analysis) มักใช้ในลักษณะที่จะทดสอบทฤษฎีว่าค่าปัจจุบันของชุดข้อมูลแบบอนุกรมเวลาอย่างน้อยหนึ่งชุด มีผลต่อค่าปัจจุบันของชุดข้อมูลแบบอนุกรมเวลาอื่น ๆ สำหรับการวิเคราะห์ข้อมูลแบบอนุกรมเวลาลักษณะนี้ไม่เรียกว่า "การวิเคราะห์อนุกรมเวลา (Time Series Analysis)" ซึ่งมุ่งเน้นไปที่การเปรียบเทียบค่าของชุดข้อมูลครั้งเดียวหรือชุดเวลาหลายชุดที่ขึ้นอยู่กับเวลาที่ต่างกัน (Wei, 2006)

นอกจากนี้โมเดลสำหรับการวิเคราะห์ชุดข้อมูลแบบอนุกรมเวลานั้นสามารถใช้ได้กับข้อมูลที่มีค่าจริง (Real-Value) ข้อมูลที่ต่อเนื่องกัน (Continuous Data) ข้อมูลตัวเลขแบบไม่ต่อเนื่อง (Discrete Numeric Data) หรือข้อมูลสัญลักษณ์แบบไม่ต่อเนื่อง (Discrete Symbolic Data) ยกตัวอย่างเช่น ข้อมูลลำดับตัวอักษรและคำในภาษาอังกฤษ

### 2.1.2 ข้อมูลย้อนหลังของการแลกเปลี่ยนเงินตราต่างประเทศ

การซื้อขายเงินตราต่างประเทศ หรือ สกุลเงินต่างประเทศ (Foreign Exchange, Forex) เป็นตลาดการซื้อขายในอนาคตที่ใหญ่ที่สุดในโลกด้วยปริมาณการซื้อขายมากกว่า 5 ล้านล้านดอลลาร์สหรัฐต่อวัน (Jacque, 2013) ตลาดการซื้อขายเงินตราต่างประเทศไม่เพียงแต่สร้างผลกำไรหรือขาดทุนสำหรับผู้ค้าเงินตราต่างประเทศ (Abbey and Doukas, 2012, pp. 142) แต่ยังส่งผลต่ออัตราแลกเปลี่ยนของสกุลเงินทั่วโลกอีกด้วย (Shu et al., 2015, pp. 163) การลงทุนในตลาดการซื้อขายเงินตราต่างประเทศนั้น นักลงทุนส่วนใหญ่มักจะวิเคราะห์ข้อมูลราคาย้อนหลัง (Forex Historical Data) ของคู่เงิน (Currency Pairwise) ที่ตัวเองกำลังให้ความสนใจอยู่ เพื่อที่จะหาจุดเหมาะสมที่สุดในการส่งคำสั่งซื้อ (Buy/Long Order) หรือคำสั่งขาย (Sell/Short Order)

ข้อมูลย้อนหลังของการแลกเปลี่ยนเงินตราต่างประเทศจัดเป็นข้อมูลแบบอนุกรมเวลา เนื่องจากข้อมูลถูกจัดเก็บอย่างเป็นลำดับ (Sequence) เช่น รายนาที่ รายชั่วโมง รายวัน รายสัปดาห์ หรือ รายเดือน เป็นต้น ซึ่งข้อมูลที่ถูกเก็บในแต่ละช่วงเวลานั้นประกอบด้วย วัน เวลา ราคาเปิด ราคาสูงที่สุดในคาบเวลานั้น ราคาต่ำที่สุดในคาบเวลานั้น ราคาปิด และมูลค่าการซื้อขายทั้งหมดในคาบเวลานั้น ดังแสดงในตารางที่ 2.1

ตารางที่ 2.1 ตัวอย่างข้อมูลย้อนหลังของการแลกเปลี่ยนเงินตราต่างประเทศของคู่เงิน EURUSD

Date	Time	Open	High	Low	Close	Volume
2015.01.02	0:00	1.20870	1.20888	1.19967	1.20004	77692
2015.01.04	0:00	1.19114	1.19530	1.18672	1.1946	6936
2015.01.05	0:00	1.19495	1.19753	1.18864	1.19366	37558
2015.01.06	0:00	1.19361	1.19683	1.18486	1.18715	38120
2015.01.07	0:00	1.1872	1.18954	1.18013	1.18327	40248
2015.01.08	0:00	1.18321	1.18466	1.17537	1.17913	36991
2015.01.09	0:00	1.17905	1.18443	1.17621	1.18387	63687
2015.01.11	0:00	1.18523	1.18691	1.18357	1.18689	4385
2015.01.12	0:00	1.18676	1.18704	1.17856	1.18312	73332
2015.01.13	0:00	1.18309	1.1859	1.17531	1.17761	79404
2015.01.14	0:00	1.17759	1.18449	1.17267	1.17832	79148

### 2.1.3 การลงทุนในตลาดการแลกเปลี่ยนเงินตราต่างประเทศ

ในตลาดการแลกเปลี่ยนเงินตราต่างประเทศหรือฟอเร็กซ์ คู่เงินที่สามารถซื้อได้นั้น จะประกอบด้วยสกุลเงิน 2 สกุลเงินซึ่งจะถูกกำหนดเป็นค่าอ้างอิง (Quotation) โดยที่ค่าอ้างอิงจะเป็นการอ้างอิงความสัมพันธ์ระหว่างสกุลเงินหลัก และสกุลเงินอื่นซึ่งใช้เป็นข้อมูลอ้างอิงเรียกว่า สกุลเงินที่เคาน์เตอร์ คู่สกุลเงินทั้งหมดในตลาดฟอเร็กซ์ มีการกำหนดอย่างเป็นระบบโดยการเชื่อมโยงรหัสสกุลเงิน ISO ของสกุลเงินหลักและสกุลเงินที่เคาน์เตอร์ ตัวอย่างเช่น สัญลักษณ์ “EURUSD” เป็นตัวบ่งชี้ค่าอ้างอิงของค่าเงินยูโรเปรียบเทียบกับค่าเงินดอลลาร์สหรัฐ

ยกตัวอย่างสัญลักษณ์ของคู่สกุลเงิน EURUSD ที่ถูกซื้อขายกันในตลาดฟอเร็กซ์ หมายความว่าค่าเงินยูโรเป็น (EUR) เป็นสกุลเงินหลักและมีค่าเงินดอลลาร์สหรัฐ (USD) เป็นสกุลเงินเคาน์เตอร์ ส่วนราคาอ้างอิงของคู่สกุลเงิน EURUSD ที่มีค่า 1.5000 หมายความว่า 1 ยูโรสามารถแลกเปลี่ยนได้ 1.5000 ดอลลาร์สหรัฐ นอกจากนี้หากราคาอ้างอิงสัญลักษณ์ของคู่สกุลเงิน EURUSD เพิ่มขึ้นจาก 1.5000 เป็น 1.5100 นั้นหมายถึงมูลค่าสัมพัทธ์ของเงินยูโรเพิ่มขึ้น อาจเป็นเพราะค่าเงินยูโรแข็งค่าหรือค่าเงินดอลลาร์สหรัฐอ่อนค่าลงหรืออาจเป็นเพราะทั้งสองกรณี ในทางกลับกันหาก ราคา EURUSD ลดลงจาก 1.5000 เป็น 1.4900 อาจเป็นเพราะค่าเงินยูโรอ่อนค่าหรือค่าเงินดอลลาร์สหรัฐแข็งค่าขึ้นหรืออาจเป็นเพราะทั้งสองกรณี เป็นต้น

การลงทุนในตลาดฟอเร็กซ์นั้น นักลงทุนจะเปิดคำสั่งซื้อ (Long หรือ Buy) ราคาอ้างอิงของคู่สกุลเงินที่พวกเขาสนใจ หากนักลงทุนเชื่อว่าราคาอ้างอิงของคู่สกุลเงินจะมีค่าเพิ่มมากขึ้น ในทางตรงกันข้ามนักลงทุนจะส่งคำสั่งขาย (Short หรือ Sell) คู่สกุลเงินที่นักลงทุนสนใจ หาก

นักลงทุนมั่นใจว่าราคาอ้างอิงของคู่สกุลเงินนั้น ๆ จะมีค่าลดลง ซึ่งการได้กำไร หรือ ขาดทุน ซึ่งเกิดจากคำสั่งซื้อ หรือ คำสั่งขายนั้น สามารถทำความเข้าใจได้ง่าย ๆ ดังตัวอย่างต่อไปนี้

เมื่อนักลงทุนส่งคำสั่งซื้อราคาอ้างอิงของคู่สกุลเงิน EURUSD ที่ 1.0500 และราคาสูงไปที่ 1.0550 หมายความว่านักลงทุนได้ทำกำไรมา 50 จุด (pips) สำหรับค่า 1 pip ในรูปแบบเลขทศนิยมอัตราแลกเปลี่ยนของสกุลเงิน ค่าเงินอ้างอิงดอลลาร์สหรัฐ เท่ากับมูลค่าแต่ละค่า pip เท่ากับ  $0.0001 / 1.0550 = 0.00009478$  บาท (ปัดเศษขึ้น) นั่นหมายความว่า นักลงทุนจะได้รับกำไรจากคำสั่งนี้ ในทางตรงข้ามหากราคาลดลงไปที่ 1.0450 หมายความว่านักลงทุนขาดทุนไป 50 pips ซึ่งในแต่ละ pip นักลงทุนจะขาดทุน 0.00009478 บาท

สำหรับทุก pip ที่นักลงทุนทำกำไร หรือ ขาดทุนนั้น ในการเทรดจริงระบบซื้อขายจะถูกจัดการด้วยจำนวนหน่วยที่ใหญ่กว่า pip ที่เรียกว่าค่า lot ซึ่งหมายถึงลำดับของจำนวนหลักของหน่วยต่าง ๆ แยกตามประเภทของบัญชีเทรดที่นักลงทุนเปิดไว้กับตัวแทนในการเทรด (Brokers) ดังแสดงในตารางที่ 2.2

ตารางที่ 2.2 ลำดับของจำนวนหลักของหน่วยต่าง ๆ แยกตามประเภทของบัญชีเทรด

บัญชีเทรด	จำนวนของหน่วย (lot)
Standard	100,000
Mini	10,000
Micro	1,000

จากตารางที่ 2.2 ถ้านักลงทุนได้กำไรจากการเทรดจำนวน 50 pips หมายความว่าอัตราแลกเปลี่ยนค่าเงินอ้างอิงของสกุลเงินดอลลาร์สหรัฐเท่ากับ 1 สำหรับคู่สกุลเงิน 1 pip จะมีราคา 10 ดอลลาร์เสมอ เมื่อเราเทรด 100,000 หน่วย (1 lot ที่บัญชีเทรดแบบ Standard) ซึ่งคิดเป็นกำไรเท่ากับ  $100,000 * 0.0001 * 50 = \$500\text{USD}$  อย่างไรก็ตามหากนักลงทุนขาดทุนจากการเทรดจำนวน 50 pips หมายความว่า นักลงทุนขาดทุนเป็นจำนวนเงิน \$500USD ด้วยเช่นกัน

#### 2.1.4 การซื้อขายตัวเลือกไบนารี

การซื้อขายตัวเลือกไบนารี (Binary Options) เป็นการลงทุนแบบเก็งกำไรที่มีหลักการคล้ายคลึงกับการลงทุนในตลาดฟอเร็กซ์ โดยที่ตัวเลือกไบนารีนั้นเป็นการเก็งกำไรโดยนำกราฟราคาจากตลาดจริงมาอ้างอิง ไม่ว่าจะเป็นราคาหุ้นในตลาดฟอเร็กซ์ หรือราคาหุ้นของบริษัทต่างๆ เช่น Apple, Google, Intel, Amazon, MC Donalds, Sony และอื่น ๆ อีกมากมาย รวมไปถึงสกุลเงินดิจิทัลต่าง ๆ ด้วย

การทำกำไรในซื้อขายตัวเลือกไบนารี นั้นสามารถทำได้ทั้งขาขึ้นและขาลง โดยนักลงทุนจะส่งคำสั่งเพื่อเก็งว่าราคาอ้างอิงของสิ่งที่เขาสนใจจะขึ้นหรือลงภายในเวลาที่กำหนด โดยมีอัตรากำไร/อัตราขาดทุนอยู่ที่ประมาณ 0.85/1 ซึ่งหมายความว่าหากนักลงทุนวางเงิน 100 บาท เมื่อทายถูกว่าราคาจะขึ้นหรือลงภายในเวลานี้ เขาก็จะได้กำไร 85 บาท แต่ถ้าหากทายผิดก็จะขาดทุน 100 บาท อัตราส่วนนี้เป็นราคาที่โบรกเกอร์อ้างอิงในตลาดจริง ส่วนคำสั่งซื้อขายของนักลงทุนจะไม่ถูกส่งตรงไปที่ตลาดกลาง แต่ทางโบรกเกอร์จะรับคำสั่งไว้เอง หรือพูดอีกอย่างหนึ่งว่าทางโบรกเกอร์นั้นจะแบกรับความเสี่ยงไว้เอง ยกตัวอย่างของการลงทุนการซื้อขายตัวเลือกไบนารี เช่น ถ้านักลงทุนเทรด การซื้อขายตัวเลือกไบนารี คู่เงิน EURUSD ด้วยรูปแบบการเก็งราคาแบบขาขึ้นภายใน 1 นาที ด้วยเงิน 100 บาท หมายความว่าเมื่อสิ้นสุดระยะเวลาหนึ่งนาทีนั้นจากการส่งคำสั่งซื้อนี้ ไม่ว่าจะราคาจะขึ้นไปเท่าใดก็ตาม นักลงทุนก็จะได้กำไรมา 85 บาท ในทางกลับกันหากราคาลงมาจากจุดที่เข้าซื้อ ไม่ว่าจะลงมาเท่าไรก็ตามเมื่อสิ้นสุดหนึ่งนาทีนี้ เขาก็จะขาดทุนทันที 100 บาท

## 2.2 การทำนายข้อมูลทางการเงินแบบอนุกรมเวลา

ข้อมูลราคาสินค้าโภคภัณฑ์หรือสินทรัพย์ที่มีการซื้อขายและถูกจัดเก็บในแต่ละช่วงเวลา จัดเป็นข้อมูลแบบอนุกรมเวลาซึ่งเรียกกันว่า ข้อมูลทางการเงินแบบอนุกรมเวลา (Financial Time Series Data) (Lai et al., 2009) ข้อมูลเหล่านี้ได้ถูกบันทึกและมีการศึกษาชุดข้อมูลทางการเงินที่ต่างกันเป็นเวลาหลายทศวรรษ ในปัจจุบันมีการบันทึกธุรกรรมทั้งหมดในตลาดการเงินต่าง ๆ เช่น ตลาดหลักทรัพย์ (Stock Market) หรือตลาดแลกเปลี่ยนเงินตราต่างประเทศ (Foreign Exchange or Forex Market) ซึ่งนำไปสู่การจัดเก็บข้อมูลจำนวนมากไม่ว่าจะเป็นข้อมูลที่เปิดเผยในอินเทอร์เน็ตหรือข้อมูลที่ใช้ในเชิงพาณิชย์

การวิเคราะห์ข้อมูลทางการเงินแบบอนุกรมเวลาเป็นเรื่องที่นักวิจัยให้ความสนใจเป็นอย่างมาก เพื่อการอนุมานและคาดการณ์ในอนาคต นอกจากนี้การจัดการความไม่แน่นอน (Uncertainty) ที่มีอยู่ในชุดข้อมูลเวลาทางการเงินและทฤษฎีที่ใช้ในการจัดการกับข้อมูลเหล่านี้เป็นเรื่องที่น่าสนใจสำหรับนักเศรษฐศาสตร์ นักสถิติและนักฟิสิกส์ (Kaltwasser, 2010, pp. 1215-1222)

การวิเคราะห์ข้อมูลทางการเงินแบบอนุกรมเวลาเกี่ยวข้องกับทฤษฎีที่ใช้ในการประเมินมูลค่าทรัพย์สินเมื่อเวลาผ่านไปเป็นระเบียบวิธีการเชิงประจักษ์เหมือนทฤษฎีสาขาอื่น ๆ ที่เป็นรากฐานในการอนุมาน (Inference) อย่างไรก็ตาม มีคุณลักษณะที่สำคัญที่ทำให้การวิเคราะห์ชุดข้อมูลทางการเงินแบบอนุกรมเวลาแตกต่างจากการวิเคราะห์ข้อมูลอนุกรมเวลาอื่น ๆ ซึ่งล้วนแต่มีองค์ประกอบของความไม่แน่นอน ตัวอย่างเช่น ความผันผวนของสินทรัพย์ในตลาดหลักทรัพย์ไม่สามารถสังเกตได้โดยตรง ดังนั้นวิธีการทางสถิติจึงมีบทบาทสำคัญในการวิเคราะห์ข้อมูลทางการเงินแบบอนุกรมเวลา (Tsay, 2005)

## 2.3 ตัวชี้วัดทางเทคนิค

ตัวชี้วัดทางเทคนิค (Technical Indicators) คือ การคำนวณทางคณิตศาสตร์ที่ขึ้นอยู่กับราคาและปริมาณการซื้อขายสินทรัพย์นั้น ๆ ซึ่งนักวิเคราะห์ทางเทคนิคใช้ตัวชี้วัดเพื่อคาดการณ์การเคลื่อนไหวของราคาในอนาคตโดยการวิเคราะห์จากข้อมูลในอดีต (Lerman and Gilder, 2009) โดยส่วนใหญ่แล้วนักลงทุนในตลาดหลักทรัพย์ หรือ ตลาดแลกเปลี่ยนเงินตราต่างประเทศจะใช้ตัวชี้วัดทางเทคนิคในการวิเคราะห์ โมเมนตัม (Momentum) ความผันผวน (Volatility) แนวโน้ม (Trend) และปริมาณการซื้อขาย (Volume) เพื่อวิเคราะห์ความเคลื่อนไหวของราคาที่เกิดขึ้นจริงและช่วยสร้างสัญญาณซื้อขายของตัวเอง ในหัวข้อนี้อธิบายตัวชี้วัดทางเทคนิคที่ได้รับความนิยม แบ่งแยกตามหมวดหมู่ต่าง ๆ ดังนี้

### 2.3.1 ตัวชี้วัดทางเทคนิคแบบโมเมนตัม

โมเมนตัม คือตัวชี้วัดสำหรับการวิเคราะห์ทางเทคนิคที่ใช้งานง่ายไม่ซับซ้อน ซึ่งแสดงถึงความแตกต่างระหว่างราคาปิดของวันนี้เทียบกับราคาปิดเมื่อ N วันที่ผ่านมา โดยทั่วไปแล้วโมเมนตัมจะอ้างถึงราคาเคลื่อนไหวอย่างต่อเนื่องจนระบุเป็นแนวโน้มได้อย่างชัดเจน ตัวชี้วัดโมเมนตัมแสดงถึงแนวโน้มเป็นบวกเมื่อราคาขึ้นอย่างต่อเนื่อง หรือ เป็นลบในขณะที่ราคาขาลงอย่างต่อเนื่อง (Pee, 2001) ในปัจจุบันมีการคิดค้นและพัฒนาตัวชี้วัดโมเมนตัมขึ้นมาอย่างมากมาย ตัวชี้วัดในหมวดหมู่นี้ที่ได้รับความนิยม ได้แก่ Relative Strength Index (Chong and Ng, 2008), Stochastic Oscillator (Kannan et al., 2010), Williams %R (Trading Strategy Guides, 2019), Awesome Oscillator (Russell et al., 2005), True strength index (Gorgulho et al., 2011) และ Money Flow Index (Chen et al., 2010) เป็นต้น ซึ่งรายละเอียดของแต่ละตัวชี้วัดมีดังนี้

### 2.3.2 ตัวชี้วัดทางเทคนิคแบบความผันผวน

ตัวบ่งชี้ทางเทคนิคประเภทความผันผวน (Volatility) มีประโยชน์อย่างมากสำหรับนักลงทุนในการตรวจสอบความผันผวนของราคาสินทรัพย์ในตลาดที่อาจเกิดขึ้น ตัวบ่งชี้ประเภทนี้จะประเมินราคาสินทรัพย์จากการวัดค่าความผันผวนของราคาในตลาด แนวโน้มขาขึ้นที่แข็งแกร่งจะบ่งบอกถึงการลดลงของความผันผวน ในขณะที่แนวโน้มขาลงที่แข็งแกร่งจะบ่งบอกถึงการเพิ่มขึ้นของความผันผวน แนวโน้มของการที่จะเกิดจุดกลับตัวของราคานั้นมักจะเกิดขึ้นเมื่อความผันผวนเพิ่มขึ้น ตัวบ่งชี้ความผันผวนมีอยู่ด้วยกันหลายแบบให้นักลงทุนเลือกใช้งาน เช่น Average True Range (Nayak et al., 2015) และ Bollinger Bands (Leung and Chong, 2003; Bollinger, 1992, pp. 47-51)



### 2.3.3 ตัวชี้วัดทางเทคนิคแบบแนวโน้มหรือทิศทาง

ตัวบ่งชี้ประเภทแนวโน้ม (Trend) เป็นกลุ่มของตัวชี้วัดที่ใช้วัดทิศทางหรือแนวโน้มความเคลื่อนไหวของราคาของสินทรัพย์นั้น ๆ ตัวชี้วัดในกลุ่มนี้มีหลากหลายแต่ตัวชี้วัดที่ได้รับความนิยมประกอบด้วย Moving Average Convergence Divergence (Appel, 2003), Average Directional Movement Index (Chenoweth et al., 1995), Triple Exponential Average (Hutson, 1983), Commodity Channel Index (Lambert, 1983), Detrended Price Oscillator (Stasinakis and Serpinis, 2014) และ Exponential Moving Average (Müller, 1991)

### 2.3.4 ตัวชี้วัดทางเทคนิคแบบปริมาตร

ตัวชี้วัดประเภท Volume เป็นตัวชี้วัดที่ใช้สำหรับวัดว่าสินทรัพย์ทางการเงินที่ระบุมีการอัตราการซื้อขายอย่างไรในช่วงเวลาที่กำหนด นักลงทุนมักใช้ข้อมูลนี้เพื่อเพิ่มผลกำไรและลดความเสี่ยงในการลงทุน ในที่งานวิจัยนี้จะยกตัวอย่างและอธิบายลักษณะของตัวชี้วัดประเภท Volume ตัวหนึ่งที่ได้รับคามนิยมในหมู่นักลงทุนคือตัวชี้วัดที่มีชื่อว่า Force Index (Ładyżyński, et al., 2013)


## 2.4 โมเดลการทำนายโดยใช้หลักการเรียนรู้ของเครื่อง

การพยากรณ์อนุกรมเวลาเป็นเรื่องยากเมื่อเปรียบเทียบกับการทำนายในรูปแบบอื่น เนื่องจากมีมิติเวลาเข้ามาเกี่ยวข้อง (Bontempi et al., 2012) อย่างไรก็ตาม มีโมเดลการเรียนรู้ของเครื่องหลายชนิดที่สามารถนำมาใช้ในการคำนวณอนุกรมเวลาได้ ยกตัวอย่างเช่น Support Vector Machine (Hearst et al., 1998) และ Artificial Neural Network (Agatonovic-Kustrin and Beresford, 2000) ซึ่งมีรายละเอียดดังนี้

### 2.4.1 เครื่องเวกเตอร์สนับสนุน

เครื่องเวกเตอร์สนับสนุน (Support Vector Machine, SVM) เป็นโมเดลการเรียนรู้แบบมีผู้สอน ใช้กับโจทย์ปัญหา 2 รูปแบบ ได้แก่ Classification และ Regression โดย SVM สามารถแก้ปัญหาได้ทั้งแบบเชิงเส้น (Linear) และไม่เป็นเชิงเส้น (Non-Linear) รวมถึงโจทย์ปัญหาชนิดอื่นๆ ได้ดี หลักการง่าย ๆ ของ SVM คือ ต้องมีอัลกอริทึมที่ใช้สร้างสมการเส้นตรงแบ่งประเภทข้อมูลที่เรียกว่าระนาบการตัดสินใจ ซึ่งใช้สำหรับโจทย์ปัญหาแบบ Classification เป้าหมายของการมีเส้นแบ่งประเภทคือเพื่อแบ่งข้อมูลออกเป็นสองประเภท ประโยชน์ของขั้นตอนนี้คือ หลังจากมีเส้นระนาบการตัดสินใจแล้ว โมเดลจะสามารถเรียนรู้ได้ว่าข้อมูลชุดใหม่ที่ป้อนเข้ามาจะจัดอยู่ใน

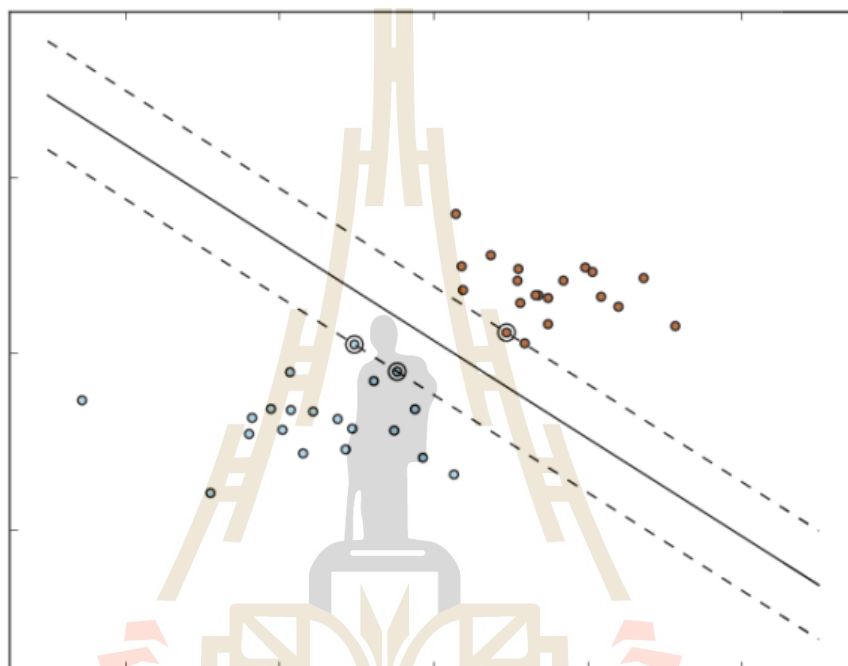
ประเภทใด วิธีการนี้ใช้ได้กับโจทย์ปัญหาที่ไม่ซับซ้อน เช่น ชุดข้อมูลที่มีคุณลักษณะเพียง 2 ลักษณะ แต่แท้จริงแล้ว SVM สามารถใช้ได้กับโจทย์ปัญหาที่ซับซ้อนหลายมิติได้เป็นอย่างดี (Suykens and Vandewalle, 1999) แม้แต่โจทย์ปัญหาที่มีจำนวนมิติมากกว่าจำนวนของตัวอย่าง สำหรับข้อได้เปรียบอื่น ๆ ของ SVM ได้แก่ การใช้หน่วยความจำได้อย่างมีประสิทธิภาพ ทำงานได้เร็วและแม่นยำกว่าการแบ่งประเภทข้อมูลด้วยวิธีอื่น เช่น K-Nearest Neighbors หรือ Deep Neural Networks (Hsu and Lin, 2002) เครื่องเวกเตอร์สนับสนุนสามารถใช้ได้ทั้งกับข้อมูลที่เป็นข้อมูลเชิงเส้นและข้อมูลที่ไม่เป็นเชิงเส้น ความแตกต่างกันของข้อมูลทั้ง 2 คือ ข้อมูลเชิงเส้น (Linear Data) เป็นข้อมูลที่สามารถแบ่งประเภทได้ด้วยตัวจำแนกเชิงเส้น การตัดสินใจของตัวจำแนกเชิงเส้นจะขึ้นอยู่กับผลรวมเชิงเส้นของคุณลักษณะของข้อมูล โดยคุณลักษณะในที่นี้ก็คือ “Features” ของระบบการเรียนรู้ของเครื่อง



รูปที่ 2.2 การแบ่งแยกข้อมูลแบบเชิงเส้น (ก) และไม่เป็นเชิงเส้น (ข)

รูปที่ 2.2 อธิบายลักษณะของข้อมูลเชิงเส้น ที่สามารถแบ่งผลลัพธ์ของตัวอย่างที่ใช้ในการสอน (Label) ด้วยเส้นตรง (เหมือนกับที่ SVM ใช้แบ่งประเภทด้วยเส้นระนาบการตัดสินใจ) ตัวจำแนกเชิงเส้น (Linear Classifier) สามารถทำเช่นนี้ได้ด้วยการหาผลรวมเชิงเส้นของคุณลักษณะ สำหรับ SVM สามารถนำไปใช้สร้างโมเดลได้ แต่จะต้องใช้วิธีการจำแนกประเภทด้วยวิธีอื่น เช่น Quadratic Classification เป็นต้น สำหรับภาพ (ข) เป็นภาพที่ใช้อธิบายข้อมูลที่ไม่เป็นเชิงเส้น ที่ไม่สามารถแบ่ง Label ได้ด้วยเส้นตรงเนื่องจากข้อมูลมีความซับซ้อนมากเกินไป ดังนั้นจึงไม่สามารถใช้วิธีเชิงเส้นในการแบ่งประเภทได้ อย่างไรก็ตาม SVM สามารถใช้ได้กับการจัดประเภทแบบเชิงเส้นและไม่เป็นเชิงเส้น ในที่นี้จะขออธิบายตัวอย่างข้อมูลเชิงเส้นอย่างง่าย จากนั้นจะอธิบายวิธีการแบ่งประเภทแบบไม่เป็นเชิงเส้นด้วย SVM และวิธีการทำงานของ SVM ด้วย Kernel

SVM ทำงานโดยการสร้างเส้นระนาบขึ้นมา 1 เส้นเพื่อแบ่งข้อมูลที่มี Label ที่แตกต่างกันออกเป็น 2 กลุ่ม เริ่มต้นจากการค้นหาระนาบที่เรียกว่า ระนาบเกินที่มีระยะห่างระหว่างข้อมูล 2 กลุ่มมากที่สุด (Maximum-margin Hyperplane) (Noble, 2006) เนื่องจากหากเลือกเส้นตรงที่มีระยะใกล้กับข้อมูลเป้าหมายมากเกินไป หากข้อมูลชุดใหม่ที่ถูกป้อนเข้ามามีค่าคลาดเคลื่อนเพียงเล็กน้อย อาจทำให้ SVM จำแนกข้อมูลผิดกลุ่มได้



รูปที่ 2.3 ตัวอย่างการแบ่งข้อมูลออกเป็น 2 กลุ่มของ SVM โดยใช้เส้น Maximum-Margin Hyperplane

ระนาบเกิน (Hyperplane) คือ เส้นที่มีระยะห่างมากที่สุดระหว่างข้อมูล 2 กลุ่ม (รูปที่ 2.3) ซึ่งอาจเรียกว่าเป็นเส้นที่อยู่เหนือเส้นระนาบการตัดสินใจ (Decision Line) แต่ศัพท์เทคนิคทางคณิตศาสตร์เรียกว่า “ระนาบเกิน” เนื่องจากเมื่ออยู่ในมิติที่มีมากกว่า 2 มิติ เส้นระนาบการตัดสินใจจะไม่มีลักษณะคงรูปเส้นอีกอีกต่อไป

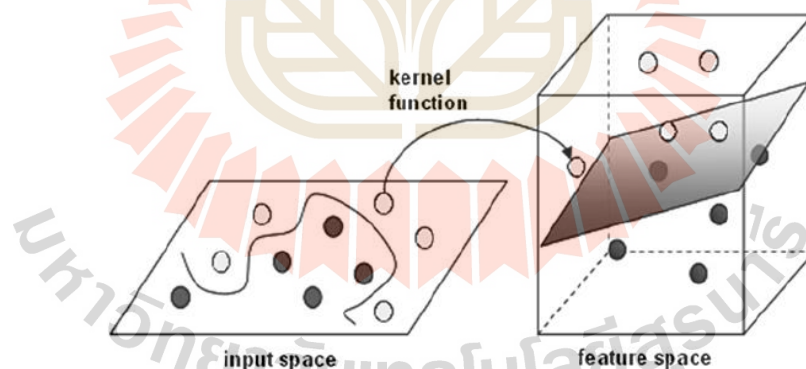
อัลกอริทึม SVM เรียนรู้เพื่อสร้างระนาบตัดสินใจจากชุดข้อมูลเวกเตอร์ที่เรียกว่า “ชุดข้อมูลฝึกหัด (Training Set)” โดยทุกเวกเตอร์มีค่ามิติเป็น  $p$  โดยที่  $p$  คือ จำนวนคุณลักษณะ (Features) ของชุดข้อมูลฝึกหัด ในการคำนวณหาว่ารั้วที่โหดสุดของระนาบเกินจะต้องทำให้ค่ามาร์จิ้นมีค่ามากที่สุดในทุก ๆ จุดเมื่อวัดระยะจากข้อมูลเป้าหมาย ในการจำแนกข้อมูลออกเป็น 2 กลุ่ม

สมมติให้ Label ของข้อมูลทั้ง 2 กลุ่มเป็น -1 และ 1 ให้ระนาบเกิน คือกลุ่มของจุดซึ่งสามารถอธิบายได้ด้วยสมการที่ (2.3)

$$y(k) = F \left( \sum_{i=0}^m w_i(k) \cdot x_i(k) + b \right) \quad (2.3)$$

โดยที่  $\vec{w} * \vec{x} - b = 0$  คือ เวกเตอร์ขนาดปกติ ส่วน  $b$  คือ ค่าโน้มน้าว (Bias) และเวกเตอร์ปกติ คือ เวกเตอร์ที่ตั้งฉากกับเส้นระนาบพารามิเตอร์ในสมการที่ 2.3 ใช้คำนวณหาค่าของระนาบ ซึ่งเมื่อหาค่าระนาบเกินได้แล้ว จะทำให้ได้โมเดลสามารถจำแนกข้อมูลชุดใหม่ได้

เมื่อต้องเผชิญกับชุดข้อมูลที่ไม่เป็นเชิงเส้น การใช้ SVM ในรูปแบบปกติการคำนวณหาเส้นระนาบเกินจะไม่สามารถทำได้ ดังนั้น SVM จึงจำเป็นต้องใช้ฟังก์ชัน Kernel เข้ามาช่วย เนื่องจาก Kernel จะช่วยให้ค้นพบรูปแบบและความสัมพันธ์ที่ซ่อนอยู่ได้อย่างแม่นยำ (Scholkopf and Smola, 2001) โดยที่ฟังก์ชัน Kernel เป็นฟังก์ชันที่ใช้จับคู่ข้อมูลที่ไม่เป็นเชิงเส้นส่ง Input Space เข้ากับคุณลักษณะที่อยู่ในมิติที่สูงกว่า และสำหรับในกลุ่มของคุณลักษณะ (Feature Space) ซึ่งมีมิติที่สูงกว่านี้เองที่ SVM จะสามารถทำงานได้ตามปกติ ดังตัวอย่างในรูปที่ 2.4




รูปที่ 2.4 หลักการทำงานของฟังก์ชัน Kernel

(<https://codeinsane.wordpress.com/2018/12/08/support-vector-machine/>)


## 2.4.2 โครงข่ายประสาทเทียม

โครงข่ายประสาทเทียม คือ โมเดลทางคณิตศาสตร์ที่พยายามจำลองโครงสร้างและการทำงานของโครงข่ายประสาทของมนุษย์ (Basheer and Hajmeer, 2000) สำหรับองค์ประกอบพื้นฐานของโครงข่ายประสาทเทียมคือ “เซลล์ประสาทเทียม (Artificial Neuron)” ซึ่งเป็นโมเดลทางคณิตศาสตร์อย่างง่าย ที่ประกอบไปด้วยกฎง่าย ๆ 3 ประการ ได้แก่ Multiplication, Summation และ Transfer โดยในขั้นแรกหลังจากมีข้อมูลนำเข้า ข้อมูลนำเข้าจะถูกคำนวณหาค่าน้ำหนักซึ่งหมายความว่าข้อมูลนำเข้าทุกค่าจะถูกนำไปคูณเพื่อหาค่าน้ำหนัก หลังจากนั้นจะส่งข้อมูลเข้าส่วนที่ 2 คือส่วนฟังก์ชัน Summation ที่จะทำหน้าที่ในการหาผลรวมของค่าน้ำหนักและค่าโน้มนำ และส่วนที่ 3 เป็นการนำข้อมูลจากส่วนที่ 2 ไปผ่านฟังก์ชัน Transfer เพื่อนำผลลัพธ์ที่ได้ออกไปใช้งาน ดังแสดงที่รูปที่ 2.5



รูปที่ 2.5 หลักการทำงานของ โครงข่ายประสาทเทียม

จากรูปที่ 2.5 เป็นภาพการทำงานที่เป็นมุมมองระดับบนแสดงให้เห็นการทำงานทั้ง 3 ส่วนของโครงข่ายประสาทเทียม รายละเอียดการทำงานเบื้องหลังของทั้ง 3 ส่วนสามารถอธิบายได้ด้วยรูปที่ 2.6 ดังนี้




รูปที่ 2.6 ตัวอย่างโครงข่ายประสาทเทียมอย่างง่าย

จากรูปที่ 2.6 จะเห็นว่าการทำงานภายในมีการเชื่อมต่อโครงข่ายประสาทเทียมใน 3 Layer คือ Input Layer, Hidden Layer และ Output Layer ซึ่งการเชื่อมต่อแต่ละ Layer จะไม่ใช่วิธีสุ่ม แต่จะใช้วิธีการคำนวณทางคณิตศาสตร์แทน ในอดีตมีนักวิจัยหลายคนได้จัดทำรูปแบบของโครงข่ายประสาทเทียมขึ้นมาหลายรูปแบบเพื่อให้สามารถนำไปใช้งานได้จริง เนื่องจากแต่ละรูปแบบมีลักษณะเฉพาะที่ใช้ได้กับโจทย์ปัญหาที่แตกต่างกันออกไป เมื่อวิเคราะห์โจทย์ปัญหาได้แล้วผู้ใช้งานสามารถเลือกโครงข่ายประสาทเทียมที่เหมาะสมเพื่อนำมาใช้แก้ปัญหาและสามารถปรับโครงข่ายประสาทเทียมให้เกิดความเหมาะสมที่สุดได้ผ่านการปรับที่รูปแบบการเชื่อมต่อและค่าพารามิเตอร์ ดังนั้น จึงกล่าวได้ว่าเราไม่สามารถใช้งานโครงข่ายประสาทเทียมได้ทันที กล่าวคือก่อนใช้งานจะต้องมีการสอนวิธีแก้ปัญหาให้กับโครงข่ายประสาทเทียมก่อน เพื่อให้โครงข่ายประสาทเทียมได้เรียนรู้และมีประสบการณ์กับการแก้ปัญหาชนิดนั้น ๆ จึงสามารถนำไปใช้ทำนายข้อมูลนำเข้าชุดอื่นได้ ซึ่งมีลักษณะเหมือนการเรียนรู้ของสมองของมนุษย์นั่นเอง ที่สามารถเรียนรู้พฤติกรรมและการตอบสนองได้จากการรับรู้ครั้งแรก สิ่งที่ได้ก็คือประสบการณ์เพื่อตอบสนองต่อการรับรู้แบบเดิมในครั้งถัดมา สำหรับประเภทของการเรียนรู้แบ่งเป็น 3 ประเภท ได้แก่ การเรียนรู้โดยมีผู้สอน (Supervised Learning) การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) และการเรียนรู้แบบเสริมแรง (Reinforcement Learning) เราจะต้องเลือกวิธีการเรียนรู้เช่นเดียวกับที่ต้องเลือกรูปแบบการเชื่อมต่อของโครงข่ายประสาทเทียม ซึ่งขึ้นอยู่กับชนิดของโจทย์ปัญหาว่าเป็นโจทย์ประเภทใด สำหรับการเรียนรู้แต่ละประเภทจะมีลักษณะที่แตกต่างกัน อย่างไรก็ตามการเรียนรู้ทั้ง 3 ประเภท มีลักษณะร่วมกันประการหนึ่ง คือ ต้องมีชุดข้อมูลเพื่อฝึกฝน (Learning Data) และมีกฎเกณฑ์การเรียนรู้ (Learning Rules) โครงข่ายประสาทเทียมจะพยายามหาผลลัพธ์ที่เหมาะสมที่สุดตามที่ได้รับข้อมูลนำเข้ามา หลังจากเลือกรูปแบบการเชื่อมต่อโครงข่ายประสาทเทียมแล้วจะต้องปรับค่าพารามิเตอร์การเชื่อมต่อ จากนั้นโครงข่ายประสาทเทียมจะทำการเรียนรู้

พฤติกรรมที่เหมาะสม ในขั้นตอนนี้จึงสามารถนำโครงข่ายประสาทเทียมมาใช้แก้ปัญหาได้ ปัจจุบันจะพบว่าการนำโครงข่ายประสาทเทียมมาใช้ในการงานหลายชนิด ไม่ว่าจะเป็นงานควบคุมเครื่องจักรงานด้านเคมี เกมส์ ระบบเรดาร์ อุตสาหกรรมรถยนต์ อุตสาหกรรมการบิน ดาราศาสตร์ วิทยาศาสตร์ พันธุกรรม ชนาคาร์ การตรวจจับการทุจริต เป็นต้น อีกทั้งพบว่าถูกนำมาใช้แก้ปัญหาในการคำนวณชนิดต่าง ๆ เช่น ค่าเฉลี่ยประมาณการณธ์ การวิเคราะห์สมการถดถอย การวิเคราะห์อนุกรมเวลา การจำแนกกลุ่มข้อมูล การจดจำรูปแบบ การตัดสินใจ การประมวลผลข้อมูล การกรองข้อมูล การแบ่งกลุ่มข้อมูล เป็นต้น

ประสาทเทียม (Artificial Neuron) เป็นองค์ประกอบพื้นฐานหลักของโครงข่ายประสาทเทียมที่ถูกพัฒนาขึ้นมาโดยเลียนแบบการทำงานของเซลล์ประสาทในทางชีวภาพของมนุษย์ ซึ่งองค์ประกอบพื้นฐานของการทำงานของอวัยวะในมนุษย์จะประกอบด้วยสมอง ไขสันหลัง และปมประสาทอื่น ๆ จากรูปที่ 2.7 (ก) แสดงให้เห็นการทำงานของเซลล์ประสาทในทางชีวภาพของมนุษย์ที่เชื่อมต่ออยู่กับตัวเซลล์ แขนงของเซลล์ประสาท และแกนประสาท รูปที่ 2.7 (ข) แสดงให้เห็นเซลล์ประสาทเทียมที่มีส่วนนำเข้า ส่วนคำนวณค่าถ่วงน้ำหนัก ส่วนถ่ายโอน ค่าโน้มเอียง และผลลัพธ์



รูปที่ 2.7 เซลล์ประสาททางชีวภาพ (ก) เปรียบเทียบกับเซลล์ประสาทเทียม (ข)

ในกรณีที่เป็นเซลล์ประสาททางชีวภาพของมนุษย์ข้อมูลข่าวสารจะเข้ามาที่ส่วนแขนงของเซลล์ก่อน (Dendrite) จากนั้นส่วนที่เป็นตัวเซลล์ (Soma) จะทำการประมวลผลข้อมูลเหล่านั้นและส่วนต่อไปที่แกนประสาท (Axon) แต่สำหรับเซลล์ประสาทเทียม ข้อมูลข่าวสารจะถูกนำเข้ามาโดยผ่านทางส่วนนำเข้าและต้องนำมาคำนวณค่าถ่วงน้ำหนักก่อน จากนั้นจะหาผลรวมค่าน้ำหนัก ค่าโน้มเอียงและประมวลผลค่าผลรวมนั้น โดยใช้ฟังก์ชันถ่ายโอน (Transfer) ขึ้นตอน

สุดท้ายจึงส่งต่อข้อมูลข่าวสารที่ประมวลผลเสร็จแล้วออกไปเป็นผลลัพธ์ สามารถอธิบายการทำงานของประสาทเทียมได้ดังสมการที่ (2.4)

$$y(k) = F \left( \sum_{i=0}^m w_i(k) \cdot x_i(k) + b \right) \quad (2.4)$$

โดยที่  $x_i(k)$  คือ ค่าข้อมูลที่นำเข้ามา ณ ช่วงเวลา  $k$  โดยที่  $i$  มีค่าตั้งแต่ 0 ถึง  $m$ ,  $w_i(k)$  คือ ค่าน้ำหนัก ณ ช่วงเวลา  $k$  โดยที่  $i$  มีค่าตั้งแต่ 0 ถึง  $m$ ,  $b$  คือ ค่าโน้มนียง,  $F$  คือ ฟังก์ชัน Transfer,  $y_i(k)$  คือ ค่าผลลัพธ์ ณ ช่วงเวลา  $k$

จากสมการที่ (2.4) ตัวแปรที่ไม่ทราบค่าในสมการนี้คือ ฟังก์ชัน transfer ซึ่งฟังก์ชันนี้เป็นตัวกำหนดค่าคุณสมบัติของเซลล์ประสาทเทียมและสามารถเป็นฟังก์ชันใดก็ได้ในทางคณิตศาสตร์ เราสามารถเลือกฟังก์ชันได้ตามประเภทของโจทย์ปัญหา กล่าวคือ สามารถเลือกใช้ฟังก์ชันจากกลุ่มของฟังก์ชันต่อไปนี้ Step Function, Linear Function และ Non-linear (Sigmoid) Function

Step Function เป็นไบนารีฟังก์ชันที่มีค่าผลลัพธ์ที่เป็นไปได้เพียง 2 ค่า คือ 0 และ 1 ดังนั้น ผลลัพธ์จึงเป็นได้ 2 กรณี คือ ถ้าข้อมูลนำเข้ามีค่าตรงกับค่า  $T$  (ค่าเงื่อนไขที่ใช้กรองข้อมูล “Threshold”) ผลลัพธ์ที่ได้จะมี 1 ค่า (ซึ่งอาจเป็น 0 หรือ 1) แต่ถ้าข้อมูลนำเข้าไม่ตรงกับเงื่อนไข  $T$  ผลลัพธ์ที่ได้จะเป็นอีกค่าที่ตรงกันข้ามกับกรณีแรก ตามสมการที่ (2.5)

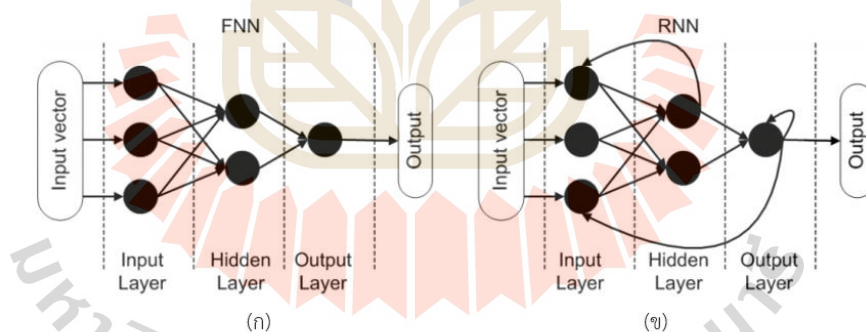
$$y = \begin{cases} 1 & \text{if } w_i x_i \geq \text{threshold} \\ 0 & \text{if } w_i x_i < \text{threshold} \end{cases} \quad (2.5)$$

หากเลือกฟังก์ชัน Transfer ชนิดไบนารีฟังก์ชันในเซลล์ประสาทเทียม จะเรียกเซลล์ประสาทเทียมดังกล่าวว่า “Perceptron” ซึ่งถูกใช้สำหรับแก้ปัญหาประเภทการจำแนกประเภทข้อมูลและมักพบว่าถูกใช้ในชั้นสุดท้ายของโครงข่ายประสาทเทียม ในกรณีที่ใช้ Linear Function เป็นฟังก์ชัน Transfer จะทำให้เซลล์ประสาทเทียมคำนวณหาผลรวมค่าน้ำหนักของข้อมูลนำเข้าและค่าโน้มนียงได้ง่ายขึ้นหากเลือกฟังก์ชัน Transfer ชนิด Linear Function จะนิยมใช้ในชั้นนำเข้าของโครงข่ายประสาทเทียม ส่วน Transfer Function ประเภท Non-linear Function เรียกอีกอย่างหนึ่งว่า Sigmoid Function นิยมใช้มากที่สุด เนื่องจากช่วยให้การคำนวณค่าน้ำหนักได้ง่ายซึ่งเป็นคุณลักษณะสำคัญเมื่อต้องมีการคำนวณเพื่อปรับค่าน้ำหนักใหม่ทุกครั้งในโครงข่ายประสาทเทียม



เมื่อนำเซลล์ประสาทเทียมมากกว่าสองเซลล์ขึ้นไปมาเชื่อมต่อกัน จะทำให้ได้เป็นโครงข่ายประสาทเทียม เนื่องจากการมีเซลล์ประสาทเทียมเพียงเซลล์เดียวจะทำให้โครงข่ายประสาทเทียมไม่สามารถทำงานและใช้แก้ไขปัญหาได้จึงจำเป็นต้องมีเซลล์ประสาทเทียมมากกว่าหนึ่งเซลล์เชื่อมต่อกัน ที่โครงข่ายประสาทเทียมสามารถใช้แก้ปัญหาที่ซับซ้อนในโลกความเป็นจริงได้ ไม่ว่าจะเป็นการประมวลผลแบบไม่เป็นเชิงเส้น การประมวลผลแบบกระจาย แบบขนาน และอื่น ๆ นั่นก็ด้วยความสามารถของเซลล์ประสาทเทียมจำนวนมากภายในโครงข่าย

วิธีที่เซลล์ประสาทเทียมถูกเชื่อมต่อเข้าด้วยกัน จะเรียกว่า “Topology” ซึ่งหมายถึงโครงสร้างหรือแผนภูมิของโครงข่ายประสาทเทียม การเชื่อมต่อภายในโครงข่ายประสาทเทียมสามารถทำได้หลายวิธี ทำให้กลายเป็น Topology หลายรูปแบบ โดยทั่วไปสามารถจำแนกเป็น 2 กลุ่ม แสดงได้ดังภาพที่ 2.8 ซึ่งแสดงให้เห็นรูปแบบของ Topology สองประเภท โดยภาพที่ 2.8 (ก) เป็น Topology ชนิด Feedforward Topology (Acyclic Graph) ซึ่งข้อมูลจะไหลจากส่วนนำเข้าไปสู่ส่วนผลลัพธ์ในทิศทางเดียว ภาพที่ 2.8 (ข) เป็น Recurrent Topology (Semi-cyclic Graph) ซึ่งข้อมูลจะไหลไปและกลับสองทิศทาง และจากภาพสามารถแบ่งชนิดของเซลล์ประสาทเทียมออกเป็นกลุ่มตามลำดับชั้น ได้แก่ ชั้นนำเข้า (Input Layer) ชั้นซ่อน (Hidden Layer) และชั้นผลลัพธ์ (Output Layer)



รูปที่ 2.8 Topology ของโครงข่ายประสาทเทียม (ก) Feed-forward Neural Network (FNN) และ (ข) Recurrent Neural Network (RNN)

เมื่อสามารถเลือกและสร้าง Topology ของโครงข่ายประสาทเทียมได้แล้วจะต้องดำเนินการในขั้นตอนต่อไป คือ “การฝึกหรือสอนโครงข่ายประสาทเทียม” เช่นเดียวกับโครงข่ายประสาทในทางชีวภาพของมนุษย์ที่ต้องเรียนรู้ว่าจะตอบสนองต่อสิ่งกระตุ้นด้วยพฤติกรรมใดที่เหมาะสมซึ่งการสอนโครงข่ายประสาทเทียมให้แสดงผลลัพธ์ที่เหมาะสมกับโจทย์จะสามารถ


เลือกใช้วิธีสอนแบบใดก็ได้ ไม่ว่าจะเป็นแบบมีผู้สอน แบบไม่มีผู้สอน หรือแบบเสริมแรง ทั้งนี้ก็เพื่อกำหนดค่าน้ำหนักและค่าโหนดเอียงให้โครงข่ายประสาทเทียมจดจำว่าจะต้องเลือกค่าที่เหมาะสมใดจึงจะให้ผลลัพธ์ที่ดีที่สุด

## 2.5 โมเดลการทำนายโดยใช้หลักการเรียนรู้เชิงลึก

อนุกรมเวลา (Time Series) คือ ข้อมูลที่ขึ้นกับเวลาซึ่งทำให้เกิดค่าข้อมูลที่แตกต่างกันจากเวลาหนึ่งไปยังอีกเวลาหนึ่ง เราสามารถใช้โมเดล Deep Learning กำหนดอนุกรมเวลาได้ โดยโมเดลที่ถูกสร้างขึ้นบนพื้นฐานของหลักการ Deep Learning นั้นสามารถใช้เพื่อทำนายและวิเคราะห์อนุกรมเวลาได้และมีงานวิจัยหลายงานวิจัยที่ระบุว่าให้ประสิทธิภาพในการทำนายดีกว่า โมเดลที่ถูกสร้างขึ้นจากหลักการอื่น ๆ (Raina et al., 2009; LeCun et al., 2015)


### 2.5.1 โครงข่ายประสาทเทียมแบบคอนโวลูชัน

โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network, CNN) เป็นโครงข่ายประสาทเทียมที่มีการจำลองการมองเห็นของมนุษย์ที่มองพื้นที่เป็นที่ย่อย ๆ และนำกลุ่มของพื้นที่ย่อย ๆ มาพาสานกันเพื่อดูว่าสิ่งที่เห็นอยู่คือสิ่งใด




รูปที่ 2.9 ตัวอย่างลักษณะ โครงสร้างของ โครงข่ายประสาทเทียมแบบคอนโวลูชัน

กระบวนการทำงานของโครงข่ายประสาทเทียมแบบคอนโวลูชันที่แสดงรายละเอียดในรูปที่ 2.9 เริ่มต้นจากข้อมูลอินพุตที่เป็นข้อมูลแบบรูปภาพ จากนั้นในส่วนของ Convolution และ Pooling Layers จะสร้าง Sliding Window (Filter) มาเพื่อทำการสแกนรูปภาพอินพุต เพื่อทำ Feature Map เพื่อแยกองค์ประกอบของรูปออกมา เช่น ขอบ สี รูปทรง เป็นต้น จากนั้น Fully Connected Layers จะเป็นส่วนที่นำเอาลักษณะสำคัญที่ได้มาจากส่วน Convolution และ Pooling Layers ก่อนหน้านี้มาทำการสร้างเป็น Neural Network สำหรับการเรียนรู้และทำนายประเภทของรูปภาพ ผลลัพธ์ที่ได้จากการทำนายแสดงตัวอย่างในรูปที่ 2.10



รูปที่ 2.10 ตัวอย่างผลการทำนายของโครงข่ายประสาทเทียมแบบคอนโวลูชัน  
(<http://www.glurgeek.com/wp-content/uploads/2019/05/2-8.png>)

หลักการการทำงานของโครงข่ายประสาทเทียมแบบคอนโวลูชันจะอาศัยหลักการมองพื้นที่ย่อยของมนุษย์จะมีการแยกคุณลักษณะ (Feature) ของพื้นที่ย่อยนั้น เช่น ลายเส้น และการตัดกันของสี ซึ่งการที่มนุษย์รู้ว่าพื้นที่ตรงนี้เป็นเส้นตรงหรือสีตัดกัน เพราะมนุษย์ดูทั้งจุดที่สนใจและบริเวณรอบ ๆ ประกอบกัน เช่น จากตัวอย่างในรูปที่ 2.11 ถ้าเปรียบว่ากรอบสี่เหลี่ยมสีเหลืองนั้นคือพื้นที่ที่มนุษย์กำลังให้ความสนใจอยู่ แต่มนุษย์สามารถรับรู้ได้ว่าสิ่งนี้คือหนู เพราะเรากวาดสายตามองรอบ ๆ



รูปที่ 2.11 พื้นที่ย่อยที่มีคุณลักษณะ (Feature) ที่สำคัญอยู่ในบริเวณนั้น  
(<https://adeshpande3.github.io>)

การแยกคุณลักษณะ (Feature Extraction) จะเริ่มจากการกำหนดค่าใน ตัวกรอง (Filter) หรือ เคอร์เนล (Kernel) ที่ช่วยดึงคุณลักษณะที่ใช้ในการรู้จำวัตถุออก โดยปกติตัวกรองหรือ

เคอร์เนลอันหนึ่งจะดึงคุณลักษณะที่สนใจออกมาได้หนึ่งอย่าง ดังนั้นจึงจำเป็นต้องมีตัวกรองหลาย ๆ ตัวกรองเพื่อหาคุณลักษณะทางพื้นที่หลายอย่างประกอบกัน เนื้อหาในส่วนนี้จะอธิบายถึงรายละเอียดในการแยกคุณลักษณะประกอบด้วย Filter, Feature Map, Stride, Padding และ Max Pooling

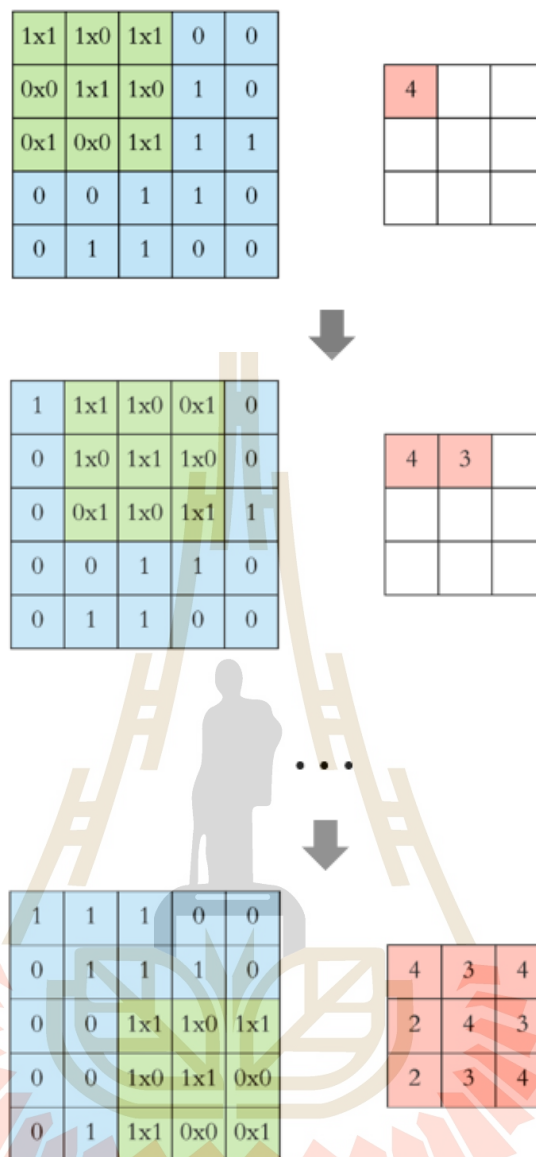
### 1) Filter

ตัวกรอง (Filter) ที่ใช้จัดการกับภาพดิจิทัลโดยปกติจะอยู่ในรูปแบบของตารางสองมิติที่มีขนาดตามพื้นที่ย่อย ๆ ที่พิจารณา ยกตัวอย่างเช่น ถ้าต้องการหาเส้นตรงทแยงมุมสีขาว ที่มีขนาด 3 พิกเซล Filter ที่ใช้ในการค้นหาวางจะอยู่ในลักษณะดังแสดงในรูปที่ 2.12

1	-1	-1
-1	1	-1
-1	-1	1

รูปที่ 2.12 ตัวอย่างของ Filter ที่มีขนาด 3×3 สำหรับหาเส้นตรงทแยงมุมสีขาว

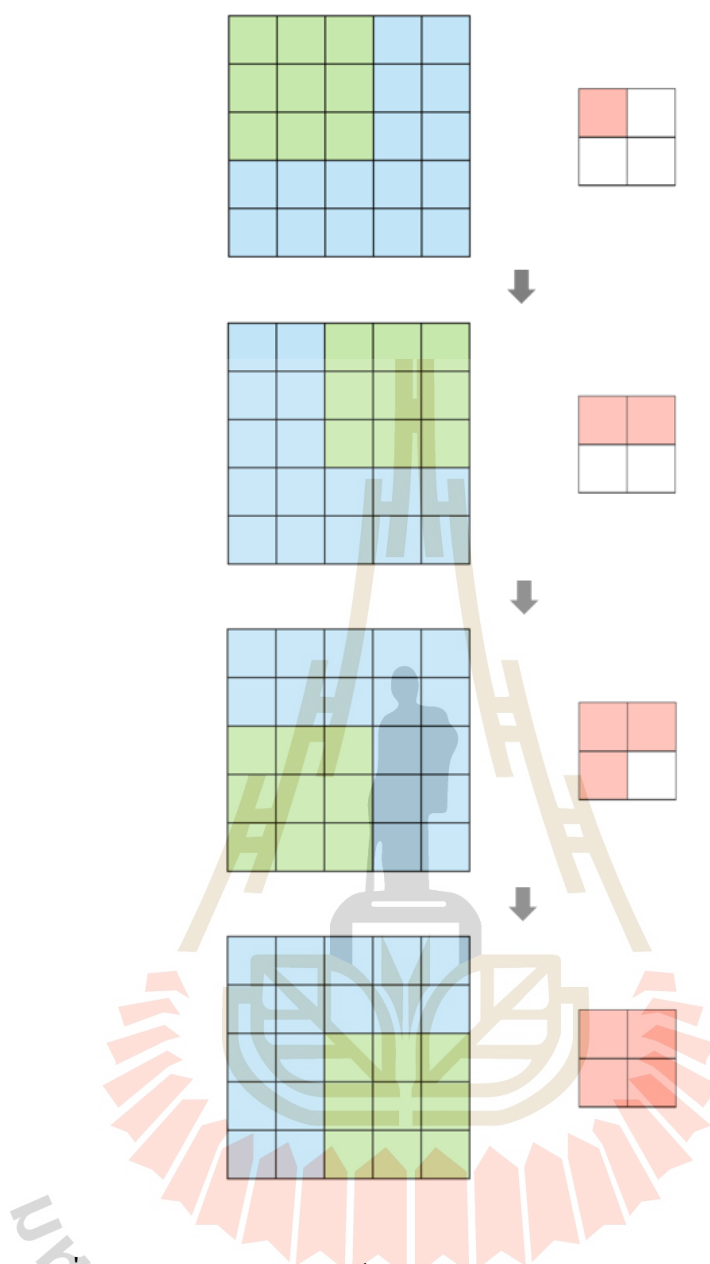
รูปที่ 2.12 คือ Filter ที่มีขนาด 3×3 พิกเซลของภาพข้อมูลเข้า ซึ่ง Filter จะถูกทาบลงในพิกเซลแรกของภาพข้อมูลเข้า จากนั้นจะถูกเลื่อนไปทาบบนพิกเซลอื่นในภาพทีละพิกเซลจนครบทุกพิกเซลในภาพ ซึ่งในบางกรณีอาจจะไม่ทาบ Filter บนพิกเซลที่อยู่ใกล้กรอบภาพ เพราะ Filter จะสั้นออกไปนอกภาพ เมื่อเลื่อน Filter ไปเรื่อย ๆ จนครบทุกพิกเซลที่สามารถเลื่อนได้ในภาพ สิ่งที่ได้นั้นจะเป็นสิ่งที่เรียกว่า พังคุณลักษณะ (Feature Map) ดังแสดงในรูปที่ 2.13



รูปที่ 2.13 รูปทางซ้ายคือ Filter ที่เลื่อนไปบนรูปภาพอินพุตทีละ 1 พิกเซล ส่วนรูปทางด้านขวาคือ ผลลัพธ์การคำนวณซึ่งออกมาเป็น Feature Map

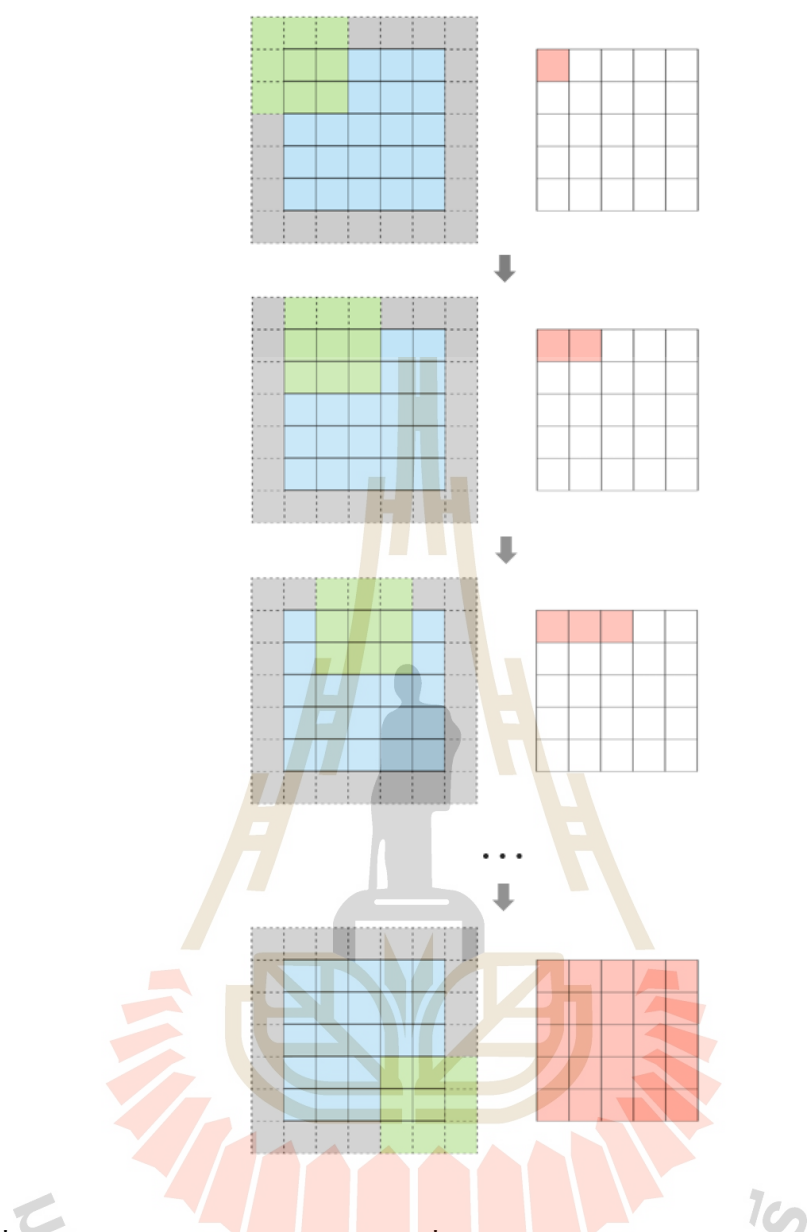
## 2) Stride และ Padding

Stride เป็นตัวกำหนดว่า Filter จะเลื่อนไปด้วย Step ขนาดเท่าไร ซึ่งการกำหนดค่าของ Stride ให้มากขึ้นจะทำให้การคำนวณหาคุณลักษณะมีพื้นที่ที่ทับซ้อนกันน้อยลง แต่อย่างไรก็ตามการกำหนดค่าของ Stride ที่มากขึ้นจะทำให้เราได้ Feature Map ที่มีขนาดเล็กลง ตัวอย่างการกำหนด Stride เท่ากับ 2 แสดงในรูปที่ 2.14



รูปที่ 2.14 ตัวอย่างของการสร้าง Feature Map โดยกำหนดค่า Stride เท่ากับ 2

Padding หมายถึงการเติมลบจากรูปที่ 2.15 เป็นการเพิ่มพื้นที่ที่เป็นสี่เหลี่ยมรอบ ๆ รูปภาพอินพุต โดยพื้นที่เหล่านี้เป็นพื้นที่ที่เรามักจะเติมค่า 0 หรือค่าต่าง ๆ เข้าไป เพื่อให้ Feature Map ที่ได้ยังคงมีขนาดเท่ากับอินพุต เหตุผลที่ต้องมีการเพิ่ม Padding เข้าไปนั้นก็คือในบางปัญหาอินพุตที่อยู่ตามขอบภาพอาจมีความสำคัญที่ส่งผลต่อการตัดสินใจบางอย่าง เราจึงจำเป็นต้องเก็บคุณลักษณะตามขอบของรูปภาพไว้ด้วย ตัวอย่างการกำหนด Stride เท่ากับ 1 และ Padding แสดงในรูปที่ 2.15



รูปที่ 2.15 ตัวอย่างการสร้าง Feature Map ซึ่งมีการกำหนดค่า Stride และ Padding เท่ากับ 1

### 3) Max Pooling

ธรรมชาติในการจำแนกภาพด้วยสายตาของมนุษย์จะทำการกวาดตาภาพทั้งหมดหากวิเคราะห์จากรูปที่ 2.16 จะเห็นว่าถึงแม้รูปภาพมีขนาดเล็กลง แต่ว่ามนุษย์ก็ยังสามารถระบุได้ว่าวัตถุในรูปภาพคือเครื่องบินดินเผา แสดงว่าเป็นการจำแนกวัตถุที่ความละเอียดต่ำลง แต่เป็นการทำโครงข่ายประสาทเทียมแบบคอนโวลูชันที่ความละเอียดสูง



รูปที่ 2.16 ตัวอย่างภาพที่เป็นวัตถุเดียวกันแต่ถูกย่อขนาดให้มีขนาดเล็กลง

([http://202.143.144.83/~skb/computer/ganjana/east\\_china\\_data.htm](http://202.143.144.83/~skb/computer/ganjana/east_china_data.htm))

สรุปได้ว่ามนุษย์เราจำแนกวัตถุโดยอาศัยทั้งการดูที่รายละเอียดเล็ก ๆ และการดูแบบคร่าว ๆ บนพื้นที่ใหญ่ เมื่อลองสังเกตการจำแนกแมวในรูปที่ 2.17 จะเห็นว่าในภาพบนแม้จะมีแมวหลายตัว แต่มนุษย์ก็ยังสามารถแยกแมวพวกนี้ออกจากกันได้ง่าย ๆ ด้วยการดูสี หรือ ดูพื้นที่ใหญ่ ๆ บนตัวแมว ในขณะที่การแยกแยะภาพแมวด้านล่างทั้งสองตัวนี้กลับต้องดูรายละเอียดเล็ก ๆ เช่น ตาและจมูก เพื่อแยกให้ออกว่ามีแมวจำนวนกี่ตัว จากปัญหานี้จะเห็นว่าเป็นไปได้ยากมากหากต้องอาศัยข้อมูลที่หายาบหรือละเอียดอย่างใดอย่างหนึ่งในการจำแนกวัตถุ ดังนั้นในการฝึกให้โครงข่ายประสาทเทียมแบบคอนโวลูชันเรียนรู้จึงต้องมีข้อมูลทั้งหายาบและละเอียดควบคู่กันไป




รูปที่ 2.17 ตัวอย่างรูปภาพแมว 2 รูปที่ใช้เทคนิคการแยกแยะแบบหายาบและละเอียด



ในความเป็นจริงเมื่อจำเป็นต้องคำนวณภาพในหลายสเกลแต่ปัญหาที่สำคัญที่สุดก็คือว่าจะทำให้การคำนวณอยู่ในรูปหลายสเกลได้อย่างไร ซึ่งหากใช้ Filter ที่มีขนาด 3x3 นั้นหมายความว่าเรากำลังจะจัดการกับรายละเอียดเล็ก ๆ แต่ด้วย Filter ขนาดเท่าเดิม หากทำกับภาพที่ขนาดเล็กลงแล้วจะครอบคลุมพื้นที่วัตถุเดิมมากขึ้น ดังนั้นการย่อรูปประกอบจะทำให้สามารถเข้าถึงความสามารถด้านการวิเคราะห์หลายความละเอียดได้

Pooling คือความสามารถในการย่อรูปแบบหนึ่ง ซึ่งหลักการที่นิยมใช้กันคือ Max Pooling ซึ่ง Max Pooling เป็น Filter แบบหนึ่งที่ทำค่าสูงสุดในบริเวณที่ Filter นั้นทาบบ่อยมาเป็นผลลัพธ์ โดยเราจะเตรียม filter ในลักษณะเดียวกันกับการทำ Feature Extraction ของโครงข่ายประสาทเทียมแบบคอนโวลูชันมาทาบบนรูปภาพอินพุต แล้วเลือกค่าที่สูงที่สุดบน Filter นั้นมาเป็นผลลัพธ์ใหม่ และจะเลื่อนตัวกรองไปตาม Stride ที่กำหนดไว้ โดยขนาด Filter ของการทำ Max Pooling จะนิยมเรียกกันว่า Pool Size การทำ Max Pooling จะทำให้ได้ค่าคุณลักษณะที่เด่นที่สุดของแต่ละส่วนย่อย ๆ ภายในรูปภาพ ดังแสดงในรูปที่ 2.18

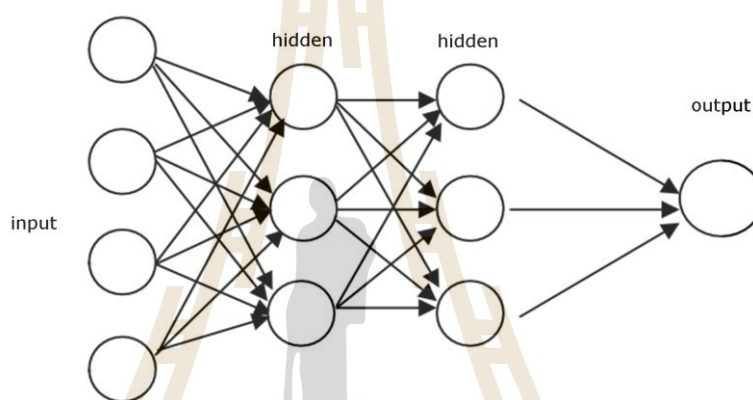


รูปที่ 2.18 ตัวอย่าง Max Pooling ที่กำหนด Filter ขนาด  $2 \times 2$  พิกเซล และกำหนดค่า Strid เท่ากับ 2  
(<https://towardsdatascience.com>)

### 2.5.2 โครงข่ายประสาทเทียมแบบวนซ้ำ

โครงข่ายประสาทเทียมแบบวนซ้ำ (Recurrent Neural Network, RNN) เป็นอัลกอริทึมใหม่ที่ใช้สำหรับเรียงข้อมูลเชิงลำดับที่ Siri จาก Apple และ Google Voice เลือกใช้ ทั้งนี้เนื่องจากเป็นอัลกอริทึมแรกที่สามารถจดจำข้อมูลนำเข้าของตนเองได้ด้วยการทำงานของหน่วยความจำภายใน ซึ่งเป็นคุณสมบัติที่เหมาะสมที่สุดสำหรับการทำงานของ Machine Learning ที่เกี่ยวข้องกับข้อมูลเชิงลำดับ (Sequential Data) (Graves et al., 2013) เนื้อหาต่อไปจะนึกกล่าวถึงแนวคิดเบื้องต้นของการทำงานของโครงข่ายประสาทเทียมแบบวนซ้ำ

การทำความเข้าใจการทำงานของโครงข่ายประสาทเทียมแบบวนซ้ำ จำเป็นจะต้องทำความเข้าใจกับการทำงานของโครงข่ายใยประสาทแบบไปข้างหน้า (Feed-forward Neural Network) (Bebis and Georgiopoulos, 1994) โดยในที่นี้จะเริ่มต้นด้วยการอธิบายถึง “ข้อมูลเชิงลำดับ” ซึ่งตามความหมายเบื้องต้นแล้วจะหมายถึงข้อมูลที่ถูกเรียงลำดับแล้ว ซึ่งมีข้อมูลที่อยู่ก่อนหน้าและข้อมูลที่อยู่ในลำดับถัดไปแบบสัมพันธ์กัน ยกตัวอย่างเช่น ข้อมูลทางการเงินหรือลำดับของดีเอ็นเอและข้อมูลเชิงลำดับที่ได้รับความนิยมมากที่สุดชนิดหนึ่งคือ “อนุกรมเวลา” ซึ่งหมายถึงชุดของข้อมูลที่ถูกบันทึกไว้ตามลำดับเวลา




รูปที่ 2.19 โครงสร้างของโครงข่ายประสาทเทียมแบบไปข้างหน้า

จากรูปที่ 2.19 จะเห็นว่าข้อมูลจะไหลเข้าในทิศทางหนึ่ง โดยไหลจากชั้นนำเข้าผ่านชั้นซ่อนไปยังชั้นผลลัพธ์ โดยการไหลตรงผ่านโครงข่ายไปที่ละโหนดโดยไม่ย้อนกลับมายังโหนดที่ผ่านไปแล้ว

โครงข่ายประสาทเทียมแบบไปข้างหน้าจะไม่มี การจดจำข้อมูลที่นำเข้าที่ได้รับมาจากโหนดก่อนหน้า ดังนั้นจึงไม่เหมาะกับการทำนายข้อมูลที่นำเข้ามาในครั้งต่อไป เนื่องจากโครงข่ายประสาทเทียมแบบไปข้างหน้าจะพิจารณาเฉพาะข้อมูลนำเข้าที่เป็นปัจจุบัน ไม่มีขั้นตอนการทำงานที่เกี่ยวข้องกับเวลา จึงไม่สามารถจดจำสิ่งที่ผ่านไปแล้วได้ แต่สามารถสร้างการจดจำให้กับโครงข่ายประสาทเทียมประเภทนี้ได้ด้วยการฝึก

สำหรับโครงข่ายประสาทเทียมแบบวนซ้ำ ข้อมูลจะไหลเข้าสู่โครงข่ายแบบวนซ้ำ เมื่อมีการตัดสินใจ จะเริ่มต้นทำงานด้วยการวิเคราะห์ข้อมูลนำเข้าปัจจุบันและเรียนรู้ข้อมูลนำเข้าดังกล่าวเพื่อเก็บไว้ในหน่วยความจำ จึงสามารถจดจำข้อมูลนำเข้าที่ผ่านไปแล้วได้ รูปที่ 2.20 แสดงให้เห็นความแตกต่างระหว่างข้อมูลที่ไหลในโครงข่ายประสาทเทียมแบบวนซ้ำกับแบบไปข้างหน้า



รูปที่ 2.20 ความแตกต่างระหว่างข้อมูลที่ไหลในโครงข่ายประสาทเทียมแบบวนซ้ำ (ก) และโครงข่ายประสาทเทียมแบบไปข้างหน้า (ข)


ยกตัวอย่างการทำงานของโครงข่ายประสาทเทียมแบบไปข้างหน้าให้เข้าใจง่ายขึ้น เช่น เมื่อเราป้อนข้อมูลนำเข้าเป็นคำว่า “Neuron” โครงข่ายประสาทเทียมชนิดนี้จะประมวลผลข้อมูลนำเข้าไปในโครงข่ายที่ละตัวอักษร และสมมติว่านำเข้าข้อมูลมาจนถึงตัวอักษร “r” โครงข่ายประสาทเทียมชนิดนี้จะลืมตัวอักษร “n”, “e”, และ “u” ไปแล้ว ซึ่งคุณลักษณะดังกล่าวไม่สามารถใช้ในการทำนายตัวอักษรในลำดับถัดไปที่จะมาถึงได้

สำหรับโครงข่ายประสาทเทียมแบบวนซ้ำ สามารถจดจำข้อมูลนำเข้าที่ผ่านไปแล้วได้ทุกข้อมูล ดังนั้นจึงสามารถสร้างผลลัพธ์และคัดลอกผลลัพธ์นำกลับเข้าสู่โครงข่ายประสาทเทียมได้อีกครั้ง โครงข่ายประสาทเทียมแบบวนซ้ำเพิ่มข้อมูลนำเข้าที่ผ่านไปแล้วเข้าไปในหน่วยความจำทันที ดังนั้น โครงข่ายประสาทเทียมแบบวนซ้ำจะมีข้อมูลนำเข้า 2 ค่า คือ ข้อมูลนำเข้าปัจจุบันและข้อมูลนำเข้าก่อนหน้า ลักษณะดังกล่าวเป็นสิ่งจำเป็นสำหรับการทำงานกับข้อมูลเชิงลำดับอย่างมาก เนื่องจากข้อมูลเชิงลำดับจะมีข้อมูลสำคัญที่บอกให้ทราบว่าข้อมูลใดจะเป็นข้อมูลลำดับถัดไป ดังนั้น โครงข่ายประสาทเทียมแบบวนซ้ำจึงเหมาะที่จะนำไปใช้กับข้อมูลเชิงลำดับ

โครงข่ายประสาทเทียมแบบไปข้างหน้า จะกำหนดเมตริกของค่าน้ำหนักขึ้นมาใช้เก็บข้อมูลที่เป็น Input แล้วใช้สร้าง Output ส่วนโครงข่ายประสาทเทียมแบบวนซ้ำจะกำหนดค่าน้ำหนักเป็นค่าปัจจุบันและเป็นค่าก่อนหน้าด้วย นอกจากนี้โครงข่ายประสาทเทียมแบบวนซ้ำยังมีการกระทำบางอย่างกับ Input และ Output ที่ผ่านไปแล้วด้วย นั่นคือจะมีการเปลี่ยนแปลงค่าน้ำหนักที่มาจาก Input ปัจจุบันและ Input ก่อนหน้า ด้วยวิธีการที่เรียกว่าวิธีการ Gradient Descent (Burges et al., 2005) และ Backpropagation (Leung and Haykin, 1991)

ในการทำงานของโครงข่ายประสาทเทียม จะมีการทำงานแบบแพร่กระจายไปข้างหน้า (Forward-Propagation) เพื่อให้ได้ผลลัพธ์ของโมเดลและตรวจสอบผลลัพธ์นั้นว่าผิดพลาด

หรือไม่ สิ่งที่ได้คือค่าความผิดพลาด (Error) สำหรับการแพร่กระจายแบบย้อนกลับ (Backward-propagation) คือการสืบย้อนกลับในโครงข่ายเพื่อค้นหาค่าน้ำหนักที่ทำให้เกิดค่า Error แล้วลบค่าน้ำหนักออกเท่ากับค่า Error โดยค่า Error จะถูกนำไปคำนวณด้วยอัลกอริทึมที่เรียกว่า “Gradient Descent” เพื่อวนรอบปรับค่า Error ให้เหลือน้อยที่สุด แล้วนำมาปรับค่าน้ำหนักให้เพิ่มขึ้นหรือลดลงขึ้นอยู่กับค่า Error ว่ามีมากขึ้นหรือน้อยลง เหล่านี้คือวิธีการทำงานของโครงข่ายประสาทเทียมในระหว่างขั้นตอนการฝึก ดังนั้น Backpropagation จึงเป็นการปรับค่าน้ำหนักของโมเดลในขณะฝึก รูปที่ 2.21 แสดงให้เห็นแนวคิดการทำงานของ Forward Propagation และ Backward Propagation สำหรับโครงข่ายประสาทเทียมแบบไปข้างหน้า




รูปที่ 2.21 การทำงานของ Forward Propagation และ Backward Propagation  
(<https://smarterbeta.wordpress.com/>)

Backpropagation Through Time (BPTT) เป็นคำที่ใช้เรียกการทำงานแบบย้อนกลับในโครงข่ายประสาทเทียมแบบวนซ้ำ ทำให้ทราบว่าเกิดอะไรขึ้นบ้างในโครงข่ายประสาทเทียมสำหรับกระบวนการพัฒนาในการเขียน โปรแกรมโครงข่ายประสาทเทียมแบบวนซ้ำ จำเป็นต้องทำ Backpropagation Through Time เพื่อทดสอบการทำงานย้อนกลับในโครงข่าย เพื่อให้มั่นใจว่าสามารถทำงานได้อย่างถูกต้องแม่นยำ (Mazumdar and Harley, 2008)

โครงข่ายประสาทเทียมแบบวนซ้ำอาจมองได้ในลักษณะของโครงข่ายที่ถูกฝึกฝนให้มีการเรียนรู้อย่างมีลำดับขั้นและถูกวัดผลทีละโครงข่าย รูปที่ 2.22 แสดงให้เห็นลักษณะของโครงข่ายประสาทเทียมแบบวนซ้ำที่ถูกกางออก (Unrolled) ซึ่งแสดงให้เห็นภาพรวมของโครงสร้าง

โครงข่ายได้เข้าใจมากขึ้น และจะพบว่าไม่มีการวนกลับเนื่องจากแสดงผลตามลำดับเวลาจากโครงข่ายหนึ่งไปยังอีกโครงข่ายหนึ่งตามลำดับเวลา การแสดงผลลักษณะทางออกแบบนี้จะทำให้ตรวจสอบค่าข้อมูลได้แม่นยำขึ้น



รูปที่ 2.22 โครงข่ายประสาทเทียมแบบวนซ้ำที่ถูกล้างออก

การทำ BPTT จำเป็นต้องมองเป็นภาพแบบกางออกข้างต้น เพื่อให้เห็นค่า Error ที่เกิดขึ้น ณ เวลาต่าง ๆ ได้ชัดเจน และจะพบว่า Error ที่เกิดขึ้น ณ เวลานั้นมักขึ้นอยู่กับเวลาก่อนหน้าเสมอโดยการทำ BPTT ค่า Error จะถูกตรวจสอบย้อนกลับจากเวลาสุดท้าย มาจนถึงเวลาเริ่มต้น ลักษณะดังกล่าวทำให้การคำนวณค่า Error แต่ละช่วงเวลาสามารถทำได้และสามารถปรับค่าน้ำหนักได้ด้วย อย่างไรก็ตามด้วยวิธีนี้การคำนวณจะช้าลงเมื่อมีช่วงเวลาที่มากขึ้น

ประเด็นที่จะต้องระวังเมื่อทำงานกับโครงข่ายประสาทเทียมแบบวนซ้ำคือ Vanishing Gradient (Hochreiter, 1998) โดยที่ Gradient คือ Partial Derivative ที่เกิดขึ้นเมื่อมี Input กล่าวคือ เป็นค่าที่ใช้วัดการเปลี่ยนแปลง Output ที่ได้จากฟังก์ชันเมื่อมีการเปลี่ยน Input เพียงเล็กน้อย (เมื่อเปลี่ยน Input ค่า Output จะเปลี่ยนไปเท่าใด) บางครั้งอาจเรียก Gradient ว่าเป็นค่าความชันของฟังก์ชัน หากความชันมีค่ามาก โมเดลชนิดนั้นจะเรียนรู้ได้เร็ว แต่หากความชันมีค่าเป็น 0 โมเดลนั้นจะหยุดเรียนรู้ Gradient ใช้วัดการเปลี่ยนแปลงของค่าน้ำหนักได้เป็นอย่างดีเมื่อค่าของ Error เปลี่ยนไป ดังนั้น Vanishing Gradient คือ การที่ค่าความชันของฟังก์ชันมีน้อยเกินไปและโมเดลหยุดการเรียนรู้หรือเรียนรู้นานเกินไป

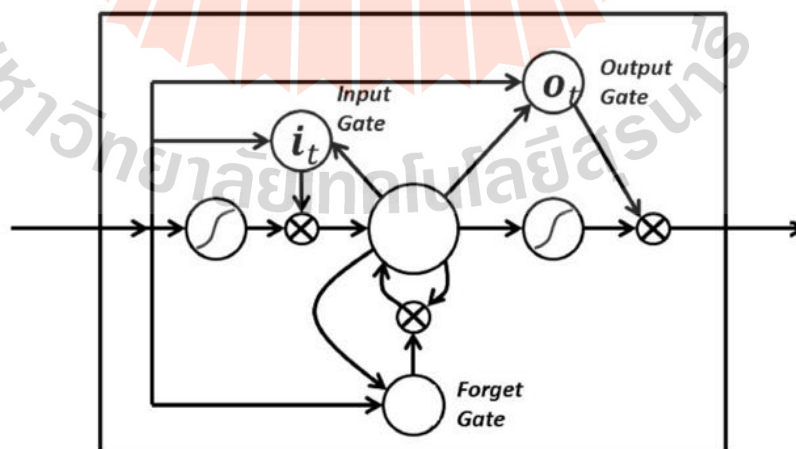
จากที่กล่าวมาข้างต้นจะเห็นได้ว่าข้อเสียของโครงข่ายประสาทเทียมแบบวนซ้ำคือ จะมีความจำระยะสั้น (Short-Term Memory) แต่หากนำมาทำงานร่วมกับ Long-Short-Term Memory (LSTM) จะทำให้สามารถมีความจำระยะยาวได้ (Graves, 2012)

### 2.5.3 หน่วยความจำระยะสั้นระยะยาว

โครงข่ายแบบหน่วยความจำระยะสั้นระยะยาว (Long Short-Term Memory, LSTM) เป็นส่วนเสริมของโครงข่ายประสาทเทียมแบบวนซ้ำ เพื่อขยายความสามารถด้านความจำ ดังนั้นจึงเหมาะกับการเรียนรู้ประสบการณ์สำคัญที่มีช่วงเวลายาวนาน โดยที่หน่วยของ LSTM ถูกนำไปใช้กำหนดเป็นหน่วยของเลเยอร์ของโครงข่ายประสาทเทียมแบบวนซ้ำ ซึ่งนิยมเรียกว่า “LSTM Network”

LSTM ช่วยให้โครงข่ายประสาทเทียมแบบวนซ้ำสามารถจดจำ Input ที่เข้ามาได้ตลอดระยะเวลา ทั้งนี้เนื่องจาก LSTM บรรจุข้อมูลข่าวสารไว้ในความจำ ซึ่งมีลักษณะเหมือนหน่วยความจำของคอมพิวเตอร์ เพราะ LSTM สามารถอ่าน เขียนและลบข้อมูลเหล่านั้นออกจากความจำได้เช่นกัน โดยความจำของ LSTM จะมีลักษณะเป็นเซลล์ของประตู (Gate cells) ซึ่งหมายความว่าเซลล์ประตุนั้นสามารถตัดสินใจได้ว่า จะจับเก็บหรือลบข้อมูล (สถานะของประตูจึงมี 2 สถานะคือ เปิด หรือ ปิด) ขึ้นอยู่กับความสำคัญที่ถูกกำหนดขึ้นที่ข้อมูลซึ่งค่าความสำคัญดังกล่าวจะเกิดขึ้นตลอดเวลาที่กำหนด ซึ่งสามารถเรียนรู้ค่าดังกล่าวได้ด้วยอัลกอริทึม กล่าวคือ โมเดลจะมีการเรียนรู้ตลอดเวลาถ้าข้อมูลนั้นมีความสำคัญและจะหยุดเรียนรู้เมื่อข้อมูลนั้นไม่มีความสำคัญ

ใน LSTM จะมี 3 ประตู ได้แก่ Input Gate, Forget Gate และ Output Gate ประตูเหล่านี้ทำหน้าที่พิจารณาว่าจะอนุญาตให้ Input ใหม่เข้ามาหรือไม่ (Input gate) จะลบข้อมูลเมื่อพบว่าไม่มีความสำคัญ (Forget Gate) หรืออนุญาตให้สร้างเป็น Output ได้ ณ ช่วงเวลาปัจจุบัน (Output Gate) ดังแสดงในรูปที่ 2.23



รูปที่ 2.23 โครงสร้างของโครงข่ายแบบหน่วยความจำระยะสั้นระยะยาว

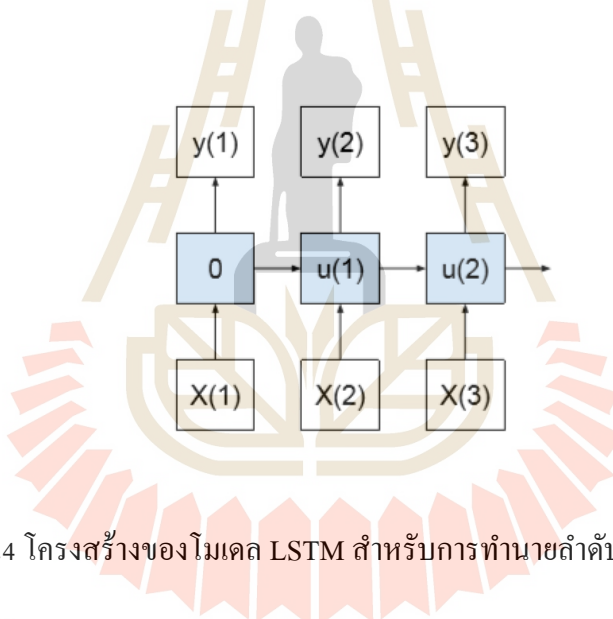
ประตูใน LSTM ทำงานแบบแอนะล็อกในรูปแบบของซิกมอยด์ กล่าวคือ มีค่าอยู่ในช่วง 0-1 และเนื่องจากทำงานแบบแอนะล็อก จึงทำให้ LSTM สามารถทำ Backpropagation ได้

ส่วนในกรณีปัญหาเรื่อง Vanishing Gradient หรือค่าความชันน้อยเกินไปจะทำให้โมเดลหยุดเรียนรู้จะถูกแก้ไขได้ด้วย LSTM เนื่องจากสามารถคงค่าความชันที่พอเหมาะไว้ได้ ดังนั้นจึงทำให้การฝึกฝนโมเดลให้เรียนรู้จึงใช้เวลาไม่นานแต่มีความแม่นยำสูง

โมเดล LSTM มีหลากหลายโครงสร้าง ซึ่งแต่ละโครงสร้างเหมาะสมกับการทำนายข้อมูลในรูปแบบที่แตกต่างกันดังนี้

### 1) การทำนายลำดับแบบหนึ่งต่อหนึ่ง


โครงสร้างของโมเดลรูปแบบนี้เหมาะสำหรับปัญหาการทำนายข้อมูลที่จะเกิดขึ้นในตอนถัดไปโดยการป้อนข้อมูลในขั้นตอนปัจจุบัน (ดังแสดงในรูปที่ 2.24) ตัวอย่างเช่นการใช้โมเดลนี้ในการทำนายคำถัดไปที่เป็นไปได้ในประโยค



รูปที่ 2.24 โครงสร้างของโมเดล LSTM สำหรับการทำนายลำดับแบบหนึ่งต่อหนึ่ง

### 2) การทำนายลำดับแบบหนึ่งต่อหลาย


โครงสร้างของโมเดลรูปแบบนี้ (รูปที่ 2.25) เหมาะสำหรับปัญหาการทำนายตามลำดับที่เราต้องการสร้างเอาต์พุตตามลำดับสำหรับแต่ละขั้นตอนของเวลาอินพุต ตัวอย่างเช่นเราใช้โมเดลนี้เพื่อทำนายลำดับของคำจากภาพเดียวหรือคาดการณ์ชุดการสังเกตจากเหตุการณ์เดียว



รูปที่ 2.25 โครงสร้างของแบบโมเดล LSTM สำหรับการทำนายลำดับแบบหนึ่งต่อหลาย

### 3) การทำนายลำดับแบบหลายต่อหนึ่ง

โครงสร้างของโมเดลรูปแบบนี้ (รูปที่ 2.26) เหมาะสำหรับการทำนายปัญหาที่ต้องใช้หลายขั้นตอนเวลาอินพุตเพื่อทำนายขั้นตอนเดียวถัดไป ตัวอย่างเช่นการคาดการณ์มูลค่าจริงต่อไปในชุดเวลาที่กำหนดลำดับของการสังเกตการป้อนข้อมูล




รูปที่ 2.26 โครงสร้างของโมเดล LSTM สำหรับการทำนายลำดับแบบหลายต่อหนึ่ง

### 4) การทำนายลำดับแบบหลายต่อหลาย

โครงสร้างของโมเดลรูปแบบนี้ (รูปที่ 2.27) เหมาะสำหรับการทำนายลำดับที่ต้องใช้หลายขั้นตอนเวลาเข้า เพื่อทำนายลำดับของขั้นตอนเวลาส่งออก ซึ่งมักเรียกว่าปัญหาเกี่ยวกับการเรียงลำดับตามลำดับ หรือ Seq2Seq ตัวอย่างเช่นการใช้โมเดลนี้เพื่อสรุปเอกสารคำเพื่อเรียงลำดับคำที่สั้นกว่าหรือจัดลำดับของข้อมูลเสียงเป็นลำดับของคำ





รูปที่ 2.27 โครงสร้างของโมเดล LSTM สำหรับการทำนายลำดับแบบหลายต่อหลาย

## 2.6 ค่าเฉลี่ยเคลื่อนที่

ค่าเฉลี่ยเคลื่อนที่ (Moving Average หรือ MA) เป็นเครื่องมือวิเคราะห์ทางเทคนิคที่แสดงค่าเฉลี่ยของราคา ณ ช่วงเวลาหนึ่ง ๆ ที่กำหนด โดยค่าเฉลี่ยเคลื่อนที่นี้นักลงทุนนิยมใช้เป็นเครื่องมือในการวิเคราะห์แนวโน้มของราคา

ในการคำนวณค่าเฉลี่ยเคลื่อนที่ของราคาหุ้น หรือดัชนีของราคาอัตราแลกเปลี่ยนเงินตราต่างประเทศ โดยใช้ข้อมูลของราคาย้อนหลังโดยมีการกำหนดระยะเวลาที่จะมองย้อนหลัง เช่น ถ้าเราสนใจค่าเฉลี่ยเคลื่อนที่ของดัชนีของราคาอัตราแลกเปลี่ยนเงินตราต่างประเทศคู่เงิน EURUSD ระยะเวลาย้อนหลัง 10 คาบเวลา เราจะใช้ราคาอัตราแลกเปลี่ยนเงินตราต่างประเทศคู่เงิน EURUSD 10 คาบเวลาย้อนหลังนับจากคาบเวลาปัจจุบัน มาคำนวณด้วยสูตรของค่าเฉลี่ยประเภทที่เราสนใจ โดยสูตรคำนวณค่าเฉลี่ยเคลื่อนที่มีอยู่ด้วยกันหลายประเภท ยกตัวอย่างเช่น ค่าเฉลี่ยเคลื่อนที่อย่างง่าย (Simple Moving Average, SMA) ค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนัก (Weighted Moving Average, WMA) และค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนักซับซ้อน (Exponential Moving Average, EMA) เป็นต้น การใช้รูปแบบการหาค่าเฉลี่ยเคลื่อนที่นั้นสามารถบอกแนวโน้มของราคาได้อย่างชัดเจนว่าเป็น แนวโน้มขาขึ้นหรือแนวโน้มขาลง

### 2.6.1 ค่าเฉลี่ยเคลื่อนที่อย่างง่าย

ค่าเฉลี่ยเคลื่อนที่อย่างง่าย (Simple Moving Average หรือ SMA) เป็นการหาค่าเฉลี่ยโดยให้น้ำหนักการเคลื่อนที่ของราคาแต่ละวันเท่ากัน (Kilgallen, 2012) สามารถคำนวณได้จากกรนำผลรวมของราคาในคาบเวลาที่เรากำหนดหารด้วยจำนวนคาบเวลา ดังแสดงในสมการที่ 2.6

$$SMA = \frac{\sum_{i=1}^N X_i}{N} \quad (2.6)$$

โดยที่  $X_i$  คือ ราคาของคาบเวลาที่  $i$  และ  $N$  คือจำนวนคาบเวลาที่กำหนด

### 2.6.2 ค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนัก

ค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนัก (Weighted Moving Average หรือ WMA) เป็นการหาค่าเฉลี่ยโดยให้น้ำหนักการเคลื่อนที่ของราคาเวลาแรกน้อยที่สุดและเพิ่มน้ำหนักให้กับคาบเวลาถัด ๆ ไป (Hunter, 1986) สามารถคำนวณได้จากสมการที่ 2.7

$$WMA = \frac{\sum_{i=1}^N (X_i \times w_i)}{\sum_{i=1}^N w_i} \quad (2.7)$$

โดยที่  $X_i$  คือ ราคาของคาบเวลาที่  $i$ ,  $N$  คือจำนวนคาบเวลาที่กำหนด และ  $w_i$  คือถ่วงน้ำหนักของข้อมูลในแต่ละคาบเวลา

### 2.6.3 ค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนักซับซ้อน

ค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนักซับซ้อน (Exponential Moving Average หรือ EMA) เป็นการหาค่าเฉลี่ยโดยนำค่าเฉลี่ยของคาบเวลาก่อนหน้ามาใช้ในการคำนวณและให้น้ำหนักการเคลื่อนที่ของคาบเวลาล่าสุดมากที่สุด (Grebekov and Serror, 2014) ซึ่งค่า EMA สามารถคำนวณได้จากสมการที่ (2.8) และ (2.9)

$$EMA = X_i \times \alpha + EMA_{(y)} \times (1 - \alpha) \quad (2.8)$$

$$\alpha = \frac{2}{N+1} \quad (2.9)$$

โดยที่  $X_i$  คือราคาของคาบเวลาที่  $i$ ,  $N$  คือจำนวนคาบเวลาที่กำหนด,  $\alpha$  คือการหาค่าเฉลี่ย โดยการนำค่าเฉลี่ยของวันก่อนหน้ามาใช้ในการคำนวณและให้น้ำหนักการเคลื่อนที่ของวันล่าสุดมากที่สุด และ  $EMA_{(y)}$  คือค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนักซับซ้อนของคาบเวลาก่อนหน้า โดยในคาบเวลาแรกให้ใช้ค่า SMA แทน

## 2.7 มาตรการประสิทธิภาพของโมเดล

### 2.7.1 ความแม่นยำโดยรวม

ค่าความแม่นยำโดยรวม (Accuracy) จะเป็นตัวบ่งบอกถึงประสิทธิภาพความถูกต้องในการทำนายคลาสเป้าหมาย ซึ่งค่า Accuracy สามารถคำนวณได้จากสมการที่ 2.10

$$Accuracy = \frac{(TP + TN)}{(TP + FN + FP + TN)} \quad (2.10)$$

*TP* คือ จำนวนของข้อมูลที่โมเดลทำนายได้ตรงกับข้อมูลทดสอบซึ่งเป็นผลลัพธ์เชิงบวก

*TN* คือ จำนวนของข้อมูลที่โมเดลทำนายได้ตรงกับข้อมูลทดสอบซึ่งเป็นผลลัพธ์เชิงลบ

*FP* คือ จำนวนของข้อมูลที่โมเดลทำนายได้ผลลัพธ์เชิงลบ ซึ่งตรงข้ามกับข้อมูลทดสอบเป็นผลลัพธ์เชิงบวก

*FN* คือ จำนวนของข้อมูลโมเดลทำนายได้ทำนายได้ทำนายได้ผลลัพธ์เชิงบวก ซึ่งตรงข้ามกับข้อมูลทดสอบเป็นผลลัพธ์เชิงลบ

ค่า *TP*, *TN*, *FP* และ *FN* นั้น ได้มาจากตาราง Confusion Matrix ตัวอย่างตาราง Confusion Matrix แสดงในตารางที่ 2.3

ตารางที่ 2.3 ตาราง Confusion Matrix

		Actual Data	
		Positive	Negative
Predicted Data	Positive	<i>TP</i>	<i>FP</i>
	Negative	<i>FN</i>	<i>TN</i>

### 2.7.2 ความแม่นยำที่สนใจเฉพาะส่วนที่ทำนาย

ความแม่นยำที่สนใจเฉพาะส่วนที่ทำนาย (Precision) คือความน่าจะเป็นที่โมเดลทำนายถูกต้องจากการทำนายทั้งหมด ซึ่งคำนวณได้จากสมการที่ (2.11)

$$Precision = \frac{TP}{TP + FP} \quad (2.11)$$

### 2.7.3 ค่าระลึกหรือความครอบคลุมของการทำนาย

ค่าระลึกหรือความครอบคลุมของการทำนาย (Recall) คือความน่าจะเป็นที่โมเดลสามารถทำนายได้จากจำนวนข้อมูลทั้งหมดในชุดข้อมูล โดยที่ค่า Recall สามารถคำนวณได้จากสมการที่ (2.12)

$$Recall = \frac{TP}{TP + FN} \quad (2.12)$$

### 2.7.4 ค่าเฉลี่ยระหว่าง Precision และ Recall

ค่าเฉลี่ยระหว่าง Precision และ Recall เรียกว่า (F-Measure) คือค่าเฉลี่ยแบบ harmonic mean ระหว่างค่า Precision และ Recall ซึ่งค่า F-Measure ถูกคิดค้นขึ้นมาเพื่อเป็น single metric ที่วัดความสามารถของโมเดล โดยที่ไม่ต้องเลือกระหว่างค่า Precision หรือค่า Recall เพราะเฉลี่ยให้แล้ว ค่า F-Measure สามารถคำนวณได้จากสมการที่ (2.13)

$$F - Measure = 2 \times \left( \frac{Precision \times Recall}{Precision + Recall} \right) \quad (2.13)$$

## 2.8 งานวิจัยที่เกี่ยวข้อง

การวิเคราะห์ข้อมูลทางการเงินแบบอนุกรมเวลาได้รับความสนใจอย่างมากในช่วง 2 ทศวรรษที่ผ่านมาจากนักลงทุน (Investor) นักเศรษฐศาสตร์ (Economist) รวมไปถึงนักวิจัยด้านนักวิทยาศาสตร์ข้อมูล (Data Scientist) (Tsay, 2005) ทั้งนี้มีงานวิจัยหลากหลายที่ได้นำความรู้และทฤษฎีที่เกี่ยวข้องกับการวิเคราะห์ข้อมูลทางการเงินแบบอนุกรมเวลาไม่ว่าจะเป็นเครื่องมือชี้วัดทางเทคนิค แบบจำลองสำหรับการวิเคราะห์อนุกรมเวลารวมไปถึงเทคโนโลยีขั้นสูงด้านการคำนวณและปัญญาประดิษฐ์ ซึ่งนำไปสู่การคิดค้นและพัฒนาเครื่องมือที่ช่วยเพิ่มขีดความสามารถของนักลงทุนในการวิเคราะห์แนวโน้มความเคลื่อนไหวและหาจุดที่เหมาะสมที่สุดสำหรับการซื้อขายสินทรัพย์ในตลาดหลักทรัพย์และตลาดการซื้อขายเงินตราต่างประเทศ

ในวิทยานิพนธ์เล่มนี้ ผู้เขียนได้มุ่งเน้นไปที่ตลาดการซื้อขายเงินตราต่างประเทศซึ่งเป็นตลาดการเงินที่มีขนาดใหญ่ที่สุดในโลก (Jacque, 2013) ในเนื้อหาส่วนนี้ผู้เขียนได้ทำการทบทวนวรรณกรรมงานวิจัยต่าง ๆ ที่เกี่ยวข้องกับสิ่งที่กล่าวมาแล้วข้างต้นตั้งแต่ปี ค.ศ. 2000 จนถึงสิ้นปี ค.ศ. 2018 สรุปได้ดังตารางที่ 2.5 โดยใช้คำย่ออ้างอิงตามตารางที่ 2.4

ตารางที่ 2.4 อธิบายรายละเอียดตัวย่อที่ปรากฏในการทบทวนวรรณกรรม

Acronym	Interpretation	Acronym	Interpretation
AIC	Akaike information criterion	HKD	Hong Kong Dollar
ANN	Artificial Neural Network	INR	Indian rupee
ANN-GARCH	Artificial Neural Network and Generalized Autoregressive Conditional Heteroskedasticity	JPY	Japanese Yen
APE	Absolute Percentage Error	LDA	Linear discriminant analysis
ARIMA	Autoregressive Integrated Moving Average	MAD	Mean Absolute Deviation
ARIMA-FNN	Autoregressive Integrated Moving Average and Fuzzy Neural Network	MAE	Mean Absolute Error
ASTAR	Adaptive Spline Threshold Autoregression	MAPE	mean absolute percentage error
AUD	Australian Dollar	ME	Mean Error
BIC	Bayesian Information Criterion	MLP	multilayer perceptron
BPNN	Back propagation neural network	MSE	Mean Square Error
BPR	Banque Populaire du Rwanda	NMSE	Normalized Mean Square Error
CHF	Switzerland Franc	NN	Neural Network
CU	Correct Up trend	NZD	New Zealand Dollar
DA	directional accuracy	PNP	Percentage normalized profit
DEM	German Deutsche Mark	RBF	Radial basis function
DRNN-ARIMA	Dynamic recurrent neural networks and Autoregressive Integrated Moving Average	RMSE	Root Mean Square Error
DS	Directional Symmetry	RNN	Recurrent Neural Network
EGP	Egyptian Pound	ROI	Return on Investment
EMA	Exponential Moving Average	RW	random walk
FNN	Fuzzy Neural Network	SAR	Saudi Arabian Riyal
GA	Genetic Algorithm	SGD	Singapore dollar
GANN	Genetic Algorithm and Neural Network	SVM	Support Vector Machine
GARCH	Generalized Autoregressive Conditional Heteroskedasticity	SVR	Support Vector Regression
GASVM	Genetic Algorithm and Support Vector Machine	USD	United States dollar
GBP	British Pound		

ตารางที่ 2.5 งานวิจัยต่าง ๆ ที่เกี่ยวข้องกับการวิเคราะห์ข้อมูลตลาดซื้อขายเงินตราต่างประเทศ และการซื้อขายด้วยเลขไบนารี (เรียงตามลำดับเหตุการณ์)

Year	Author(s)	Based model(s)	Compared model(s)	Winner	Forex data	Evaluation metrics
2000	Yao and Tan (2000)	NN	ARIMA	NN	AUD/USD, CHF/USD, DEM/USD, GBP/USD and JPY/USD	NMSE, Return (%)
2003	Kamruzzaman and Sarker (2003a)	ANN	ARIMA	ANN	USD, GBP, JPY, SGD, NZD, CHF	NMSE, MAE, DS
2003	Kamruzzaman, Sarker and Ahmad (2003)	SVM	ARIMA, ANN	SVM	USD, GBP, JPY, SGD, NZD, CHF	NMSE, MAE, DS, CU, CD
2003	Kamruzzaman and Sarker (2003b)	ANN	ARIMA	ANN	GBP, SGD, BPR	NMSE, MAE, DS, CU, CD
2004	Kamruzzaman and Sarker (2004a)	SVM	ANN, ARIMA	SVM	GBP, USD, JPY, SGD, NZD, CHF	NMSE, MAE, DS, CU, CD
2004	Kamruzzaman and Sarker (2004b)	ANN	-	-	GBP, USD, JPY, SGD, NZD, CHF	NMSE, MAE, DS, CU, CD
2005	Cao, Pang and Bai (2005)	SVM	-	-	GBP/USD	MSE
2007	Yu, Wang and Lai (2007)	GASVM	GA, RW, ARIMA, LDA, BPNN, SVM, ANN	GASVM	US dollar against broad index currencies	Hit ratio (%)
2008	Eng et al. (2008)	ANN	-	-	GBP/USD	RMSE, DA
2008	Li, Shao and Zheleva (2008)	RNN	-	-	EUR, GBP, CHF, AUD, CAD, JPY compared to the U.S. dollar	Out-of-sample forecast errors
2011	Baasher and Fakhr (2011)	SVM	MLP	SVM, RBF	USD/JPY, USD/EGP, EUR/EGP, EUR/SAR	PNP
2013	Lavanya and Parveentaj (2013)	ANN	-	-	USD/CHF, USD/CHF	APE, MAPE
2014	Xiao et al. (2014)	ARIMA-FNN	FNN, ARIMA	ARIMA-FNN	EUR/USD, GBP/USD, USD/CAD	MAE, MAPE, RSME, DC
2014	Stankeviciene, Maknickiene and Maknickas (2014)	RNN	-	-	USD/CHF, USD/CHF	APE, MAPE
2015	Babu (2015)	ARIMA	NN, Fuzzy	ARIMA	Indian Rupees against USD, GBP, Euro and Yen	AIC and BIC
2015	Nyoni (2018)	ARIMA	-	-	Naira/USD	AIC, ME, RMSE, MAE, MPE, MAPE and Theil's U
2016	Sidehabi, Indrabayu and Tandungan (2016)	ASTAR	SVM, GANN	ASTAR and GANN	EUR/USD	RMSE
2016	Rani and Haragopal (2016)	ANN	MLP, ARIMA	ANN	INR/USD	RMSE, MAE, MAPE, AIC

Year	Author(s)	Based model(s)	Compared model(s)	Winner	Forex data	Evaluation metrics
2017	Mucaj (2017)	ANN	ARIMA	ANN	Euro against all currencies	MSE
2017	Pathberiya, Tilakaratne and Hansen (2017)	ANN-GARCH	ANN, GARCH	ANN-GARCH	EUR/USD	MSE, Profit/Loss in pips
2017	Handa, Shrivastava and Hota (2019)	RNN	SVR	SVR	INR/USD, EUR/USD, HKD/USD	MAPE, MAD, RSME
2018	Weerathunga and Silva (2018)	DRNN-ARIMA	ANN, DRNN, ARIMA	DRNN-ARIMA	EUR/USD	MAPE, MSE, MAPE, MSE
2018	de Almeida et al. (2018)	GASVM	SVM	GASVM	EUR/USD	ROI, Max. Drawdown
2018	Thu and Xuan (2018a)	SVM	SVM with kernel functions of Gaussian RBF and Polynomial	SVM with Polynomial	EUR/USD	Accuracy, Profits, Growth
2018	Thu and Xuan (2018b)	SVM	SVM with different kernel functions	SVM-Poly	EUR/USD	Accuracy, Profits, Growth
2018	Kipruto et al. (2018)	ANN	-	-	Kenya against USD, EUR, GBP, JPY	RMSE, MAE, MAPE
2018	McNally, Roche and Caton (2018)	LSTM	ARIMA, RNN	LSTM	Bitcoin price in USD	Accuracy, RMSE
2018	Huisu et al. (2018)	rolling window LSTM	SVR, LR, NN, LSTM	rolling window LSTM	USD/JPY, USD/CNY, USD/CHF, USD/BTC	MAPE, RMSE

ปี ค.ศ. 2000 Yao and Tan (2000) รายงานหลักฐานเชิงประจักษ์ว่าโมเดลโครงข่ายประสาทเทียม (Artificial Neural Network, ANN) สามารถนำไปใช้กับการทำนายอัตราแลกเปลี่ยนเงินตราต่างประเทศได้ วิธีการที่พวกเขาใช้คือการป้อนข้อมูลอนุกรมเวลาและตัวชี้วัดทางเทคนิค (Technical Indicator, TA) เช่น ค่าเฉลี่ยเคลื่อนที่ (Moving Average, MA) เข้าสู่เครือข่ายประสาทเทียมเพื่อตรวจจับกฎพื้นฐานของการเคลื่อนไหวในอัตราแลกเปลี่ยนสกุลเงิน เครือข่ายประสาทเทียมที่ผ่านการฝึกฝนแล้วถูกนำมาใช้ในการคาดการณ์อัตราแลกเปลี่ยนระหว่างสกุลเงิน US Dollar (USD) และอีก 5 สกุลเงินหลักคือ Japanese Yen (JPY), Deutsch Mark (DEM), British Pound (GBP), Swiss Franc (CHF) และ Australian Dollar (AUD) ผลลัพธ์จากการทดสอบประสิทธิภาพ โมเดลที่พวกเขาแนะนำแสดงให้เห็นว่าโมเดลที่ถูกสร้างขึ้นบนพื้นฐานของ ANN สามารถสร้างผลกำไรให้เกิดขึ้นได้สำหรับข้อมูลที่ไม่อยู่ในกลุ่มตัวอย่างฝึก (Out-Of-Sample Data) นอกจากนี้โมเดล ANN ยังมีประสิทธิภาพที่ดีกว่าอย่างมีนัยสำคัญเมื่อเปรียบเทียบกับโมเดลที่นิยมใช้กันก่อนหน้านี้ เช่น โมเดล Simple Autoregressive-Integrated-Moving-Average (ARIMA)

ในปี ค.ศ. 2003 Kamruzzaman และ Sarker (Kamruzzaman and Sarker, 2003a; 2003b) ได้ทำการพัฒนาและตรวจสอบประสิทธิภาพการพยากรณ์ ของโมเดลที่ถูกสร้างขึ้นโดยใช้โครงข่ายประสาทเทียม (ANN) จำนวน 3 รูปแบบโดยใช้ Standard Backpropagation (SBP), Scient Conjugate Gradient (SCG) และ Scalpagation Backsportpagation คิวบ Baysian Normalization (BPR) ข้อมูลที่ได้จากตัวชี้วัด MA ถูกนำมาใช้เป็นข้อมูลนำเข้าสำหรับสร้าง โมเดล ANN จากนั้นโมเดลที่ได้รับการฝึกฝนแล้วได้ถูกนำมาทดสอบกับข้อมูลการซื้อขายแลกเปลี่ยน 6 สกุลเงินที่แตกต่างกันประกอบด้วย USD, GBP, JPY, SGD, NZD, CHF เทียบกับสกุลเงิน AUD ผลการทดสอบแสดงให้เห็นว่า โมเดลทั้ง 3 โมเดลให้ประสิทธิภาพที่ดีกว่าโมเดล ARIMA

นอกจากนี้ในปลายปี ค.ศ. 2003 ทีมวิจัยของ Kamruzzaman (Kamruzzaman, Sarker and Ahmad, 2003) ยังทำการตรวจสอบประสิทธิภาพของ โมเดลที่ถูกพัฒนาขึ้นด้วย Support Vector Machine (SVM) เพื่อใช้สำหรับการพยากรณ์อัตราแลกเปลี่ยนของข้อมูลการซื้อขายแลกเปลี่ยน 6 สกุลเงินเปรียบเทียบกับสกุลเงิน AUD เช่นเดียวกับในงานวิจัยก่อนหน้านี้ของพวกเขา นอกจากนี้ยังได้ตรวจสอบผลกระทบของฟังก์ชันเคอร์เนล (Kernel Functions) ที่แตกต่างกัน 3 ฟังก์ชันคือ (1) เชิงเส้น (Linear) (2) พหุนาม (Polynomial) พื้นฐานรัศมี (Radial Basis) และ (3) เส้นโค้ง (Spline) ทั้ง 3 ฟังก์ชันนี้ส่งผลต่อข้อผิดพลาดการทำนายผลของโมเดล SVM โดยตรงเมื่อวัดประสิทธิภาพของโมเดลโดยใช้ตัวชี้วัด เช่น NMSE, MAE, DS, CU และ CD ผลการทดลองพบว่า ในมุมมองของข้อผิดพลาดในการทำนายนั้น โมเดล SVM ซึ่งใช้ฟังก์ชัน Polynomial Kernel ให้ผลลัพธ์ที่ดีที่สุด ในขณะที่ในการทำนายแนวโน้ม โมเดล SVM ซึ่งใช้ฟังก์ชัน Radial Basis และ Polynomial Kernel ให้ผลลัพธ์ที่ดีเท่าเทียมกัน



จากนั้นในปีถัดมา Kamruzzaman (2004a) ได้ทำการตรวจสอบประสิทธิภาพการทำนายของโมเดล ANN โดยใช้อัลกอริทึมการเรียนรู้ 3 แบบคือ SBP, SCG และ BPR โดยโมเดลทั้ง 3 ได้รับการฝึกฝนจากข้อมูลที่ใช้ตัวชี้วัดทางเทคนิค 5 ตัวชี้วัด คือ MA5, MA10, MA20, MA60 และ MA120 ซึ่งได้มาจากข้อมูลการซื้อขายแลกเปลี่ยนในอดีตของ 6 สกุลเงินหลักในตลาดซื้อขายเงินตราต่างประเทศได้แก่ สกุลเงิน GBP, USD, JPY, SGD, NZD และ CHF เปรียบเทียบกับสกุลเงิน AUD ซึ่งผลการศึกษาในครั้งนี้แสดงให้เห็นว่าโมเดล ANN-SCD มีประสิทธิภาพที่ดีในแง่ของมาตรวัดประสิทธิภาพโมเดล NMSE และ MAE

ในปีเดียวกัน Kamruzzaman and Sarker (2004b) ได้ทำการศึกษาเปรียบเทียบประสิทธิภาพของโมเดลที่ถูกพัฒนาบนพื้นฐานของ SVM ที่ใช้ Simple Linear Kernel เปรียบเทียบกับโมเดล ANN ที่ใช้อัลกอริทึม SCG โดยใช้ข้อมูลและมาตรวัดประสิทธิภาพของโมเดลเช่นเดียวกับในงานวิจัยก่อนหน้านี้ของพวกเขา ซึ่งผลการทดสอบพบว่าโมเดล SVM-simple linear มีประสิทธิภาพสูงกว่าโมเดล ANN-SCG

เช่นเดียวกับงานวิจัยของ Kamruzzaman, Sarker and Ahmad (2003c) ในปี ค.ศ. 2005 ทีมวิจัยที่ประกอบด้วย Cao, Pang และ Bai (2005) สร้างโมเดลสำหรับการทำนายอัตราแลกเปลี่ยนโดยใช้ SVM ฝึกสอนด้วยข้อมูลรายวันของอัตราแลกเปลี่ยน USD/GBP ตั้งแต่วันที่ 2 มกราคม 2546 ถึง 28 มกราคม 2548 โมเดลที่ได้มีวัตถุประสงค์เพื่อการทำนายแบบขั้นตอนเดียว (One-Step Prediction) ผลการวิจัยพบว่าโมเดล SVM มีประสิทธิภาพในการทำนาย ซึ่งสามารถใช้ในการทำนายแนวโน้มของอัตราแลกเปลี่ยนได้เป็นอย่างดี นอกจากนี้ยังตรวจสอบการตั้งค่าพารามิเตอร์ของ SVM และรู้ว่าพารามิเตอร์เหล่านี้มีบทบาทสำคัญต่อประสิทธิภาพของ SVM การตั้งค่าที่ไม่เหมาะสมนี้ทำให้ผลลัพธ์มีความแตกต่างกันมาก

จากข้อสรุปของ Cao, Pang และ Bai ที่กล่าวไว้ว่าการตั้งค่าพารามิเตอร์มีผลเป็นอย่างไรกับประสิทธิภาพของโมเดล SVM จากนั้นถัดมาอีก 2 ปี ในปี ค.ศ. 2007 Yu, Wang และ Lai (2007) ได้นำเทคนิคการเพิ่มประสิทธิภาพ (Optimization Technique) ด้วยอัลกอริทึมทางพันธุกรรม (Genetic Algorithm, GA) เพื่อค้นหาค่าที่เหมาะสมที่สุดสำหรับการตั้งค่าพารามิเตอร์ให้กับโมเดล SVM นอกจากนี้ GA ยังถูกใช้เพื่อการเลือกคุณสมบัติ (Feature Selection) ที่จะถูกใช้เป็นตัวแปรอินพุตสำหรับ SVM อีกด้วย ซึ่งข้อมูลที่น่ามาใช้เป็นตัวแปรอินพุตสำหรับ SVM ประกอบด้วยค่าที่ได้จากตัวชี้วัดทางเทคนิคจำนวน 23 ตัวชี้วัด ในการวัดประสิทธิภาพการทำนายของโมเดลนั้น ผลการวัดประสิทธิภาพโมเดลเมื่อเปรียบเทียบกับวิธีการแบบอื่น ๆ เช่น โมเดลทางสถิติ (Statistical Models) และ โมเดลโครงข่ายประสาทเทียม ANN ซึ่งผลการวิจัยพบว่าโมเดล GASVM มีประสิทธิภาพที่ดีที่สุด

ในปี ค.ศ. 2008 Eng et al. (2008) รายงานหลักฐานเชิงประจักษ์ว่า โมเดล ANN สามารถใช้สำหรับการทำนายอัตราแลกเปลี่ยนเงินตราต่างประเทศได้ โดยได้ทำการพัฒนา โมเดล ANN โดยใช้ข้อมูลปัจจัยพื้นฐานทางเศรษฐกิจเป็นข้อมูลนำเข้าสำหรับการฝึกฝน โมเดล ANN ผลการวิจัยพบว่าปัจจัยพื้นฐานทางเศรษฐกิจนั้นมีความสำคัญต่อการเคลื่อนไหวของอัตราแลกเปลี่ยนเงินตราต่างประเทศ แต่ทว่าความสัมพันธ์ที่ซ่อนเร้นอยู่ของปัจจัยเหล่านี้ไม่ได้มีผลต่อประสิทธิภาพในการทำนายของ โมเดล ANN แม้ว่าจะถูกใช้เป็นตัวแปรนำเข้าก็ตาม ซึ่ง Eng และทีมวิจัยได้กล่าวถึงเหตุผลที่ทำให้เป็นเช่นนั้นไว้ว่าอาจเป็นผลมาจากความถี่ของปัจจัยพื้นฐานทางเศรษฐกิจซึ่งมีการอัพเดทเป็นรายไตรมาส ทั้งนี้ตัวชี้วัดทางเศรษฐกิจที่มีการปรับปรุงบ่อยครั้งมากขึ้นอาจส่งผลให้การทำนายของ ANN มีประสิทธิภาพมากขึ้น

Li, Shao and Zheleva (2008) ได้นำเสนอการใช้อัลกอริทึม Discrete-Time Recurrent Neural Network (RNN) เพื่อเรียนรู้อัตราแลกเปลี่ยนเงินตราต่างประเทศระยะสั้น ข้อมูลการซื้อขายย้อนหลังของ 6 คู่เงินหลักที่สำคัญในตลาดแลกเปลี่ยนเงินตราต่างประเทศ ถูกเลือกมาใช้สำหรับการฝึกฝนและทดสอบประสิทธิภาพวิธีการที่ได้นำเสนอ ซึ่งผลลัพธ์ที่ได้จากการทดลองแสดงให้เห็นว่า โมเดล Discrete-Time RNN เป็นเครื่องมือที่มีแนวโน้มสำหรับใช้สำหรับการเรียนรู้และทำนายอัตราแลกเปลี่ยนเงินตราต่างประเทศในระยะสั้นได้

ในปี ค.ศ. 2013 Lavanya และ Parveentaj (2013) ใช้สมการถดถอยเชิงเส้น (Linear Regression Equation) เพื่อวิเคราะห์ข้อมูลในอดีตและค้นหารูปแบบแนวโน้มในตลาดแลกเปลี่ยนเงินตราต่างประเทศ โดยที่รูปแบบแนวโน้มเหล่านี้ถูกสร้างโดยอัลกอริทึม ANN และอัลกอริทึมการแปรปรวนเวลาแบบไดนามิก (Dynamic Time Warping) ซึ่งจะถูกใช้ในการทำนายแนวโน้มในอนาคตอันใกล้ของแนวโน้มในตลาด Forex ผลลัพธ์จากการทดลองแสดงให้เห็นผลลัพธ์ที่น่าพอใจโดยใช้วิธีการที่พวกเขาได้เสนอ

ถัดมาอีกหนึ่งปี Xiao et al. (2014) นำเสนอ โมเดลที่ใช้วิธีการ Multiscale Ensemble และโมเดลที่เป็นแบบลูกผสมระหว่าง โมเดล ARIMA กับ โมเดล Feedforward Neural Network (FNN) โดย โมเดล ARIMA ถูกใช้เพื่อสร้างการพยากรณ์เชิงเส้น (Linear Forecast) จากนั้น โมเดล FNN ถูกใช้สำหรับการจดจำรูปแบบไม่เป็นเชิงเส้น (Nonlinear) เพื่อแก้ไขข้อผิดพลาดจากการทำนายของ โมเดล ARIMA การสร้างและการทดสอบ โมเดลใช้ข้อมูลอัตราแลกเปลี่ยนรายสัปดาห์ของตลาดซื้อขายเงินตราต่างประเทศ ซึ่งผลการทดลองแสดงให้เห็นว่า ARIMA-FNN เป็น โมเดลที่มีประสิทธิภาพที่ดีเมื่อประเมินด้วยมาตรวัดประสิทธิภาพ MAE, MAPE, RSME และ DC

ในปีเดียวกัน Stankeviciene, Maknickiene และ Maknickas (2014) ได้พัฒนา โมเดลด้วยวิธีการ RNN โดยใช้ข้อมูลราคาสูงสุดและราคาต่ำสุดรายวันของตลาดซื้อขายเงินตราต่างประเทศในการเรียนรู้และทำนาย ผลการทดสอบประสิทธิภาพของ โมเดลพบว่า โมเดลที่สร้าง

ขึ้นจากข้อมูลราคาสูงสุดและต่ำสุดรายวันนี้ไม่สามารถใช้สำหรับคาดการณ์ข้อมูลแนวโน้มในอนาคตได้ ดังนั้นพวกเขาจึงได้ปรับเปลี่ยนข้อมูลนำเข้าโดยการแปลงข้อมูลจากเดิมให้อยู่ในรูปแบบของ Standard Deviation, Skewness และ Kurtosis ซึ่งส่งผลทำให้ประสิทธิภาพของโมเดลดีขึ้นอย่างมีนัยสำคัญ

ถัดมาในปี ค.ศ. 2015 Babu (2015) ตรวจสอบพฤติกรรมของอัตราแลกเปลี่ยนประจำวันของค่าเงินรูปีอินเดีย (INR) เทียบกับดอลลาร์สหรัฐ (USD), ปอนด์อังกฤษ (GBP), ยูโร (EUR) และเยนญี่ปุ่น (JPY) ซึ่งงานวิจัยนี้ยังมีความพยายามที่จะตรวจสอบประสิทธิภาพของโมเดล ARIMA, ANN และ Fuzzy Neuron ในการคาดการณ์สกุลเงินที่ซื้อขายในตลาดแลกเปลี่ยนเงินตราต่างประเทศของอินเดีย ผลการทดสอบโดยมาตรวัด AIC และ BIC ยืนยันว่าโมเดล ANN ทำงานได้ดีกว่าโมเดล ARIMA นอกจากนี้โมเดล Fuzzy Neuron มีประสิทธิภาพดีกว่าโมเดล ANN อย่างไรก็ตามในด้านการทำนายตลาดอัตราแลกเปลี่ยนของสกุลเงินอินเดียนั้น ผลปรากฏว่าโมเดล ARIMA ทำได้ดีกว่าโมเดล ANN และ Fuzzy Neuron

ในปี ค.ศ. 2017 และ 2018 จำนวนงานวิจัยที่เกี่ยวข้องกับการพัฒนา โมเดลเพื่อใช้ในการทำนายข้อมูลของตลาดซื้อขายเงินตราต่างประเทศนั้นเพิ่มขึ้นอย่างมากเมื่อเทียบกับปีก่อน ๆ Pathberiya, Tilakaratne และ Hansen (2017) นำเสนอข้อมูลเชิงลึกใหม่ที่ใช้ในการทำนายข้อมูลอนุกรมเวลาโดยการเปรียบเทียบประสิทธิภาพของเทคนิคทางสถิติซึ่งได้แก่ Adaptive Spline Threshold Autoregression (ASTAR) และกระบวนการเรียนรู้ของเครื่องได้แก่ SVM และเทคนิคซึ่งผสมผสานกันระหว่าง ANN และ GA ซึ่งจุดมุ่งหมายหลักของการพัฒนาเทคนิคนี้คือใช้ในการทำนายอัตราแลกเปลี่ยนเงินตราต่างประเทศ การเปรียบเทียบประสิทธิภาพระหว่างวิธีการทั้งสามวิธีนั้นใช้มาตรวัด RMSE ผลการทดสอบพบว่าเทคนิค ASTAR และ GA-NN มีประสิทธิภาพที่ดีกว่า SVM ในบางช่วงเวลาที่ทำการทดสอบ

Mucaj (2017) สร้าง โมเดลและพยากรณ์ตลาดแลกเปลี่ยนเงินตราต่างประเทศของสกุลเงินยูโรเปรียบเทียบกับทุกสกุลเงินทั่วโลก ตั้งแต่ปี ค.ศ. 2000 ถึง 2016 โดยใช้วิธีการ ANN และ ARIMA โมเดลทั้ง 2 จะถูกวัดประสิทธิภาพจากความถูกต้องในการทำนาย (Accuracy) ซึ่งผลการเปรียบเทียบประสิทธิภาพ พบว่าโมเดล ANN มีประสิทธิภาพมากกว่าโมเดล ARIMA

Handa, Shrivastava and Hota (2017) ตำรวจประสิทธิภาพในการทำนายของโมเดล 2 แบบคือ RNN และ Support Vector Regression (SVR) โดยใช้ข้อมูลย้อนหลัง 5 ปีของอัตราแลกเปลี่ยนหลากหลายสกุลเงินเทียบกับดอลลาร์สหรัฐ ในที่นี้เทคนิค Feature Selection ได้ถูกนำไปใช้เพื่อแยกคุณลักษณะใหม่ที่ซ่อนเร้นอยู่ในชุดข้อมูลเพื่อการปรับปรุงประสิทธิภาพของโมเดล จากผลการวัดประสิทธิภาพ โมเดลทั้ง 2 แบบ โดยใช้มาตรวัดซึ่งประกอบด้วย MAPE, MAD และ RSME พบว่าโมเดล SVR มีประสิทธิภาพดีกว่าโมเดล RNN

Nyoni (2018) สร้างโมเดล ARIMA เพื่อใช้สำหรับการคาดการณ์อัตราแลกเปลี่ยนสกุลเงิน Naira ของประเทศไนจีเรียเทียบกับ US dollar ในช่วงปี ค.ศ. 1960 - 2017 ผลการทดสอบโดยใช้มาตรวัด ME, RMSE, MAE, MPE, MAPE and Theil's U แสดงให้เห็นว่าโมเดลสามารถพยากรณ์ได้ถูกต้องค่อนข้างดี

Weerathunga and Silva (2018) เสนอการวิเคราะห์ทางเทคนิคของแนวโน้มระยะสั้นสำหรับการคาดการณ์ในราคา Forex โดยการบูรณาการโมเดล ANN, DRNN และ ARIMA ผลการวิจัยแสดงให้เห็นว่าวิธีการที่ได้นำเสนอซึ่งเกิดจากการรวมกันของโมเดล ARIMA และ ANN ช่วยปรับปรุงความแม่นยำเมื่อเทียบกับโมเดลเดี่ยว (ANN, DRNN และ ARIMA) ในงานวิจัยนี้กล่าวไว้ว่าโมเดล ANN ถูกใช้เพื่อเอาชนะปัญหาของ Non-linearity และ Non-stationarity ของราคาตลาดเงินตราต่างประเทศ ในขณะที่โมเดล ARIMA ใช้เพื่อให้ได้การคาดการณ์ที่เชื่อถือได้สำหรับการทำนายข้อมูลในอนาคต นอกจากนี้ DRNN ยังถูกใช้เพื่อเพิ่มความยืดหยุ่นในการเรียนรู้คุณสมบัติที่ซ่อนเร้นจำนวนมากของข้อมูลให้กับโมเดล ANN

Almeida, Neves and Horta (2018) เสนอวิธีการใหม่โดยใช้ GA และ SVM เพื่อใช้ทำนายการซื้อขายในตลาดแลกเปลี่ยนเงินตราต่างประเทศ โดยที่ SVM ถูกใช้ในการระบุและจำแนกสัญญาณซื้อขาย ในขณะที่ GA ถูกใช้เพื่อเพิ่มประสิทธิภาพของกฎการซื้อขาย โมเดลนี้ใช้ข้อมูลย้อนหลังของคู่สกุลเงิน EURUSD ในช่วงเวลาระหว่างปี 2003 ถึง 2016 เป็นข้อมูลฝึกและทดสอบโมเดล ผลจากงานวิจัยนี้แสดงให้เห็นว่าในช่วงระยะเวลาการทดสอบระหว่างวันที่ 2 มกราคมของปี 2015 จนถึงวันที่ 2 มีนาคมของปี 2016 เป็นช่วงเวลาที่โมเดลมีประสิทธิภาพที่ดีที่สุดซึ่งให้ผลตอบแทนการลงทุนเพิ่มขึ้นถึง 83%

Thu and Xuan (2018a; 2018b) พัฒนาระบบเทรดอัตโนมัติบนพื้นฐานของโมเดล SVM โดยใช้ Polynomial Kernel เทียบกับการใช้ Gaussian Kernel สำหรับการเทรดคู่เงิน EUR/USD ซึ่ง Thu และ Xuan ได้ให้ข้อสรุปไว้ว่าระบบเทรดอัตโนมัติของพวกเขาเป็นระบบที่มีประสิทธิภาพและมีศักยภาพที่จะสร้างผลกำไรในตลาดซื้อขายเงินตราต่างประเทศได้ ซึ่งการทดลองในงานวิจัยนี้ทำการทดสอบโดยใช้บัญชีทดลองเทรดเท่านั้น

Kipruto et al. (2018) อธิบายการประยุกต์ใช้ Back-Propagation Neural Network ในการสร้างโมเดลสำหรับการทำนายความผันผวนในการแลกเปลี่ยนสกุลเงินเคนยา (KES) เทียบกับ 4 สกุลเงินต่างประเทศคือ ดอลลาร์สหรัฐอเมริกา (USD), ยูโร (EUR), ปอนด์สหราชอาณาจักร (GBP) และเยนญี่ปุ่น (JPY) จากปี ค.ศ. 2005 ถึง 2007 ผลการทดสอบโมเดลพบว่า ในขณะที่เครือข่ายที่ได้รับการฝึกสอนอาจมีความสามารถในการทำงานอย่างถูกต้องในทางทฤษฎี แต่ Backpropagation ไม่สามารถหาคำตอบที่ดีที่สุดได้ในทุกกรณี

McNally, Roche and Caton (2018) ได้พัฒนาโมเดลโดยใช้หลักการเรียนรู้เชิงลึก (Deep Learning) จำนวน 2 โมเดลซึ่งประกอบด้วย โมเดล Bayesian optimized RNN และ โมเดล LSTM สำหรับการทำนายทิศทางและการเคลื่อนไหวของราคา Bitcoin ในหน่วยเงิน US dollar ผลการทดลองพบว่า LSTM ให้ความแม่นยำในการจำแนกสูงสุด 52% และค่า RMSE ต่ำสุดที่ 8% เมื่อเทียบกับโมเดล ARIMA

Huisu et al. (2018) ใช้โมเดล Rolling Window LSTM เพื่อทำนายราคาของ Bitcoin ซึ่งข้อมูลอินพุตสำหรับ โมเดล LSTM นี้ประกอบด้วยข้อมูลเศรษฐศาสตร์มหภาค (Macroeconomics) ข้อมูลอัตราส่วนสกุลเงินทั่วโลก (Global Currency Ratios) และข้อมูลบล็อกเชน (Blockchain) นอกจากนี้ทีมวิจัยของ Huisu ยังได้ทำการเปรียบเทียบประสิทธิภาพโมเดลที่ได้นี้กับโมเดลที่ใช้หลักการ Machine Learning ได้แก่ SVR, LR และ ANN ซึ่งผลการวิจัยระบุว่าโมเดล Rolling Window LSTM สามารถทำนายราคา Bitcoin ได้ดีอย่างแม่นยำและมีประสิทธิภาพสูงกว่าโมเดล Machine Learning อื่น ๆ ที่กล่าวมาแล้ว



## บทที่ 3

### วิธีดำเนินงานวิจัย

วัตถุประสงค์ของงานวิจัยนี้คือ การพัฒนา โมเดลซึ่งจะถูกใช้เป็นเครื่องมือสำหรับช่วยในการทำนายทิศทางแนวโน้มของราคาอ้างอิงในคาบเวลาถัดไป โดยใช้หลักการเรียนรู้เชิงลึกคือ LSTM นอกจากนี้ยังได้นำเสนอวิธีการที่ใช้ในการเพิ่มประสิทธิภาพด้านความแม่นยำในการทำนายให้กับ โมเดล LSTM อีกทั้งยังได้นำเสนอกลยุทธ์ที่ใช้ในการเทรดและกลยุทธ์ในการตัดขาดทุน เพื่อให้นักลงทุนนำไปใช้สร้างผลกำไรในการซื้อขายตัวเลือกไบนารี ในบทนี้จึงเป็นการนำเสนอในส่วนของกรอบแนวคิดงานวิจัย วิธีดำเนินงานวิจัย และเครื่องมือที่ใช้สำหรับการวิจัย ตามลำดับ

#### 3.1 กรอบแนวคิดงานวิจัย

กรอบแนวคิดของงานวิจัยนี้แบ่งออกเป็น 3 ส่วน โดยเนื้อหาส่วนแรกเกี่ยวข้องกับ การกำหนดขอบเขตของชุดข้อมูลที่ใช้ศึกษา รวมถึงหลักการและทฤษฎีที่นำมาใช้สำหรับการพัฒนา ซึ่งมีรายละเอียดดังนี้

- ข้อมูลย้อนหลังที่ประกอบด้วยราคาราคาปิดในทุก ๆ ช่วงเวลาราย 5 นาทีของราคาอ้างอิงการซื้อขายแลกเปลี่ยนเงินตราต่างประเทศของคู่เงินที่นักลงทุนส่วนใหญ่นิยมซื้อขายกันและมีมูลค่าในการซื้อขายมากกว่า 60 เปอร์เซ็นต์ของมูลค่าการซื้อขายในตลาดได้แก่ คู่สกุลเงิน EURUSD ตั้งแต่วันที่ 2 มกราคม ถึงวันที่ 30 เมษายน พ.ศ. 2562 รวมทั้งสิ้น 10,200 ข้อมูล
- เทคนิคการเรียนรู้เชิงลึกได้แก่ โครงข่ายประสาทแบบคอนโวลูชันและหน่วยความจำระยะสั้นระยะยาว
- เทคนิคการเรียนรู้ของเครื่องได้แก่ โครงข่ายประสาทเทียม และเครื่องเวกเตอร์สนับสนุน

เนื้อหาในส่วนที่ 2 คือผลผลิตของงานวิจัยอันประกอบด้วย เครื่องมือช่วยในการตัดสินใจและกลยุทธ์ที่ใช้ในการซื้อขาย รวมทั้งกลยุทธ์ที่ใช้ในการตัดขาดทุนที่เหมาะสมสำหรับใช้ในการซื้อขายตัวเลือกไบนารี ซึ่งมีรายละเอียดดังนี้

- โมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไป (Trend Prediction Model) ที่พัฒนาโดยใช้เทคนิค LSTM จำนวน 3 โมเดล ได้แก่  $LSTM_{UP}$ ,  $LSTM_{SW}$  และ  $LSTM_{DN}$  ซึ่งแต่ละโมเดลจะมีความเหมาะสมสำหรับทำนายข้อมูลตามประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในคาบเวลาถัดไปที่จะเกิดขึ้น
- เครื่องมืออัตโนมัติสำหรับการจำแนกประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนด (Trend Classification Model, TCM) โดย TCM ที่พัฒนาขึ้นนี้จะเป็เครื่องมือที่ถูกใช้เพื่อจำแนกประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในคาบเวลาที่กำหนดแทนที่การใช้ผู้เชี่ยวชาญในการจำแนก ซึ่งข้อมูลที่ถูกจำแนกด้วย TCM แต่ละประเภทจะถูกนำไปใช้ในการสร้างโมเดล LSTM
- กลยุทธ์ที่เหมาะสมสำหรับการซื้อขายตัวเลือกไบนารี
- กลยุทธ์สำหรับการตัดขาดทุนที่เหมาะสมสำหรับการซื้อขายตัวเลือกไบนารี

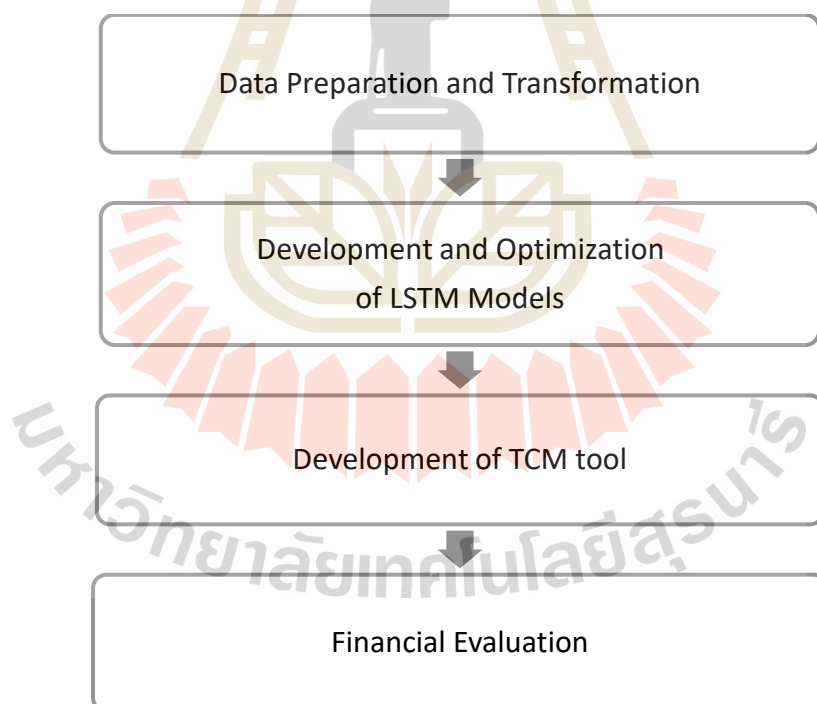
ในส่วนสุดท้ายเป็นการอธิบายเกี่ยวกับแนวทางการใช้งานเครื่องมือที่พัฒนาขึ้นไปใช้ให้เกิดประโยชน์ตามวัตถุประสงค์ของงานวิจัย มีรายละเอียดดังนี้

- วิธีนำเครื่องมือ TCM ไปใช้จำแนกประเภทแนวโน้มหรือประเภทการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาปัจจุบันเพื่อเลือกใช้โมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไปที่เหมาะสมที่สุด
- ข้อมูลที่ถูกจำแนกประเภทของแนวโน้มราคาอ้างอิงด้วยเครื่องมือ TCM จะถูกใช้เป็นข้อมูลนำเข้าสำหรับโมเดล LSTM ที่ตรงตามประเภทของข้อมูลประเภทนั้น ๆ เพื่อทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไป
- เมื่อทำนายแนวโน้มที่จะเกิดขึ้นในคาบเวลาถัดไปโดยใช้โมเดล LSTM แล้วข้อมูลที่ได้จะใช้เป็นตัวกำหนดทิศทางการเข้าซื้อ หรือ ขายในการลงทุนครั้งนั้น ๆ ด้วยจำนวนเงินลงทุนที่ถูกกำหนดไว้ในกลยุทธ์สำหรับการลงทุนที่ได้นำเสนอในงานวิจัยนี้

- เมื่อนักลงทุนขาดทุนอย่างต่อเนื่องและถึงจุดที่ต้องตัดขาดทุนที่ถูกกำหนดไว้ในกลยุทธ์การตัดขาดทุนที่นำเสนอไว้ เพื่อทำการรักษาเงินลงทุนส่วนใหญ่ในพอร์ตลงไว้

### 3.2 วิธีดำเนินงานวิจัย

ในงานวิจัยนี้ผู้วิจัยได้แบ่งขั้นตอนในการดำเนินการวิจัยออกเป็น 4 ขั้นตอนประกอบด้วย 1) การเตรียมข้อมูล การแปลงข้อมูล และการกำหนดค่านิยามให้กับข้อมูล 2) การพัฒนาและการเพิ่มประสิทธิภาพโมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไป 3) การพัฒนาเครื่องมือสำหรับจำแนกประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนด และ 4) การวัดประสิทธิภาพด้านการเงินของโมเดลในการซื้อขายตัวเลือกไบนารี ดังแสดงในรูปที่ 3.1 โดยการดำเนินงานวิจัยในแต่ละขั้นตอนมีรายละเอียด อธิบายในหัวข้อย่อย 3.2.1 ถึง 3.2.4



รูปที่ 3.1 กระบวนการดำเนินงานวิจัย



### 3.2.1 การเตรียมข้อมูล การแปลงข้อมูล และการกำหนดค่านิยามให้กับข้อมูล

#### 3.2.1.1 การเตรียมข้อมูล

ในขั้นตอนนี้จะเริ่มต้นจากการรวบรวมข้อมูลย้อนหลังของราคาอ้างอิงในการซื้อขายเงินตราต่างประเทศของคู่เงิน EURUSD ราย 5 นาที ในการวิจัยนี้ ผู้วิจัยใช้วิธีการเก็บรวบรวมโดยการนำออก (Export) จากแพลตฟอร์ม Meta Trader 4 (MT4) ซึ่งเป็นแพลตฟอร์มที่ใช้ในการซื้อขายเงินตราต่างประเทศจากโบรกเกอร์ต่าง ๆ เช่น Exness, FXPro และ FXCM เป็นต้น โดยข้อมูลที่น่าออกจากแพลตฟอร์ม MT4 นั้นจะเป็นข้อมูลที่สำคัญของกราฟแบบ OHLC (Golfinvz, 2016) ซึ่งจะอยู่ในรูปแบบไฟล์ CSV ที่ประกอบด้วย 7 คอลัมน์คือ 1) วันที่ 2) เวลา 3) ราคาเปิด 4) ราคาสูงสุด 5) ราคาต่ำสุด 6) ราคาปิด และ 7) ปริมาณการซื้อขายสุทธิในคาบเวลาที่สนใจ ผู้วิจัยทำการตัดเอาเฉพาะคอลัมน์ที่ 3 และ 6 คือข้อมูลราคาเปิดและราคาปิดของคาบเวลามาใช้เพื่อทำการทดลอง ดังแสดงในรูปที่ 3.2

1	Date	Time	Open	High	Low	Close	Volume
2	2018.07.04	17:30	1.16491	1.16495	1.16443	1.16481	413
3	2018.07.04	17:35	1.16481	1.1649	1.16444	1.16462	404
4	2018.07.04	17:40	1.16462	1.16471	1.16445	1.16468	302
5	2018.07.04	17:45	1.16468	1.16487	1.1645	1.16465	285
6	2018.07.04	17:50	1.16465	1.16465	1.16433	1.16435	399
7	2018.07.04	17:55	1.16435	1.16451	1.16425	1.16431	350
8	2018.07.04	18:00	1.16432	1.16445	1.16409	1.16409	534
9	2018.07.04	18:05	1.1641	1.16428	1.1641	1.16425	159
10	2018.07.04	18:10	1.16425	1.16434	1.16395	1.1641	317
11	2018.07.04	18:15	1.1641	1.1642	1.16399	1.16402	213
12	2018.07.04	18:20	1.16402	1.16408	1.16389	1.16405	101
13	2018.07.04	18:25	1.16405	1.16432	1.16392	1.16424	162
14	2018.07.04	18:30	1.16424	1.16424	1.16374	1.16385	217
15	2018.07.04	18:35	1.16385	1.16399	1.16384	1.16399	74

รูปที่ 3.2 ตัวอย่างข้อมูลย้อนหลังการซื้อขายเงินตราต่างประเทศของคู่เงิน EURUSD คาบเวลาราย 5 นาที

#### 3.2.1.2 การแปลงข้อมูล

เมื่อได้ข้อมูลราคาปิดของคาบเวลาราย 5 นาทีของข้อมูลย้อนหลังการซื้อขายเงินตราต่างประเทศของคู่เงิน EURUSD ซึ่งเป็นข้อมูลแบบอนุกรมเวลาแล้ว จากนั้นผู้วิจัยจะทำการแปลงข้อมูลเพื่อใช้เป็นข้อมูลนำเข้าเพื่อพัฒนาโมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของ

ราคาอ้างอิงในช่วงเวลาถัดไปโดยใช้เทคนิค LSTM และเครื่องมือสำหรับใช้ในการจำแนกประเภท แนวโน้มการเคลื่อนไหวของราคาในช่วงเวลาที่กำหนด โดยอาศัยหลักการเรียนรู้ของเครื่องได้แก่ SVM และ ANN รวมทั้งหลักการวิเคราะห์เทคนิคคือ MA ในหัวข้อนี้จะอธิบายกระบวนการที่ใช้ในการแปลงข้อมูลให้เหมาะสมกับการพัฒนาและทดสอบประสิทธิภาพของ โมเดลรวมทั้งเครื่องมือที่นำเสนอในงานวิจัยดังต่อไปนี้

- ข้อมูลสำหรับใช้เป็นข้อมูลนำเข้าในการพัฒนาโมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไป

ในขั้นตอนนี้ ข้อมูลที่จะต้องเตรียมจะอยู่ในรูปแบบของชุดข้อมูลอนุกรมเวลา ซึ่งเป้าหมายของงานวิจัยนี้คือ การทำนายว่าในคาบเวลาถัดไปของค่าอ้างอิงของอัตราแลกเปลี่ยนเงินตราต่างประเทศในคู่เงินที่กำลังสนใจนั้นจะมีค่าอ้างอิงที่เพิ่มขึ้นหรือลดลง ดังนั้นผู้วิจัยจึงแทนค่าตัวเลข 0 และ 1 ซึ่งถ้าค่าเป็น 0 หมายความว่า ค่าอ้างอิงของของราคาในคาบเวลาปัจจุบันนั้นมีค่าลดลงจากคาบเวลาก่อนหน้าและในทางตรงกันข้ามถ้าค่าเป็น 1 หมายความว่า ค่าอ้างอิงของของราคาในคาบเวลาปัจจุบันนั้นมีค่าเพิ่มขึ้นจากคาบเวลาก่อนหน้า โดยกระบวนการแปลงข้อมูลในขั้นตอนนี้จะเริ่มจากการสร้างคอลัมน์ข้อมูลขึ้นมาใหม่ ซึ่งเป็นคอลัมน์ที่ระบุทิศทางของการเคลื่อนไหวของราคา (Trend) ดังแสดงตัวอย่างในรูปที่ 3.3 โดยข้อมูลในคอลัมน์นี้จะมีความเป็น 1 และ 0 โดยการกำหนดค่าข้อมูลสามารถคำนวณได้ดังนี้

- ข้อมูลจะมีค่าเป็น 0 ก็ต่อเมื่อ ข้อมูลในคอลัมน์ Close ลบข้อมูลในคอลัมน์ Open มีค่าน้อยกว่า 0
- ข้อมูลจะมีค่าเป็น 1 ก็ต่อเมื่อ ข้อมูลในคอลัมน์ Close ลบข้อมูลในคอลัมน์ Open มีค่ามากกว่าหรือเท่ากับ 0

1	Date	Time	Open	High	Low	Close	Volume	Trend
2	2018.07.04	17:30	1.16491	1.16495	1.16443	1.16481	413	0
3	2018.07.04	17:35	1.16481	1.16490	1.16444	1.16462	404	0
4	2018.07.04	17:40	1.16462	1.16471	1.16445	1.16468	302	1
5	2018.07.04	17:45	1.16468	1.16487	1.16450	1.16465	285	0
6	2018.07.04	17:50	1.16465	1.16465	1.16433	1.16435	399	0
7	2018.07.04	17:55	1.16435	1.16451	1.16425	1.16431	350	0
8	2018.07.04	18:00	1.16432	1.16445	1.16409	1.16409	534	0
9	2018.07.04	18:05	1.16410	1.16428	1.16410	1.16425	159	1
10	2018.07.04	18:10	1.16425	1.16434	1.16395	1.16410	317	0
11	2018.07.04	18:15	1.16410	1.16420	1.16399	1.16402	213	0
12	2018.07.04	18:20	1.16402	1.16408	1.16389	1.16405	101	1
13	2018.07.04	18:25	1.16405	1.16432	1.16392	1.16424	162	1
14	2018.07.04	18:30	1.16424	1.16424	1.16374	1.16385	217	0
15	2018.07.04	18:35	1.16385	1.16399	1.16384	1.16399	74	1

รูปที่ 3.3 ตัวอย่างชุดข้อมูลที่เพิ่มคอลัมน์สำหรับระบุทิศทางของการเคลื่อนไหวของราคา

จากนั้นตัดเอาเฉพาะข้อมูลคอลัมน์ Trend ออกมาและใช้เทคนิคหน้าต่างบานเลื่อนในการตัดข้อมูลออกมาเป็นชุดข้อมูลอนุกรมย่อย ๆ ที่มีความยาวของแต่ละชุดข้อมูลตามที่กำหนด จะทำให้ได้ชุดข้อมูลอนุกรมเวลาแบบไบนารี (Binary Sequence Dataset) ดังแสดงในรูปที่ 3.4

	A	B	C	D	E	F	G	H	I	J
1	0	0	1	0	0	0	0	1	0	0
2	0	1	0	0	0	0	1	0	0	1
3	1	0	0	0	0	1	0	0	1	1
4	0	0	0	0	1	0	0	1	1	0
5	0	0	0	1	0	0	1	1	0	1
6	0	0	1	0	0	1	1	0	1	0
7	0	1	0	0	1	1	0	1	0	0
8	1	0	0	1	1	0	1	0	0	1
9	0	0	1	1	0	1	0	0	1	1
10	0	1	1	0	1	0	0	1	1	1
11	1	1	0	1	0	0	1	1	1	0
12	1	0	1	0	0	1	1	1	0	1
13	0	1	0	0	1	1	1	0	1	1
14	1	0	0	1	1	1	0	1	1	1
15	0	0	1	1	1	0	1	1	1	0

รูปที่ 3.4 ตัวอย่างของขั้นตอนการแปลงข้อมูลสำหรับใช้เป็นข้อมูลนำเข้าเพื่อสร้างโมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไป

- ข้อมูลสำหรับการพัฒนาเครื่องมืออัตโนมัติที่ใช้ในการจำแนกข้อมูลแนวโน้มของราคาในช่วงเวลาที่กำหนดโดยใช้หลักการวิเคราะห์เทคนิคการหาค่าเฉลี่ยเคลื่อนที่

ในส่วนนี้ข้อมูลที่ต้องใช้จะอยู่ในรูปแบบของชุดข้อมูลอนุกรม ซึ่งข้อมูลอนุกรมแต่ละชุดจะมีความยาวตามที่ผู้วิจัยได้กำหนดไว้ โดยการสร้างชุดข้อมูลแบบอนุกรมนั้นผู้วิจัยได้นำหลักการหน้าต่างบานเลื่อน (Sliding Windows) (de Brito and Oliveira, 2014) มาใช้เพื่อตัดข้อมูลออกมาเป็นชุดข้อมูลย่อย ๆ จำนวนหลาย ๆ ชุดข้อมูล โดยจะทำการตัดข้อมูลตามจำนวนความยาวของข้อมูลที่กำหนด แล้วเลื่อนคาบเวลาไปข้างหน้าครั้งละ 1 คาบเวลาเพื่อสร้างชุดข้อมูลใหม่ ตัวอย่างเช่น กำหนดความยาวของชุดข้อมูลเท่ากับ 10 คาบเวลาและเลื่อนหน้าต่างทีละ 1 คาบเวลา เพื่อสร้างชุดข้อมูลใหม่ดังแสดงในรูปที่ 3.5

Close	1.16481	1.16462	1.16468	1.16465	1.16435	1.16431	1.16409	1.16425	1.16410	1.16402	1.16405	1.16424	1.16385	1.16399	1.16391	1.16381	1.16381	1.16400	1.16408	1.16411	1.16389	1.16407	1.16600	1.16634	1.16606	1.16590	1.16634	1.16652	1.16679	1.16727	1.16665	1.16650	1.16726	1.16723	1.16703
Close	1.16481	1.16462	1.16468	1.16465	1.16435	1.16431	1.16409	1.16425	1.16410	1.16402	1.16405	1.16424	1.16385	1.16399	1.16391	1.16381	1.16381	1.16400	1.16408	1.16411	1.16389	1.16407	1.16600	1.16634	1.16606	1.16590	1.16634	1.16652	1.16679	1.16727	1.16665	1.16650	1.16726	1.16723	1.16703
Close	1.16481	1.16462	1.16468	1.16465	1.16435	1.16431	1.16409	1.16425	1.16410	1.16402	1.16405	1.16424	1.16385	1.16399	1.16391	1.16381	1.16381	1.16400	1.16408	1.16411	1.16389	1.16407	1.16600	1.16634	1.16606	1.16590	1.16634	1.16652	1.16679	1.16727	1.16665	1.16650	1.16726	1.16723	1.16703
Close	1.16481	1.16462	1.16468	1.16465	1.16435	1.16431	1.16409	1.16425	1.16410	1.16402	1.16405	1.16424	1.16385	1.16399	1.16391	1.16381	1.16381	1.16400	1.16408	1.16411	1.16389	1.16407	1.16600	1.16634	1.16606	1.16590	1.16634	1.16652	1.16679	1.16727	1.16665	1.16650	1.16726	1.16723	1.16703

รูปที่ 3.5 การใช้หลักการหน้าต่างบานเลื่อนในการตัดข้อมูลออกมาเป็นชุดข้อมูลย่อย ๆ


ผลจากการใช้หลักการหน้าต่างบานเลื่อนเพื่อตัดข้อมูลในคอลัมน์ Close ออกมาเป็นชุดข้อมูลย่อย โดยแต่ละชุดข้อมูลย่อยมีความยาวเท่ากับ 10 คาบเวลาและทำการเลื่อนหน้าต่างทีละ 1 คาบเวลาแสดงในรูปที่ 3.6

1	1.16481	1.16462	1.16468	1.16465	1.16435	1.16431	1.16409	1.16425	1.16410	1.16402
2	1.16462	1.16468	1.16465	1.16435	1.16431	1.16409	1.16425	1.16410	1.16402	1.16405
3	1.16468	1.16465	1.16435	1.16431	1.16409	1.16425	1.16410	1.16402	1.16405	1.16424
4	1.16465	1.16435	1.16431	1.16409	1.16425	1.16410	1.16402	1.16405	1.16424	1.16385
5	1.16435	1.16431	1.16409	1.16425	1.16410	1.16402	1.16405	1.16424	1.16385	1.16399
6	1.16431	1.16409	1.16425	1.16410	1.16402	1.16405	1.16424	1.16385	1.16399	1.16391
7	1.16409	1.16425	1.16410	1.16402	1.16405	1.16424	1.16385	1.16399	1.16391	1.16381
8	1.16425	1.16410	1.16402	1.16405	1.16424	1.16385	1.16399	1.16391	1.16381	1.16400
9	1.16410	1.16402	1.16405	1.16424	1.16385	1.16399	1.16391	1.16381	1.16400	1.16408
10	1.16402	1.16405	1.16424	1.16385	1.16399	1.16391	1.16381	1.16400	1.16408	1.16411
11	1.16405	1.16424	1.16385	1.16399	1.16391	1.16381	1.16400	1.16408	1.16411	1.16389
12	1.16424	1.16385	1.16399	1.16391	1.16381	1.16400	1.16408	1.16411	1.16389	1.16407
13	1.16385	1.16399	1.16391	1.16381	1.16400	1.16408	1.16411	1.16389	1.16407	1.16600
14	1.16399	1.16391	1.16381	1.16400	1.16408	1.16411	1.16389	1.16407	1.16600	1.16634
15	1.16391	1.16381	1.16400	1.16408	1.16411	1.16389	1.16407	1.16600	1.16634	1.16606

รูปที่ 3.6 ตัวอย่างชุดข้อมูลที่ถูกตัดออกมาให้อยู่ในรูปแบบชุดข้อมูลย่อย ๆ โดยใช้หลักการหน้าต่างบานเลื่อน

- ข้อมูลรูปภาพใช้สำหรับให้ผู้เชี่ยวชาญสังเกตเพื่อทำการจำแนกข้อมูลตามประเภทของแนวโน้มการเคลื่อนไหวของราคาอ้างอิง

ชุดข้อมูลอนุกรมย่อย ๆ ที่ได้หลังจากการใช้หลักการหน้าต่างบานเลื่อน ถูกนำมาสร้างเป็นกราฟเส้น และทำการบันทึกข้อมูลในรูปแบบรูปภาพซึ่งแสดงในรูปที่ 3.7

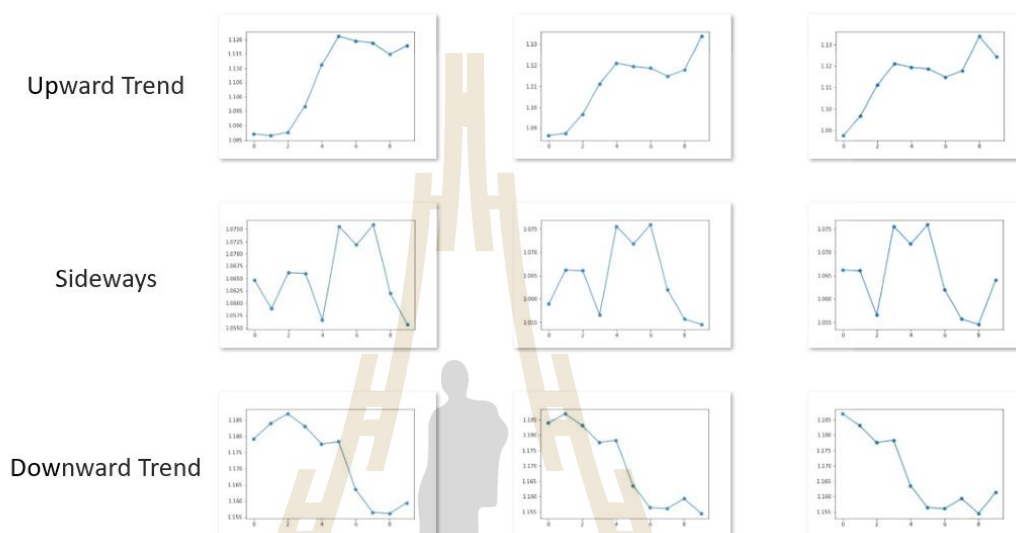


รูปที่ 3.7 ตัวอย่างข้อมูลรูปภาพที่สร้างขึ้นจากชุดข้อมูลย่อย ๆ หลังจากการใช้หลักการหน้าต่างบานเลื่อน

### 3.2.1.3 การกำหนดคำนิยามให้กับข้อมูล

การสร้างโมเดลสำหรับการจำแนกข้อมูลแนวโน้มของราคาในช่วงเวลาที่กำหนดโดยอาศัยหลักการโครงข่ายประสาทแบบคอนโวลูชัน ข้อมูลนำเข้าจะต้องถูกกำหนดคำนิยาม (Label) ของคลาสเป้าหมาย (Target Class) เอาไว้ เพื่อให้โมเดลสามารถเรียนรู้ได้ตามหลักการเรียนรู้ของเครื่องแบบมีผู้แนะนำ (Supervised Learning) (Caruana and Niculescu-Mizil, 2006) ซึ่งเป้าหมายของโมเดลสำหรับการจำแนกข้อมูลแนวโน้มของราคา ในช่วงเวลาที่กำหนดคือการคัดแยกว่าข้อมูลอนุกรมชุดนี้เป็นข้อมูลที่บ่งบอกถึงเทรนหรือแนวโน้มความเคลื่อนไหวของราคาแบบใดใน 3 รูปแบบดังนี้ แนวโน้มของราคาแบบขาขึ้น (Upward Trend) แนวโน้มของราคา

แบบผันผวน (Sideways) และแนวโน้มของราคาแบบขาลง (Downward Trend) ดังนั้น เพื่อการกำหนดคลาสเป้าหมาย ผู้วิจัยได้รับความอนุเคราะห์จากผู้เชี่ยวชาญที่มีประสบการณ์ในการลงทุนในตลาดการซื้อขายเงินตราต่างประเทศมากกว่า 10 ปี มาเป็นผู้กำหนดคลาสเป้าหมายโดยดูจากรูปแบบของกราฟในแต่ละรูป ดังแสดงในรูปที่ 3.8



รูปที่ 3.8 ตัวอย่างรูปภาพที่ถูกกำหนดคลาสเป้าหมายโดยผู้เชี่ยวชาญ

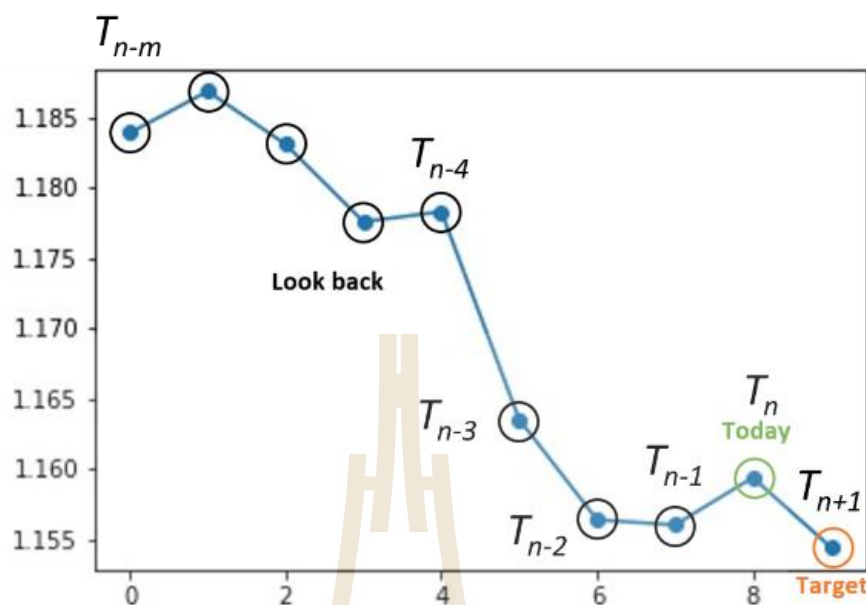
เมื่อกำหนดคลาสเป้าหมายให้ข้อมูลรูปภาพแล้ว ผู้วิจัยได้นำคลาสเป้าหมายที่ถูกกำหนดโดยผู้เชี่ยวชาญของข้อมูลแต่ละรูปภาพที่ได้จากขั้นตอนในรูปที่ 3.8 มาทำการกำหนดเป็นคลาสเป้าหมายให้กับชุดข้อมูลอนุกรมแต่ละข้อมูลย่อย ๆ ในคอลัมน์ Trend ข้อมูลชุดนี้จะถูกนำไปใช้เป็นส่วนนำเข้าสู่สำหรับการสร้าง โมเดล SVM และ ANN เพื่อใช้ในการเปรียบเทียบประสิทธิภาพอีกด้วย ตัวอย่างข้อมูลแสดงได้ดังรูปที่ 3.9

1	t-8	t-7	t-6	t-5	t-4	t-3	t-2	t-1	t	Trend
2	1.48020	1.46890	1.46780	1.47810	1.47430	1.48960	1.47930	1.47530	1.46430	Upward
3	1.46890	1.46780	1.47810	1.47430	1.48960	1.47930	1.47530	1.46430	1.47150	Sideways
4	1.46780	1.47810	1.47430	1.48960	1.47930	1.47530	1.46430	1.47150	1.46930	Sideways
5	1.47810	1.47430	1.48960	1.47930	1.47530	1.46430	1.47150	1.46930	1.46780	Sideways
6	1.47430	1.48960	1.47930	1.47530	1.46430	1.47150	1.46930	1.46780	1.45860	Downward
7	1.48960	1.47930	1.47530	1.46430	1.47150	1.46930	1.46780	1.45860	1.45130	Downward
8	1.47930	1.47530	1.46430	1.47150	1.46930	1.46780	1.45860	1.45130	1.44900	Sideways
9	1.47530	1.46430	1.47150	1.46930	1.46780	1.45860	1.45130	1.44900	1.42400	Sideways
10	1.46430	1.47150	1.46930	1.46780	1.45860	1.45130	1.44900	1.42400	1.42670	Sideways
11	1.47150	1.46930	1.46780	1.45860	1.45130	1.44900	1.42400	1.42670	1.41170	Sideways
12	1.46930	1.46780	1.45860	1.45130	1.44900	1.42400	1.42670	1.41170	1.41060	Downward
13	1.46780	1.45860	1.45130	1.44900	1.42400	1.42670	1.41170	1.41060	1.39640	Downward
14	1.45860	1.45130	1.44900	1.42400	1.42670	1.41170	1.41060	1.39640	1.40180	Downward
15	1.45130	1.44900	1.42400	1.42670	1.41170	1.41060	1.39640	1.40180	1.42230	Sideways
16	1.44900	1.42400	1.42670	1.41170	1.41060	1.39640	1.40180	1.42230	1.42740	Sideways
17	1.42400	1.42670	1.41170	1.41060	1.39640	1.40180	1.42230	1.42740	1.40980	Sideways
18	1.42670	1.41170	1.41060	1.39640	1.40180	1.42230	1.42740	1.40980	1.43060	Upward
19	1.41170	1.41060	1.39640	1.40180	1.42230	1.42740	1.40980	1.43060	1.43230	Upward

รูปที่ 3.9 ตัวอย่างข้อมูลอนุกรมย่อย ๆ หลังจากกำหนดคลาสเป้าหมายในคอลัมน์ Trend

### 3.2.2 การพัฒนาและการเพิ่มประสิทธิภาพโมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไป

งานวิจัยในขั้นตอนนี้มีวัตถุประสงค์เพื่อการพัฒนาโมเดลสำหรับการทำนายราคาอ้างอิงของคู่เงินที่สนใจในคาบเวลาถัดไป โดยใช้อัลกอริทึมหน่วยความจำระยะยาวระยะสั้น (Long Short-Term Memory, LSTM) ซึ่งเป็นอัลกอริทึมที่อยู่บนพื้นฐานของหลักการเรียนรู้เชิงลึก รูปที่ 3.10 แสดงตัวอย่างรูปแบบการกำหนดปัญหาที่ต้องการใช้อัลกอริทึม LSTM ทำนายข้อมูลที่จะเกิดขึ้นในอนาคต โดยจะเห็นได้ว่าหากแทนค่าข้อมูลในปัจจุบันด้วยตัวแปร  $T_n$  ข้อมูลก่อนหน้าคือ  $T_{n-1}, T_{n-2}, \dots, T_{n-m}$  โดยที่  $n$  คือตำแหน่งปัจจุบันของข้อมูล  $m$  คือความยาวของลำดับข้อมูลที่นำเข้า และ  $T_{n+1}$  คือ ตำแหน่งของข้อมูลที่ต้องการทำนาย ซึ่งเป็นข้อมูลในคาบถัดไป ดังนั้นจะเห็นว่าจะต้องใช้ข้อมูลจำนวน  $m$  คาบเวลาเพื่อทำนายว่า ข้อมูลในคาบเวลาถัดไปจะเป็นอย่างไร



รูปที่ 3.10 ตัวอย่างรูปแบบของปัญหาที่ต้องการทำนายโดยใช้อัลกอริทึม LSTM

ในส่วนของการพัฒนาโมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไปนั้น ขั้นตอนการพัฒนาจะถูกแบ่งเป็น 2 ส่วน คือส่วนของการพัฒนาโมเดลและการเพิ่มประสิทธิภาพให้กับโมเดลซึ่งรายละเอียดแต่ละส่วนสามารถอธิบายได้ดังนี้

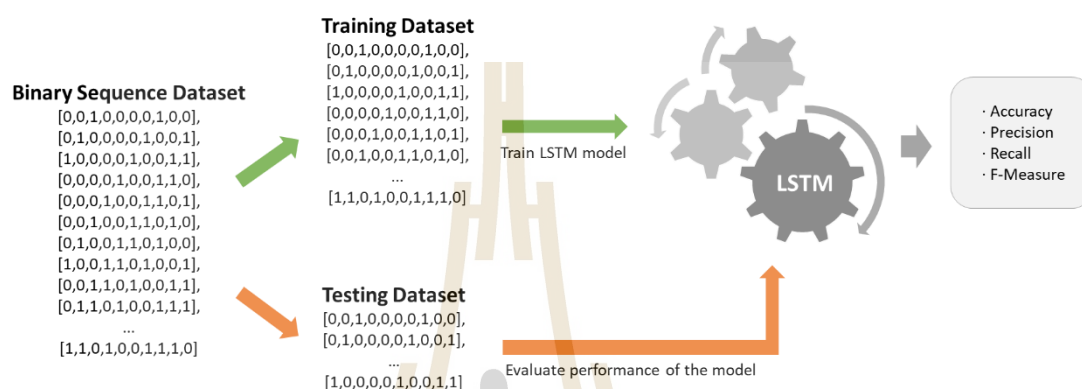
### 3.2.2.1 การพัฒนาโมเดล LSTM พื้นฐานสำหรับเปรียบเทียบประสิทธิภาพกับโมเดล LSTM ที่ได้รับการเพิ่มประสิทธิภาพด้วยวิธีการต่าง ๆ

เป้าหมายสำหรับการสร้าง โมเดล LSTM คือต้องการทำนายว่าในคาบเวลาถัดไปราคาอ้างอิงของคู่เงินที่สนใจจะสูงหรือต่ำกว่าราคาอ้างอิงในคาบเวลาปัจจุบัน ดังนั้นจากข้อมูลอนุกรมเวลาที่เป็นราคาอ้างอิง (ค่าตัวเลขที่มีทศนิยม 5 ตำแหน่ง) จึงถูกแปลงเป็นตัวเลขแบบไบนารี (0 และ 1) โดยค่า 0 หมายถึงข้อมูลปัจจุบัน ( $T_n$ ) มีค่าต่ำลงเมื่อเทียบกับข้อมูลในคาบเวลาก่อนหน้านี้ ( $T_{n-1}$ ) ในขณะที่ค่า 1 หมายถึงข้อมูลปัจจุบัน ( $T_n$ ) มีค่าสูงขึ้นหรือไม่เปลี่ยนแปลงเมื่อเทียบกับข้อมูลในคาบเวลาก่อนหน้านี้ ( $T_{n-1}$ ) ดังนั้นข้อมูลที่จะใช้เป็นข้อมูลนำเข้าเพื่อสร้างโมเดลบนพื้นฐานของทฤษฎี LSTM จึงมีลักษณะเป็นชุดข้อมูลอนุกรมแบบไบนารี ตัวอย่างเช่น [1, 0, 0, 0, 0, 1, 1, 0, 0, 1, 0, 1] ข้อมูลนี้จะถูกใช้เป็นข้อมูลเข้าสำหรับการทำนายข้อมูลที่จะเกิดขึ้นในคาบเวลาถัดไปซึ่งเป็นข้อมูลไบนารีเช่นเดียวกัน ซึ่งรูปแบบของอัลกอริทึม LSTM ที่เหมาะสมที่สุดที่จะใช้พัฒนาโมเดล



ในงานวิจัยนี้คือ LSTM แบบหลายต่อหนึ่ง ซึ่งเป็นการใช้ข้อมูลนำเข้าหลายข้อมูลเพื่อทำนายข้อมูลที่จะเกิดขึ้นในอนาคตจำนวน 1 ข้อมูล ดังที่ได้เคยกล่าวไว้แล้วก่อนหน้านี้ (ในบทที่ 2 หัวข้อ 2.5.3)

ขั้นตอนนี้จะเป็นการพัฒนาโมเดล LSTM พื้นฐานเพื่อจะถูกใช้เป็นโมเดลเพื่อเปรียบเทียบประสิทธิภาพกับโมเดล LSTM ที่ได้รับการเพิ่มประสิทธิภาพด้วยวิธีการต่าง ๆ



รูปที่ 3.11 กระบวนการพัฒนาโมเดล LSTM พื้นฐาน

จากรูปที่ 3.11 อธิบายกระบวนการพัฒนาโมเดล LSTM พื้นฐานสำหรับใช้ในการทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไป โดยขั้นตอนในการพัฒนาเริ่มต้นจากการนำข้อมูลอนุกรมเวลาแบบไบนารีที่เตรียมไว้มาแบ่งออกเป็น 2 ส่วนคือ ข้อมูลสำหรับการเรียนรู้ของโมเดล (Training Dataset) และข้อมูลสำหรับการทดสอบประสิทธิภาพของโมเดล (Testing Dataset) โดยที่ข้อมูลสำหรับการเรียนรู้จะถูกนำไปพัฒนาโมเดลโดยใช้อัลกอริทึม LSTM ด้วยภาษา Python จากนั้นโมเดลจะถูกวัดประสิทธิภาพด้วยชุดข้อมูลสำหรับทดสอบ โดยใช้มาตรวัดประสิทธิภาพได้แก่ Accuracy, Precision, Recall และ F-Measure

### 3.2.2.2 การเพิ่มประสิทธิภาพโมเดลโดยการกำหนดค่าพารามิเตอร์ต่าง ๆ ให้เหมาะสม

การพัฒนาโมเดลบนพื้นฐานของ LSTM นั้น มีปัจจัยอยู่หลายข้อที่ส่งผลต่อประสิทธิภาพในการทำนายของโมเดลได้แก่ 1) ความยาวของข้อมูลอินพุตสำหรับการสร้างโมเดล 2) จำนวนที่เหมาะสมของข้อมูลที่จะใช้สำหรับการเรียนรู้เพื่อสร้างโมเดล และ 3) ระยะเวลาที่ต้องทำการปรับปรุงโมเดลให้ทันสมัยเพื่อรักษาประสิทธิภาพในการทำนาย ดังนั้นในขั้นตอนนี้ ผู้วิจัยจะทำการทดลองเพื่อหาค่าที่เหมาะสมของปัจจัยทั้ง 3 ที่กล่าวมาข้างต้น เพื่อให้โมเดลมี

ประสิทธิภาพสูงขึ้นและเมื่อเวลาผ่านไปประสิทธิภาพนั้นไม่ได้มีการลดลงตามระยะเวลาที่เพิ่มมากขึ้น อธิบายขั้นตอนโดยละเอียดได้ดังนี้

1) การหาความยาวของข้อมูลอินพุตที่เหมาะสมสำหรับการสร้างโมเดล โดยผู้วิจัยจะกำหนดค่าความยาวของข้อมูลอินพุตสำหรับการสร้างโมเดลที่หลากหลายเพื่อทดสอบประสิทธิภาพของโมเดล โดยมีระหว่าง 5 – 30 คาบเวลา

2) การหาจำนวนข้อมูลที่เหมาะสมสำหรับการเรียนรู้เพื่อพัฒนาโมเดล โดยผู้วิจัยได้ทำการกำหนดจำนวนข้อมูลโดยอ้างอิงจากระยะเวลาที่จะนำข้อมูลมาใช้ระบุเป็นจำนวนวัน ยกตัวอย่างเช่น ถ้าต้องการระยะเวลาของข้อมูลที่จะใช้ในการเรียนรู้ของโมเดลเป็นจำนวน 5 วัน ดังนั้นข้อมูลที่จะใช้จะมีจำนวนทั้งสิ้น 1,440 ข้อมูล ระยะเวลาของข้อมูลที่จะใช้ในการเรียนรู้ของโมเดลจะถูกกำหนดให้มีค่าเป็น 5, 7, 14, 30, 60 และ 90 วัน ซึ่งเมื่อแปลงเป็นจำนวนของข้อมูลจะเท่ากับ 1,440, 2,016, 4,032, 8,640, 17,280 และ 25,920 ข้อมูลตามลำดับ

3) การหาระยะเวลาที่ต้องทำการปรับปรุงโมเดลให้ทันสมัยเพื่อรักษาประสิทธิภาพในการทำงาน โดยผู้วิจัยจะใช้โมเดลเพื่อทำนายข้อมูลย้อนหลังของดัชนีอัตราแลกเปลี่ยนเงินตราต่างประเทศคู่เงิน EURUSD และสังเกตว่าเมื่อใดที่ความแม่นยำในการทำงานของโมเดลเริ่มลดลงกว่าค่าความแม่นยำมาตรฐานที่กำหนดไว้ (Accuracy > 65%) จุดนั้นจะเป็นเวลาที่ควรปรับปรุงโมเดล

### 3.2.2.3 การเพิ่มประสิทธิภาพให้กับโมเดลโดยการจำแนกข้อมูลและสร้างโมเดลตามลักษณะแนวโน้มการเคลื่อนไหวของราคาแต่ละประเภท

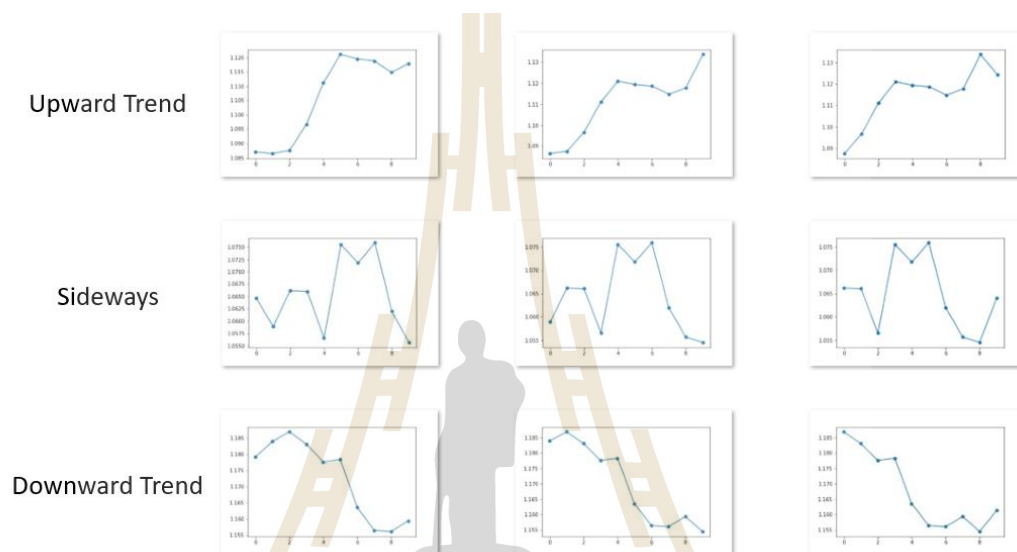
เนื่องจากแนวโน้มความเคลื่อนไหวของราคานั้น สามารถแบ่งออกได้เป็นหลายประเภท โดยสังเกตจากรูปแบบแนวโน้มการเคลื่อนไหวของราคาอ้างอิงที่มีความแตกต่างกันอย่างชัดเจน (Bulkowski, 2011) โดยทั่วไปแล้วนักลงทุนจะนิยมแบ่งแนวโน้มการเคลื่อนไหวของราคาออกเป็น 3 ประเภทดังนี้

1) แนวโน้มแบบขาขึ้นอย่างต่อเนื่อง (Upward Trend) คือ รูปแบบของราคาที่มีการเคลื่อนไหวแบบขี้นอย่างต่อเนื่องและมีราคาในคาบเวลาปัจจุบันสูงกว่าคาบเวลาเริ่มต้นอย่างชัดเจน

2) แนวโน้มแบบผันผวน (Sideways) คือ รูปแบบของราคาที่มีการเคลื่อนไหวแบบขึ้น ๆ ลง ๆ สลับกันไปและราคาในคาบเวลาปัจจุบันอาจจะมีค่าสูงหรือต่ำกว่าคาบเวลาเริ่มต้นได้

3) แนวโน้มแบบขาลงอย่างต่อเนื่อง (Downward Trend) คือ รูปแบบของราคาที่มีการเคลื่อนไหวแบบลงอย่างต่อเนื่องและมีราคาในคาบเวลาปัจจุบันต่ำกว่าคาบเวลาเริ่มต้นอย่างชัดเจน

เพื่อให้เห็นภาพได้อย่างชัดเจน ผู้วิจัยได้แสดงตัวอย่างของรูปแบบของแนวโน้มความเคลื่อนไหวของราคาทั้ง 3 ประเภทในรูปแบบของกราฟ ดังแสดงในรูปที่ 3.12




รูปที่ 3.12 ตัวอย่างแนวโน้มความเคลื่อนไหวของราคาทั้ง 3 ประเภทได้แก่ Upward Trend, Sideways และ Downward Trend

โดยทั่วไปแล้วนักลงทุนจะทำการวิเคราะห์แนวโน้มการเคลื่อนไหวของราคา ณ ช่วงเวลานั้น ๆ ว่าอยู่ในรูปแบบแนวโน้มแบบใด ซึ่งจะส่งผลต่อการตัดสินใจในการลงทุน ตัวอย่างเช่น ถ้าช่วงเวลานั้น ๆ เป็นแนวโน้มแบบขาขึ้นอย่างต่อเนื่อง ราคาอ้างอิงที่จะเกิดขึ้นในคาบถัดไป ก็มีแนวโน้มที่จะเพิ่มขึ้นตามแนวโน้มขาขึ้น ดังนั้นนักลงทุนก็จะลงทุนในฝั่งของการซื้อ (Buy / Long) ในทางกลับกันถ้าแนวโน้มเป็นแบบขาลงอย่างต่อเนื่อง ราคาอ้างอิงที่จะเกิดขึ้นในคาบถัดไป ก็มีแนวโน้มที่จะลดลงตามแนวโน้มขาลง นักลงทุนก็จะลงทุนในฝั่งของการขาย (Sell / Short) นอกจากนี้ถ้าแนวโน้มเป็นแบบผันผวน ราคาอ้างอิงที่จะเกิดขึ้นในคาบถัดไปก็มีแนวโน้มที่จะเพิ่มขึ้นหรือลดลงสวนทางกับราคาอ้างอิงในคาบเวลาปัจจุบัน นักลงทุนก็อาจจะลงทุนในทิศทางตรงข้ามกับแนวโน้มของราคาอ้างอิงในคาบเวลาปัจจุบัน

จากแนวคิดและรูปแบบของการลงทุนของนักลงทุนที่กล่าวมาข้างต้น งานวิจัยนี้ได้นำแนวคิดดังกล่าวมาประยุกต์ใช้เพิ่มประสิทธิภาพของโมเดลสำหรับทำนายแนวโน้มการ

เปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไป โดยแนวคิดนี้อยู่บนสมมุติฐานที่ว่า ถ้าข้อมูลที่ใช้สร้างและทดสอบประสิทธิภาพของโมเดลมีรูปแบบหรือลักษณะการเคลื่อนที่ของราคาที่ชัดเจนมาก จะทำให้อัลกอริทึมสามารถกำหนดค่าน้ำหนักของข้อมูลได้อย่างเหมาะสมมากขึ้น ซึ่งจะส่งผลให้โมเดลมีประสิทธิภาพในการทำนายที่ดีขึ้น กระบวนการวิจัยในขั้นตอนนี้อธิบายดังรูปที่ 3.13





รูปที่ 3.13 กระบวนการวิจัยและขั้นตอนของการเพิ่มประสิทธิภาพให้กับโมเดลโดยการจำแนกข้อมูลและสร้างโมเดลตามลักษณะแนวโน้มการเคลื่อนไหวของราคาแต่ละประเภท

จากรูปที่ 3-13 กระบวนการวิจัยในขั้นตอนนี้จะเริ่มต้นจากการนำข้อมูลอนุกรมเวลาแบบไบนารีที่ได้เตรียมไว้มาให้ผู้เชี่ยวชาญทำการคัดแยกข้อมูลตามประเภทของแนวโน้มการเคลื่อนที่ของราคาอ้างอิงออกเป็น 3 ประเภท จากนั้นทำการตัดแยกชุดข้อมูลอนุกรมเวลาแบบไบนารีที่ลำดับอ้างอิงตรงกับข้อมูลรูปภาพแต่ละรูป จะแบ่งแยกข้อมูลอนุกรมเวลาแบบไบนารีออกเป็น 3 ชุดข้อมูล จากนั้นชุดข้อมูลอนุกรมเวลาแบบไบนารีแต่ละชุดจะถูกแบ่งออกเป็นข้อมูลสำหรับการเรียนรู้และข้อมูลสำหรับการทดสอบประสิทธิภาพของโมเดล ต่อจากนั้นข้อมูลสำหรับการเรียนรู้แต่ละชุดจะถูกนำมาสร้างโมเดลจำนวน 3 โมเดลซึ่งประกอบด้วย

- 1) โมเดล LSTM สำหรับการทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไปสำหรับข้อมูลประเภทแนวโน้มแบบขาขึ้นอย่างต่อเนื่อง (LSTM<sub>UP</sub>)
- 2) โมเดล LSTM สำหรับการทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไปสำหรับข้อมูลประเภทแนวโน้มแบบผันผวน (LSTM<sub>SW</sub>)
- 3) โมเดล LSTM สำหรับการทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไปสำหรับข้อมูลประเภทแนวโน้มแบบขาลงอย่างต่อเนื่อง (LSTM<sub>DN</sub>)

จากนั้นโมเดล LSTM แต่ละโมเดลจะถูกประเมินความแม่นยำในการทำนายโดยใช้ชุดข้อมูลทดสอบที่ได้เตรียมไว้และประเมินด้วยมาตรวัดประสิทธิภาพ Accuracy

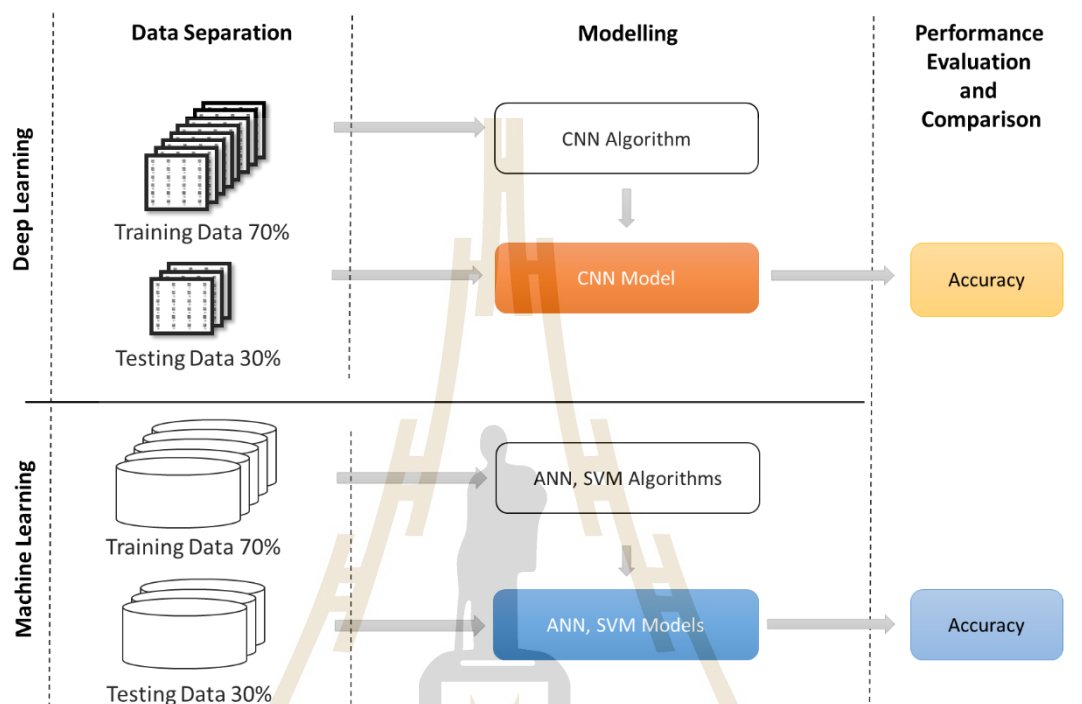
### 3.2.2.4 การพัฒนาเครื่องมือสำหรับการจำแนกประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนด

แนวคิดของการวิจัยในขั้นตอนนี้คือ การใช้เทคโนโลยีคอมพิวเตอร์ด้านปัญญาประดิษฐ์มาสร้างเป็นเครื่องมืออัตโนมัติเพื่อใช้แทนผู้เชี่ยวชาญในกระบวนการจำแนกประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนดและเปรียบเทียบประสิทธิภาพกับการใช้หลักการวิเคราะห์ทางเทคนิค

#### 3.2.2.4.1 การพัฒนาเครื่องมือสำหรับการจำแนกประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนดโดยใช้โครงข่ายประสาทแบบคอนโวลูชัน

ในขั้นตอนนี้ผู้วิจัยได้ประยุกต์ใช้ความรู้ด้านปัญญาประดิษฐ์มาสร้างเป็นโมเดลสำหรับใช้เป็นเครื่องมือในการจำแนกประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนดโมเดลนี้จะทำหน้าที่แทนที่ผู้เชี่ยวชาญ โดยทฤษฎีที่นำมาใช้สร้างโมเดลได้แก่ โครงข่ายประสาทแบบคอนโวลูชันหรือที่นิยมเรียกสั้น ๆ ว่า CNN ซึ่งเป็นทฤษฎีรูปแบบหนึ่งของกระบวนการเรียนรู้เชิงลึก CNN เป็นทฤษฎีที่เป็นการจำลองรูปแบบการมองเห็นรวมทั้งการคิดและวิเคราะห์ที่มีความใกล้เคียงกับการทำงานของสมองของมนุษย์ นอกจากนี้ผู้วิจัยได้เลือกนำ

ทฤษฎีการเรียนรู้ของเครื่องได้แก่ SVM และ ANN มาใช้เพื่อสร้างโมเดลพื้นฐานที่จะใช้สำหรับการเปรียบเทียบประสิทธิภาพในการจำแนกเทียบกับโมเดล CNN โดยมาตรวัดที่ใช้ในการวัดประสิทธิภาพของโมเดลคือ Accuracy ดังแสดงในรูปที่ 3.14

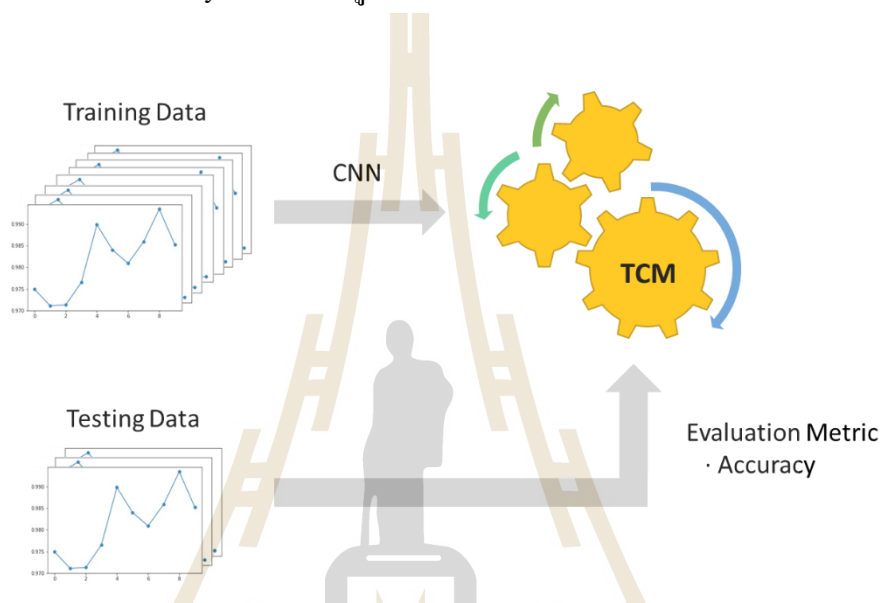


รูปที่ 3.14 กระบวนการพัฒนาโมเดลสำหรับการจำแนกประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนดโดยใช้โครงข่ายประสาทแบบคอนโวลูชัน

กระบวนการสำหรับการพัฒนาโมเดลที่แสดงในรูปที่ 3.14 จะแบ่งออกเป็น 2 ส่วนหลักคือ 1) ส่วนของการพัฒนาโมเดลโดยใช้ CNN และ 2) การพัฒนาโมเดลโดยใช้ SVM และ ANN ซึ่งมีรายละเอียดขั้นตอนดังนี้

### ส่วนที่ 1: การพัฒนาโมเดลโดยใช้ CNN

กระบวนการในส่วนนี้จะเริ่มต้นจากการแบ่งข้อมูลนำเข้าซึ่งเป็นข้อมูลรูปภาพออกเป็น 2 ส่วนคือข้อมูลสำหรับใช้เป็นข้อมูลเรียนรู้และข้อมูลสำหรับใช้ทดสอบประสิทธิภาพของโมเดล โดยข้อมูลสำหรับใช้เป็นข้อมูลเรียนรู้จะถูกนำไปใช้สร้างโมเดลโครงข่ายประสาทแบบคอนโวลูชัน จากนั้น โมเดลที่ถูกพัฒนาขึ้นจะถูกทดสอบด้วยข้อมูลทดสอบที่เตรียมไว้ โดยใช้มาตรวัดคือ Accuracy ดังแสดงในรูปที่ 3.15



รูปที่ 3.15 การพัฒนาโมเดลสำหรับการจำแนกประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนด โดยใช้โครงข่ายประสาทแบบคอนโวลูชัน


โครงสร้างของโมเดลโครงข่ายประสาทแบบคอนโวลูชันจะประกอบด้วย 4 ชั้นคือ ชั้นนำเข้า (Input Layer) ชั้นคอนโวลูชัน (Convolution Layers) ชั้นเชื่อมต่อกันหมด (Fully Connected Layers) และชั้นเอาต์พุต (Output Layer) โดยแต่ละชั้นมีการกำหนดค่าพารามิเตอร์ไว้ดังนี้

- 1) ชั้นนำเข้า จะนำเข้รูปภาพที่มีขนาด  $432 \times 288$  พิกเซล
- 2) ชั้นคอนโวลูชัน ประกอบด้วย 3 Convolutional Layers ( $16 \times 16 \times 16$ ,  $16 \times 16 \times 32$ ,  $16 \times 16 \times 64$ ), 2 Max Pooling ( $7 \times 7 \times 64$ ,  $7 \times 7 \times 64$ ), และ 1 Dropout Layer (0.25)
- 3) Fully Connected Layer (128)
- 4) ขนาดของตัวกรอง (Filter) มีค่า  $3 \times 3$  พิกเซล




## ส่วนที่ 2: การพัฒนาโมเดลโดยใช้ SVM และ ANN

การพัฒนาโมเดลในขั้นตอนนี้เริ่มต้นจากการแบ่งข้อมูลนำเข้าของข้อมูลรูปภาพออกเป็นสองส่วนเช่นเดียวกัน คือข้อมูลสำหรับใช้สำหรับการเรียนรู้ร้อยละ 70 ของจำนวนข้อมูลทั้งหมด และข้อมูลสำหรับใช้ในการทดสอบประสิทธิภาพของโมเดล คิดเป็นร้อยละ 30 ของจำนวนข้อมูลทั้งหมด จากนั้นข้อมูลสำหรับเรียนรู้จะถูกนำไปใช้สร้างโมเดล จำนวน 2 โมเดลคือ 1) โมเดลโครงข่ายประสาทเทียม และ 2) โมเดลเครื่องเวกเตอร์สนับสนุน จากนั้นโมเดลทั้ง 2 จะถูกทดสอบด้วยข้อมูลทดสอบที่เตรียมไว้ โดยใช้มาตรวัดประสิทธิภาพโมเดลคือ Accuracy ดังแสดงในรูปที่ 3.16



รูปที่ 3.16 กระบวนการพัฒนาโมเดลบนพื้นฐานของทฤษฎีการเรียนรู้ของเครื่อง

หลังจากทำการวัดประสิทธิภาพของโมเดลทั้ง 3 แล้ว โมเดลที่ให้ผลการจำแนกได้ถูกต้องแม่นยำที่สุดจะถูกนำไปใช้เป็นเครื่องมือสำหรับทำการจำแนกประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนดแทนการใช้ผู้เชี่ยวชาญ แต่เนื่องด้วยข้อมูลที่นำไปใช้ในการสร้างโมเดลสำหรับการทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไปเป็นข้อมูลอนุกรมเวลาของราคาอ้างอิงแบบไบนารี ดังนั้นต้องทำการจำแนกข้อมูลชุดนี้โดยอ้างอิงจากดัชนีของข้อมูลให้ตรงกันกับดัชนีของข้อมูลที่ถูกจำแนกไว้แล้ว ซึ่งจะทำให้ได้ข้อมูลอนุกรมเวลาของราคาอ้างอิงแบบไบนารีที่ถูกจำแนกเป็น 3 ชุดข้อมูลย่อย ๆ เพื่อนำไปใช้ในการพัฒนาและทดสอบประสิทธิภาพโมเดล LSTM ดังแสดงในรูปที่ 3.17



รูปที่ 3.17 กระบวนการพัฒนาและทดสอบประสิทธิภาพโมเดลสำหรับการทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไปโดยใช้โมเดล TCM<sub>CNN</sub> ในการคัดแยกข้อมูลแทนที่การใช้ผู้เชี่ยวชาญ

### 3.2.2.4.2 การพัฒนาเครื่องมือสำหรับการจำแนกประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนดโดยใช้หลักการวิเคราะห์ทางเทคนิค

โดยทั่วไปแล้วนักลงทุนในตลาดหลักทรัพย์และตลาดซื้อขายแลกเปลี่ยนเงินตราต่างประเทศ จะใช้หลักการวิเคราะห์ทางเทคนิคเป็นเครื่องมือในการวิเคราะห์แนวโน้มหรือทิศทางของการเคลื่อนไหวของราคาอ้างอิง โดยหลักการวิเคราะห์ทางเทคนิคที่นิยมกันอย่างแพร่หลายคือการใช้การวิเคราะห์จากค่าเฉลี่ยเคลื่อนที่ (Moving Average, MA) (Hayes, 2019) ซึ่งค่าเฉลี่ยเคลื่อนที่ที่สามารถกรองสัญญาณที่ผิดปกติต่าง ๆ ออกและปรับราคาให้เรียบ (Smooth) โดยการหาค่าเฉลี่ยจากราคาปิดย้อนหลังในช่วงเวลาที่กำหนดไว้

การวิเคราะห์ทางเทคนิคโดยใช้ค่าเฉลี่ยเคลื่อนที่นั้นมียุทธวิธีด้วยกันหลายแบบ ดังที่อธิบายไว้ในหัวข้อที่ 2.7 โดยทั่วไปแล้วการกำหนดช่วงเวลาที่ จะทำการวิเคราะห์นั้น จะกำหนดเป็นช่วงเวลาสั้น ๆ และค่าเฉลี่ยเคลื่อนที่ที่เหมาะสมสำหรับการวิเคราะห์ช่วงเวลาสั้น ๆ คือ ค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนักขั้วซ้อน (Exponential Moving Average หรือ EMA) (Marshall, Young, & Rose, 2006, pp. 2303-2323) ดังนั้นงานวิจัยนี้ จึงนำหลักการคำนวณค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนักขั้วซ้อนมาประยุกต์ใช้งานร่วมกับเงื่อนไขที่ผู้วิจัยกำหนดขึ้นเพื่อสร้างเป็นเครื่องมืออัตโนมัติสำหรับการจำแนกประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนดแทนที่การใช้ผู้เชี่ยวชาญ โดยเงื่อนไขที่ผู้วิจัยได้กำหนดสำหรับการตัดแยกประเภทแนวโน้มของข้อมูลนั้นอธิบายได้ดังนี้


1) ข้อมูลจะถูกจำแนกอยู่ในรูปแบบของ Upward Trend เมื่อนำค่า EMA ของราคาอ้างอิงในคาบปัจจุบันลบด้วยค่า EMA ของราคาอ้างอิงในคาบเริ่มต้นของช่วงเวลาที่กำหนดแล้วมีค่ามากกว่าหรือเท่ากับ 10 และอัตราส่วนแนวโน้มของราคาขาขึ้น (1) และขาลง (0) ของแต่ละคาบเวลาในช่วงเวลาที่กำหนดมีที่ 70% ต่อ 30%


2) ข้อมูลจะถูกจำแนกอยู่ในรูปแบบของ Sideways เมื่อนำค่า EMA ของราคาอ้างอิงในคาบปัจจุบันลบด้วยค่า EMA ของราคาอ้างอิงในคาบเริ่มต้นของช่วงเวลาที่กำหนดแล้วมีค่าน้อยกว่า 10 และอัตราส่วนแนวโน้มของราคาขาขึ้น (1) และขาลง (0) ของแต่ละคาบเวลาในช่วงเวลาที่กำหนดมีที่ 60% ต่อ 40% หรือ 40% ต่อ 60%

3) ข้อมูลจะถูกจำแนกอยู่ในรูปแบบของ Downward Trend เมื่อนำค่า EMA ของราคาอ้างอิงในคาบปัจจุบันลบด้วยค่า EMA ของราคาอ้างอิงในคาบเริ่มต้นของช่วงเวลาที่กำหนดแล้วมีค่าน้อยกว่าหรือเท่ากับ -10 และอัตราส่วนแนวโน้มของราคาขาขึ้น (1) และขาลง (0) ของแต่ละคาบเวลาในช่วงเวลาที่กำหนดมีที่ 30% ต่อ 70%

หลังจากทำการจำแนกข้อมูลอนุกรมของราคาอ้างอิงทั้งหมดโดยใช้เงื่อนไขดังกล่าว จะทำให้สามารถแบ่งข้อมูลออกเป็น 3 ชุดข้อมูลย่อยตามประเภทแนวโน้มของ

ราคาอ้างอิงทั้ง 3 ประเภท เช่นเดียวกันกับในขั้นตอนการพัฒนาเครื่องมือสำหรับการจำแนกประเภท แนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนดโดยใช้ความรู้ด้านปัญญาประดิษฐ์ ด้วยข้อมูลที่นำไปใช้ในการสร้างโมเดลสำหรับการทำนายแนวโน้มการเปลี่ยนแปลงของราคา อ้างอิงในช่วงเวลาที่ถัดไปเป็นข้อมูลอนุกรมเวลาของราคาอ้างอิงแบบไบนารี ดังนั้นต้องทำการ จำแนกข้อมูลชุดนี้ โดยอ้างอิงจากดัชนีของข้อมูลให้ตรงกันกับดัชนีของข้อมูลที่ถูกจำแนกไว้แล้ว ซึ่งจะช่วยให้ได้ข้อมูลอนุกรมเวลาของราคาอ้างอิงแบบไบนารีที่ถูกจำแนกเป็น 3 ชุดข้อมูลย่อย ๆ เพื่อนำไปใช้ในการสร้างและทดสอบประสิทธิภาพโมเดลสำหรับการทำนายแนวโน้มการเปลี่ยนแปลง ของราคาอ้างอิงในช่วงเวลาที่ถัดไปทั้ง 3 โมเดล ดังแสดงในรูปที่ 3.18





รูปที่ 3.18 กระบวนการพัฒนาและทดสอบประสิทธิภาพโมเดลสำหรับการทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาที่ถัดไปโดยใช้โมเดล TCM<sub>EMA</sub> ในการคัดแยกข้อมูลแทนที่การใช้ผู้เชี่ยวชาญ

### 3.2.2.4.3 การเปรียบเทียบประสิทธิภาพเครื่องมือสำหรับการจำแนกประเภทของข้อมูลตามแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนดโดยใช้ความรู้ด้านปัญญาประดิษฐ์และหลักการวิเคราะห์ทางเทคนิค

ขั้นตอนสุดท้ายในการพัฒนาเครื่องมือสำหรับการจำแนกประเภทของข้อมูลตามแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนด คือการนำข้อมูลที่ถูกจำแนกโดยเครื่องมือทั้ง 2 แบบ ไปใช้ในการพัฒนาและทดสอบประสิทธิภาพโมเดล LSTM สำหรับการทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไป ในส่วนของการวัดประสิทธิภาพเครื่องมือที่ใช้ในการจำแนกนั้น ใช้มาตรวัดคือ Accuracy โดยเครื่องมือที่ให้ผลการทำนายที่ดีที่สุดจะถูกนำไปใช้ในการทดสอบประสิทธิภาพด้านการเงิน ซึ่งอธิบายในหัวข้อถัดไป

### 3.2.3 กลยุทธ์สำหรับการลงทุนในตัวเลือกไบนารี

การที่นักลงทุนจะสามารถทำกำไรในการลงทุนไม่ว่าจะเป็นในตลาดหุ้น ตลาดซื้อขายแลกเปลี่ยนเงินตราต่างประเทศ รวมทั้งการลงทุนในตัวเลือกไบนารีนั้น นอกจากที่นักลงทุนจะต้องมีเครื่องมือที่ใช้เป็นตัวช่วยในการวิเคราะห์หรือตัดสินใจว่าจะส่งข้อมูลสำหรับการซื้อหรือการขายในแต่ละครั้งไปในทิศทางใดแล้ว นักลงทุนยังต้องมีการบริหารจัดการเงินในพอร์ตลงทุน (Money Management) และการตัดขาดทุน (Cut Loss) ที่ดีด้วย ดังนั้นในหัวข้อนี้จะเป็นการนำเสนอวิธีการใช้งานเครื่องมือ TCM สำหรับการจำแนกข้อมูลและการใช้งานโมเดล LSTM สำหรับการทำนายทิศทางแนวโน้มของราคาอ้างอิง อีกทั้งยังได้นำเสนอกลยุทธ์ที่ใช้ในการบริหารจัดการเงินในพอร์ตลงทุนและกลยุทธ์ที่ใช้ในการตัดขาดทุนที่เหมาะสมสำหรับการซื้อขายตัวเลือกไบนารี

#### 3.2.3.1 การกำหนดทิศทางการซื้อขายตัวเลือกไบนารี

รูปที่ 3.19 แสดงขั้นตอนในการใช้เครื่องมือ TCM และโมเดล LSTM เพื่อจำแนกข้อมูลและทำนายทิศทางการเคลื่อนไหวของราคาอ้างอิงในคาบเวลาถัดไป โดยข้อมูลที่ได้จากการทำนายจะเป็นตัวกำหนดทิศทางการซื้อหรือขายตัวเลือกไบนารี โดยขั้นตอนในการกำหนดทิศทางการซื้อขายตัวเลือกไบนารีสามารถอธิบายได้ดังนี้


1) ตัดข้อมูลจากคอลัมน์ราคาปิดของข้อมูลอ้างอิงของอัตราการซื้อขายเงินตราต่างประเทศในกลุ่มสกุลเงินที่สนใจตามความยาวคาบเวลาที่กำหนด เช่น [1.16481, 1.16462, 1.16468, 1.16465, 1.16435, 1.16431, 1.16409, 1.16425, 1.16410, 1.16402] เป็นต้น

2) แปลงข้อมูลให้อยู่ใน 2 ลักษณะคือ ข้อมูลรูปภาพและข้อมูลอนุกรมแบบไบนารี เช่น [0, 0, 1, 0, 0, 0, 1, 0, 0] เป็นต้น

3) ใช้เครื่องมือ TCM ในการจำแนกข้อมูลรูปภาพว่าข้อมูลชุดนั้นจัดอยู่ในแนวโน้มประเภทใด (Upward Trend, Sideways, Downward Trend)

4) เมื่อทราบว่าข้อมูลดังกล่าวจัดอยู่ในแนวโน้มประเภทใดแล้ว จากนั้นเลือกโมเดล LSTM ที่ตรงกับประเภทของแนวโน้มที่ระบุโดยนำเครื่องมือ TCM มาใช้ในการทำนายแนวโน้มของราคาอ้างอิงในคาบเวลาถัดไป โดยใช้ข้อมูลอนุกรมเวลาแบบไบนารีเป็นข้อมูลอินพุต

5) นำผลลัพธ์ที่ได้จากการทำนายไปใช้ในการกำหนดคำสั่งซื้อหรือขายตัวเลือกไบนารี ถ้าโมเดล LSTM ทำนายข้อมูลออกมาเป็น 0 ให้ส่งคำสั่งขาย (Sell) แต่หากโมเดลทำนายข้อมูลออกมาเป็น 1 ให้ส่งคำสั่งซื้อ (Buy)



รูปที่ 3.19 ขั้นตอนในการกำหนดสัญญาณในการซื้อขายตัวเลือกไบนารี

### 3.2.3.2 กลยุทธ์ที่ใช้ในการเทรดและการบริหารจัดการเงินในพอร์ตลงทุน

ในงานวิจัยนี้ ผู้วิจัยได้นำเสนอกกลยุทธ์ในการบริหารจัดการเงินในบัญชีเทรด โดยประยุกต์มาจากกลยุทธ์การซื้อขาย Martingale (Martingale Trading Strategy) (“The Martingale Strategy: A Negative Progression System”, 2019) ซึ่งกลยุทธ์นี้เป็นกลยุทธ์ที่สามารถอธิบายหลักการได้ง่าย ๆ คือเมื่อเกิดการสูญเสีย นักลงทุนจะต้องทำการเพิ่มจำนวนเงินที่จะลงทุนในครั้งถัดไปจนกว่าจะเทรดชนะ การทำเช่นนี้จะทำให้นักลงทุนได้รับเงินลงทุนที่สูญเสียไปในการเทรด แต่ก่อนหน้านี้อาจกลับคืนมาและยังได้กำไรเพิ่มขึ้นอีกด้วย ยกตัวอย่างให้เห็นภาพชัดเจนมากขึ้นดังนี้

ถ้านักลงทุนเทรดครั้งแรกด้วยจำนวนเงิน 1 ดอลลาร์ ผลจากการเทรดครั้งแรกแพ้นักลงทุนจะสูญเสียเงินจำนวน 1 ดอลลาร์ ดังนั้นในการลงทุนครั้งต่อไปหากนักลงทุนต้องการที่จะได้เงินกลับคืนมารวมทั้งผลกำไรสุทธิที่เพิ่มขึ้นด้วย นักลงทุนจะต้องลงทุนในครั้งที่ 2 ด้วยจำนวนเงิน 3 ดอลลาร์ หมายความว่า การลงทุนครั้งที่ 1 และครั้งที่ 2 นี้ นักลงทุนใช้เงินในพอร์ตของตนไปแล้วจำนวน 4 ดอลลาร์ (สูญเสียครั้งที่แล้ว 1 ดอลลาร์ร่วมกับเงินที่ลงทุนไปในครั้งที่ 2 อีก 3 ดอลลาร์ รวมเป็น 4 ดอลลาร์) ถ้าครั้งนี้ นักลงทุนเทรดชนะจะได้รับเงินกลับคืนมาคิดเป็นจำนวนเงิน 5.4 ดอลลาร์ (กรณีที่ว่าโบรกเกอร์จ่ายค่าตอบแทนการลงทุนที่ 80%) ดังนั้นการลงทุนในครั้งนี้นัก

ลงทุนจะได้รับเงินที่เขาลงทุนในครั้งที่ 1 และครั้งที่ 2 กลับคืนมาจำนวน 4 ดอลลาร์และยังได้รับกำไรจากการลงทุนเพิ่มขึ้นอีก 1.4 ดอลลาร์ หลังจากที่นักลงทุนเทรดชนะแล้วในการเทรดครั้งถัดไป นักลงทุนจะกลับมาลงทุนด้วยจำนวนเงินตั้งต้นเท่ากับจำนวนเงินในการเทรดครั้งแรก (1 ดอลลาร์) แต่หากเทรดแพ้ก็จะต้องเพิ่มจำนวนเงินในการลงทุนไปเรื่อย ๆ ดังแสดงในตารางที่ 3.1

ตารางที่ 3.1 ตารางแสดงจำนวนเงินที่ใช้ลงทุนและผลกำไรตอบแทนในการซื้อขายแต่ละรอบ

Trade Number	Trade Amount (\$)	Sum of Previous Loss + Current Trade (\$)	Payout at 80% (\$)	Profits (\$)
1	1	1	1.8	0.8
2	3	4	5.4	1.4
3	7	11	12.6	1.6
4	16	27	28.8	1.8
5	37	64	66.6	2.6
6	84	148	151.2	3.2
7	190	338	342.0	4.0
8	428	766	770.4	4.4

จากตารางที่ 3.1 ในคอลัมน์ที่ 3 (Sum of Previous Loss + Current Trade (\$)) แสดงจำนวนเงินทั้งหมดที่สูญเสียไปในการเทรดแพ้มาก่อนหน้านี้นี้รวมกับจำนวนเงินที่ต้องใช้ในการลงทุนในปัจจุบัน ตัวเลขนี้แสดงถึงความเสี่ยงที่นักลงทุนจะต้องให้ความสำคัญเป็นอย่างมาก เพราะว่าตัวเลขดังกล่าวสอดคล้องกับจำนวนเงินในพอร์ตลงทุน เช่น ถ้านักลงทุนมีเงินอยู่ในพอร์ตลงทุนจำนวน 500 ดอลลาร์ ถ้าเทรดโดยใช้กลยุทธ์นี้จะแพ้ต่อเนื่องได้มากที่สุดไม่เกิน 7 ครั้ง หากเขาเทรดแพ้ 7 ครั้งเงินลงทุนคงเหลือในพอร์ตลงทุนของนักลงทุนจะมีไม่เพียงพอสำหรับการเทรดในครั้งที่ 8 (ลงทุนครั้งที่ 8 ใช้เงินลงทุนจำนวน 766 ดอลลาร์ แต่เงินในพอร์ตลงทุนคงเหลือเพียงแค่ 162 ดอลลาร์) ดังนั้นจำเป็นต้องจำกัดวงเงินสูงสุดที่สามารถสูญเสียได้ไม่ให้เกินวงเงินที่มีอยู่ในพอร์ตลงทุน อีกทั้งยังทำให้นักลงทุนมีเงินเหลือในพอร์ตลงทุนกลับมาเริ่มต้นการเทรดครั้งใหม่ที่มีเงินลงทุนต่ำสุด (1 ดอลลาร์) การกระทำเช่นนี้เรียกว่าการตัดขาดทุน (Cut Loss) ซึ่งการตัดขาดทุนจะทำให้ให้นักลงทุนมีโอกาสที่จะใช้เงินคงเหลือในพอร์ตลงทุนสร้างผลกำไรในอนาคตได้ ดังนั้นนักลงทุนจะต้องกำหนดกลยุทธ์ที่จะใช้ในการตัดขาดทุนที่เหมาะสม ซึ่งจะอธิบายในหัวข้อถัดไป



### 3.2.3.3 กลยุทธ์ในการตัดขาดทุน

การตัดขาดทุนเป็นกลยุทธ์ที่จำเป็นสำหรับนักลงทุน โดยเฉพาะอย่างยิ่งการลงทุนในรูปแบบที่มีความเสี่ยงสูง เช่น การซื้อขายแลกเปลี่ยนเงินตราต่างประเทศและการลงทุนในตัวเลือกไบนารี ซึ่งทั้งสองรูปแบบนี้นักลงทุนสามารถทำกำไรจำนวนมากได้อย่างรวดเร็ว ในทางตรงกันข้ามพวกเขาก็สามารถสูญเสียเงินทั้งหมดในพอร์ตการลงทุนของเขาได้ในเวลาอันรวดเร็วเช่นกัน ดังนั้นกลยุทธ์ในการตัดขาดทุนจึงเป็นสิ่งจำเป็นที่นักลงทุนจะต้องทำอย่างมีวินัย ในความเป็นจริงนั้นมึ่นักลงทุนจำนวนมากที่ไม่ให้ความสำคัญกับการตัดขาดทุน ทำให้พวกเขาสูญเสียเงินลงทุนจนกระทั่งไม่เหลือเงินเพียงพอที่จะสร้างผลกำไรกลับคืนมาได้

กลยุทธ์ในการตัดขาดทุนที่นิยมใช้โดยทั่วไปคือ นักลงทุนทำการระบุอัตราส่วนความเสี่ยง (Risk Ratio) (Hayes, 2019) ที่ตนเองรับได้ จากนั้นนำค่าอัตราส่วนความเสี่ยงที่กำหนดไปคำนวณเป็นจำนวนเงินที่จะต้องทำการตัดขาดทุน ยกตัวอย่างเช่น ถ้านักลงทุนมีเงินในพอร์ตลงทุนจำนวน 500 ดอลลาร์ และกำหนดอัตราส่วนความเสี่ยงไว้ที่ร้อยละ 40 หมายความว่านักลงทุนจะต้องทำการตัดขาดทุนเมื่อเขาสูญเสียเงินลงทุนในพอร์ตไปแล้วจำนวน 200 ดอลลาร์ ( $500 \times 40\%$ ) ในกรณีที่เป็นการลงทุนในตลาดหุ้น นักลงทุนจะต้องขายสินทรัพย์นั้น ๆ เมื่อมูลค่าของสินทรัพย์ลดลงกว่ามูลค่า ณ ตอนที่เข้าซื้อเป็นจำนวนเงิน 200 ดอลลาร์

ส่วนกรณีที่เป็นการลงทุนในตลาดซื้อขายเงินตราต่างประเทศนั้น นักลงทุนจะต้องส่งคำสั่งปิดออเดอร์เมื่อมูลค่ากำไรขาดทุนที่เกิดจากออเดอร์ที่เปิดอยู่นั้นคิดลบเป็นจำนวนเงินเกินกว่า 200 ดอลลาร์ อย่างไรก็ตามสำหรับการลงทุนในการซื้อขายตัวเลือกไบนารีนั้นแตกต่างจากการลงทุนในตลาดหุ้นและตลาดซื้อขายเงินตราต่างประเทศ เนื่องจากการลงทุนในการซื้อขายตัวเลือกไบนารีนั้น คำสั่งซื้อขายจะถูกปิดเองอัตโนมัติเมื่อถึงเวลาที่กำหนด ดังนั้นนักวิจัยจึงได้นำเสนอกลยุทธ์ในการตัดขาดทุนสำหรับการลงทุนในตัวเลือกไบนารีที่สอดคล้องกับกลยุทธ์ในการลงทุนแบบ Martingale Trading Strategy ซึ่งมีวิธีการดังนี้

- 1) กำหนดอัตราส่วนความเสี่ยงที่เหมาะสมอยู่ที่ 20%
- 2) คำนวณจำนวนเงินที่ต้องทำการตัดขาดทุนจากอัตราส่วนความเสี่ยงที่กำหนด (100 ดอลลาร์ ในกรณีที่มีเงินในพอร์ตลงทุนจำนวน 500 ดอลลาร์)
- 3) เมื่อเทรดด้วยกลยุทธ์ Martingale แล้วเพื่ออย่างต่อเนื่องทำให้สูญเสียเงินลงทุนเป็นจำนวนมากหรือเท่ากับจำนวนเงินที่ต้องทำการตัดขาดทุน การลงทุนในครั้งถัดไปนั้นให้นักลงทุนต้องหยุดทำการเพิ่มจำนวนเงินลงทุนและกลับมาลงทุนด้วยจำนวนเงินลงทุนเริ่มต้นใหม่อีกครั้ง (ตัดขาดทุนเมื่อเทรดแพ้ติดต่อกันจำนวน 6 ครั้ง และการลงทุนในครั้งถัดไป

จะต้องลงทุนด้วยจำนวนเงิน 1 ดอลลาร์ ในกรณีที่ไม่มีเงินในพอร์ตลงทุน  
จำนวน 500 ดอลลาร์)

### 3.2.4 การวัดประสิทธิภาพด้านการเงินของโมเดลในการซื้อขายตัวเลือกไบนารี

นอกจากโมเดลที่ถูกพัฒนาในงานวิจัยนี้จะถูกวัดประสิทธิภาพด้านความแม่นยำในการ  
จำแนกและการทำนายผลแล้ว ผู้วิจัยยังได้ทดสอบในการใช้งาน โมเดลร่วมกับการใช้กลยุทธ์การ  
เทรดและการบริหารจัดการเงินในพอร์ตลงทุนรวมทั้งกลยุทธ์ในการตัดขาดทุนเพื่อทดสอบ  
ประสิทธิภาพด้านการทำกำไรในการซื้อขายตัวเลือกไบนารีอีกด้วย โดยการวัดประสิทธิภาพในด้าน  
นี้จะแบ่งเป็น 2 ส่วนคือการทดสอบแบบย้อนกลับ (Backward Test) ซึ่งเป็นการทดสอบโดยการใช้  
ข้อมูลย้อนหลังและการทดสอบแบบไปข้างหน้า (Forward Test) ซึ่งเป็นการทดสอบโดยการใช้  
ข้อมูลการซื้อขายที่เกิดขึ้นจริงในปัจจุบัน โดยผู้วิจัยได้กำหนดระยะเวลาในการทดสอบ  
ประสิทธิภาพในขั้นตอนนี้ไว้เป็นระยะเวลา 4 เดือนย้อนหลังสำหรับการทดสอบ Backward Test  
และ 1 เดือนไปข้างหน้าสำหรับการทดสอบแบบ Forward Test

#### 3.2.5.1 การทดสอบแบบย้อนกลับ

การทดสอบย้อนกลับ เป็นการจำลองการเทรดเพื่อวัดประสิทธิภาพใน  
ด้านการทำกำไรหรือขาดทุนของกลยุทธ์ที่นำมาใช้ในการเทรด สำหรับการทดสอบย้อนกลับที่ทำ  
การทดลองในงานวิจัยนี้ ได้นำข้อมูลย้อนหลังของราคาอ้างอิงอัตราแลกเปลี่ยนเงินตราต่างประเทศ  
คู่เงิน EURUSD คาบเวลา 5 นาที การจำลองการเทรดจะใช้ข้อมูลย้อนหลังเป็นระยะเวลา 4 เดือน  
เริ่มตั้งแต่วันที่ 2 มกราคม พ.ศ. 2562 จนถึง วันที่ 30 เมษายน พ.ศ. 2562 มาใช้เป็นข้อมูลในการ  
จำลองการเทรดเพื่อวัดประสิทธิภาพของโมเดลและกลยุทธ์ในการเทรดที่ได้นำเสนอ ข้อมูลที่ถูก  
นำมาใช้ในแต่ละวันจะถูกตัดออกมาเฉพาะช่วงเวลา 13.00 ถึงเวลา 23.00 น. ดังนั้นข้อมูลแต่ละวัน  
จะมีจำนวนข้อมูลที่ใช้เทรดวันละ 120 ข้อมูล อีกนัยหนึ่งคือในหนึ่งวันจะทำการเทรดจำนวนทั้งสิ้น  
120 ครั้งโดยใช้กลยุทธ์ในการเทรดและการตัดขาดทุนดังที่อธิบายไว้ในหัวข้อก่อนหน้านี้ กำหนด  
เงินลงทุนเริ่มต้นที่กำหนดให้ในแต่ละเดือนคือ 500 ดอลลาร์

เมื่อทำการจำลองการเทรดครบ 1 เดือน นักวิจัยทำการสรุปผลการทดลอง  
ที่ได้จากการจำลองการเทรด ซึ่งประกอบด้วย กำไรหรือขาดทุนและจำนวนเงินคงเหลือในพอร์ต  
การลงทุนรายวันและรายเดือน และนักลงทุนจะต้องกลับมาเริ่มต้นลงทุนด้วยเงินลงทุนในพอร์ต  
ลงทุน จำนวนเงิน 500 ดอลลาร์ ในทุก ๆ เดือน

### 3.2.5.2 การทดสอบแบบไปข้างหน้า

การทดสอบแบบไปข้างหน้า เป็นการนำเครื่องมือและกลยุทธ์ทั้งหมดที่ได้นำเสนอในงานวิจัยนี้มาทดลองเทรดจริง โดยโบรกเกอร์ที่ใช้ลงทุนในงานวิจัยนี้คือ Olymp Trade (<https://olymptrade.com>) คู่เงินที่ใช้ในการเทรดคือ EURUSD ในคาบเวลา 5 นาที โดยการทดสอบไปข้างหน้าในครั้งนี้จะทดสอบเป็นระยะเวลา 1 เดือน เริ่มตั้งแต่วันที่ 1 พฤษภาคม พ.ศ. 2562 จนถึง วันที่ 30 พฤษภาคม พ.ศ. 2562 ช่วงเวลาที่ทำการเทรดคือตั้งแต่เวลา 13.00 ถึงเวลา 23.00 น. ของแต่ละวัน เมื่อทำการจำลองการเทรดครบหนึ่งเดือน ทำการสรุปผลการทดลองที่ได้จากการจำลองการ เทรด ซึ่งประกอบด้วยมูลค่ากำไรหรือขาดทุนและจำนวนเงินคงเหลือในพอร์ตการลงทุนรายวันและรายเดือนเช่นเดียวกันกับการทดสอบย้อนกลับ

### 3.3 เครื่องมือที่ใช้สำหรับการวิจัย

เครื่องมือที่ใช้ในการพัฒนางานวิจัยนี้ ประกอบด้วย

- 1) เครื่องคอมพิวเตอร์สำหรับพัฒนา มีรายละเอียดดังนี้
  - หน่วยประมวลผลกลาง : Intel(R) Core(TM) i7-7700 CPU @ 3.40GHz
  - หน่วยประมวลผลกราฟิก : NVIDIA GeForce GTX 1060 6GB × 6 Cards
  - หน่วยความจำหลัก : 32 GB
  - หน่วยความจำสำรอง : 1 TB
- 2) ระบบปฏิบัติการและ โปรแกรมประยุกต์สำหรับพัฒนา ประกอบด้วย
  - ระบบปฏิบัติการ : Windows 10 Home 64 bits
  - ภาษาที่ใช้พัฒนา : Python 3
  - ซอฟต์แวร์และกรอบงานที่ใช้ในการพัฒนา : Anaconda, Jupyter Notebook, Tensor Flow และ Keras

## บทที่ 4

### ผลการศึกษาและการวิเคราะห์ผล

วัตถุประสงค์หลักของงานวิจัยนี้คือการนำความรู้ทางด้านปัญญาประดิษฐ์ โดยเฉพาะเทคนิคการเรียนรู้เชิงลึก ได้แก่ หน่วยความจำระยะสั้นระยะยาว มาประยุกต์เพื่อพัฒนาเป็น โมเดลสำหรับทำนายทิศทางการเปลี่ยนแปลงราคาอ้างอิงในคาบเวลาถัดไปของสกุลเงินในตลาดการซื้อขายแลกเปลี่ยนเงินตราต่างประเทศ ซึ่งโมเดลนี้จะช่วยให้นักลงทุนสามารถกำหนดทิศทางการลงทุนแต่ละครั้งในการซื้อขายตัวเลือกไบนารีได้ นอกจากนี้ยังได้นำเสนอวิธีการเพิ่มประสิทธิภาพให้กับโมเดลด้วยเทคนิคต่าง ๆ ซึ่งจะทำให้โมเดลทำนายข้อมูลได้อย่างแม่นยำมากขึ้น นอกจากนี้ยังได้นำเสนอกกลยุทธ์ที่ใช้ในการลงทุนซึ่งเป็นการประยุกต์ใช้ทฤษฎีแบบ Martingale และกลยุทธ์ในการตัดขาดทุนที่เหมาะสมกับการลงทุนในการซื้อขายตัวเลือกไบนารี นอกจากการวัดประสิทธิภาพด้านความแม่นยำในการทำนายของโมเดลแล้ว งานวิจัยนี้ได้ทำการวัดประสิทธิภาพในด้านการทำกำไรของเครื่องมือและกลยุทธ์ต่าง ๆ ที่ได้นำเสนอด้วยการจำลองการเทรดโดยใช้ข้อมูลย้อนหลัง (Backward Test) และการให้นักลงทุนทดลองใช้เครื่องมือและกลยุทธ์ที่ได้นำเสนอในงานวิจัยนี้ในการเทรดจริง (Forward Test) จากผลการทดลองทั้งหมด สามารถสรุปผลการศึกษาและวิเคราะห์ผลการศึกษาที่ได้ ดังต่อไปนี้

#### 4.1 ผลการทดสอบประสิทธิภาพโมเดลพื้นฐานสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไป

ในขั้นตอนแรกสุดของกระบวนการวิจัยนี้คือการพัฒนาโมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไป โดยใช้เทคนิค LSTM ซึ่งยังไม่ผ่านกระบวนการปรับปรุงประสิทธิภาพ โดยโมเดลนี้จะถูกใช้เป็นโมเดลพื้นฐานในการเปรียบเทียบประสิทธิภาพด้านความแม่นยำในการทำนายกับโมเดล LSTM ที่ผ่านกระบวนการเพิ่มประสิทธิภาพด้วยวิธีการต่าง ๆ ซึ่งขั้นตอนในการสร้างโมเดล LSTM พื้นฐานนี้เริ่มจากนำข้อมูลที่ได้อัดเตรียมไว้ดังอธิบายในหัวข้อที่ 3.1.2 ซึ่งได้แก่ ข้อมูลย้อนหลังของราคาอ้างอิงการซื้อขายเงินตราต่างประเทศสกุลเงิน EURUSD คาบเวลา 5 นาที ตั้งแต่วันที่ 2 มกราคม ถึงวันที่ 30 เมษายน พ.ศ. 2562 ที่ถูกแปลงให้อยู่

ในรูปของชุดข้อมูลอนุกรมเวลาแบบไบนารี ในขั้นตอนนี้ผู้วิจัยได้ทำการแบ่งข้อมูลชุดนี้โดยกำหนดให้ข้อมูลที่อยู่ในช่วงเวลาตั้งแต่วันที่ 2 มกราคม ถึงวันที่ 31 มีนาคม พ.ศ. 2562 เป็นข้อมูลสำหรับการเรียนรู้ของโมเดลและข้อมูลที่อยู่ในช่วงเวลาตั้งแต่วันที่ 1 – 31 เมษายน พ.ศ. 2562 เป็นข้อมูลสำหรับการทดสอบประสิทธิภาพของโมเดลโดยใช้มาตรวัดประสิทธิภาพของโมเดลได้แก่ Accuracy, Precision, Recall และ F-Measure ซึ่งผลการทดสอบประสิทธิภาพแสดงในรูปที่ 4.1 และตารางที่ 4.1

**Confusion Matrix**

<b>Output Class</b>	Up (1)	685	584	54.0%
	Down (0)	669	702	51.2%
		50.6%	54.6%	<b>52.5%</b>
		Up (1)	Down (0)	
		<b>Target Class</b>		

รูปที่ 4.1 Confusion Matrix แสดงผลการทดสอบประสิทธิภาพโมเดลพื้นฐานสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไป

รูปที่ 4.1 แสดงตาราง Confusion Matrix ซึ่งบ่งบอกถึงผลลัพธ์ที่โมเดลทำนาย จากข้อมูลที่ใช้ทดสอบทั้งสิ้นจำนวน 2,640 ข้อมูล โมเดลได้ทำนายได้ถูกต้องจำนวน 1,387 ข้อมูลแบ่งเป็นทำนายถูกต้องสำหรับข้อมูลแนวโน้มการของราคาอ้างอิงแบบขาขึ้นจำนวน 685 ข้อมูล และแบบขาลงจำนวน 702 ข้อมูล ค่าในตาราง Confusion Matrix ถูกนำไปคิดเป็นค่าความแม่นยำในการทำนายดังแสดงในตารางที่ 4.1

ตารางที่ 4.1 สรุปผลการทดสอบประสิทธิภาพโมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไปโดยใช้มาตรวัดต่าง ๆ

Class	Accuracy (%)	Precision (%)	Recall (%)	F-Measure (%)
Up (1)	52.5	50.6	54.0	52.2
Down (0)		54.6	51.2	52.8
<i>Average</i>		52.6	52.6	52.5

ตารางที่ 4.1 แสดงผลลัพธ์ในด้านความแม่นยำในการทำนายของโมเดล ซึ่งโมเดลมีความแม่นยำโดยรวม (Accuracy) อยู่ที่ 52.5% นอกจากนี้จะเห็นว่าเมื่อสนใจเฉพาะส่วนที่ทำนาย โมเดลสามารถทำนายคลาส Down ได้ดีกว่าคลาส Up (ค่า Precision ของ Down สูงที่สุดเป็น 54.6%) ในขณะที่เมื่อดูความครอบคลุมของการทำนายข้อมูลพบว่า โมเดลสามารถทำนายคลาส Up ได้ดีที่สุด (ค่า Recall ของ Up เป็น 54.0%)

จากผลการทดสอบประสิทธิภาพของโมเดลในขั้นตอนนี้พบว่าโมเดลมีความแม่นยำโดยรวม อยู่ที่ 52.5% ซึ่งความแม่นยำระดับนี้ยังไม่เพียงพอที่จะนำไปใช้เป็นเครื่องมือเพื่อใช้ทำนายทิศทางของการเปลี่ยนแปลงราคาในการเทรดได้ เนื่องจากโมเดลที่จะใช้ได้นั้นจะต้องมีความแม่นยำในการทำนายมากกว่า 65% (50% รวมกับค่า Commission 15%) ดังนั้นงานวิจัยนี้ได้นำเสนอวิธีการต่าง ๆ เพื่อเพิ่มประสิทธิภาพให้กับโมเดล ซึ่งผลการทดลองแสดงในหัวข้อถัดไป

#### 4.2 ผลการทดสอบประสิทธิภาพโมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไปเมื่อผ่านกระบวนการเพิ่มประสิทธิภาพโดยการกำหนดค่าพารามิเตอร์ต่าง ๆ ให้เหมาะสม

หัวข้อนี้แสดงผลจากการเพิ่มประสิทธิภาพให้โมเดลโดยการกำหนดค่าพารามิเตอร์ต่าง ๆ ให้เหมาะสม ซึ่งค่าพารามิเตอร์ที่สำคัญ ประกอบด้วยข้อกำหนด 1) ความยาวของข้อมูลนำเข้าที่เหมาะสมสำหรับการสร้างโมเดล 2) จำนวนข้อมูลที่เหมาะสมสำหรับการเรียนรู้ของโมเดล และ 3) ระยะเวลาที่เหมาะสมที่ต้องทำการปรับปรุงโมเดลให้ทันสมัยเพื่อรักษาความแม่นยำในการทำนายผลลัพธ์ของการทดลองหลังจากการกำหนดค่าพารามิเตอร์ทั้ง 3 พารามิเตอร์แสดงในหัวข้อที่

4.2.1 – 4.2.3

#### 4.2.1 การกำหนดความยาวของข้อมูลนำเข้าที่เหมาะสมสำหรับการสร้างโมเดล

เนื่องจากข้อมูลราคาอ้างอิงในการซื้อขายเงินตราต่างประเทศนั้นเป็นข้อมูลแบบอนุกรมเวลาที่มีความเกี่ยวเนื่องกันระหว่างข้อมูลก่อนหน้า ข้อมูลปัจจุบัน และข้อมูลที่จะเกิดขึ้นในอนาคต การกำหนดความยาวของข้อมูลที่ใช้เป็นข้อมูลนำเข้าให้โมเดลเรียนรู้และทำนายนั้น มีความสำคัญต่อประสิทธิภาพด้านความแม่นยำในการทำนายของโมเดล ดังนั้นการกำหนดความยาวของข้อมูลที่จะใช้เป็นข้อมูลนำเข้าสำหรับการสร้างโมเดลที่เหมาะสม จะช่วยเพิ่มความแม่นยำในการทำนายของโมเดลได้ ในกระบวนการนี้ได้ทำการทดลองโดยกำหนดความยาวของข้อมูลที่ใช้เป็นข้อมูลนำเข้าของโมเดลที่หลากหลายซึ่งมีค่าอยู่ระหว่าง 3 – 30 คาบเวลา ในส่วนของการทดสอบประสิทธิภาพการทำนายของโมเดลที่ถูกกำหนดค่าพารามิเตอร์ดังกล่าวนั้น จะทดสอบโดยใช้ข้อมูลทดสอบเป็นระยะเวลา 1 เดือน จำนวนทั้งสิ้น 4 เดือนคือ ตั้งแต่เดือน มกราคม พ.ศ. 2562 ถึงเดือน เมษายน พ.ศ. 2562 ส่วนข้อมูลที่ใช้สร้างโมเดลจะเป็นข้อมูลจำนวน 2 เดือนก่อนหน้าของข้อมูลในเดือนที่ใช้ทดสอบ มาตรวัดที่ใช้วัดประสิทธิภาพของโมเดลในขั้นตอนนี้คือค่า Accuracy ผลการทดสอบในขั้นตอนนี้แสดงในตารางที่ 4.2

ตารางที่ 4.2 สรุปผลการทดสอบประสิทธิภาพโมเดลที่มีการกำหนดความยาวของข้อมูลนำเข้าที่เหมาะสมสำหรับการสร้างโมเดล

Training periods	Testing periods	Input length (Periods)								
		5	7	9	10	12	15	20	25	30
November 2018 – December 2018	January 2019	46.6	49.9	55.4	<b>56.1</b>	52.3	54.2	54.0	55.1	47.8
December 2018 – January 2019	February 2019	48.4	50.0	54.1	<b>55.2</b>	54.0	52.0	53.8	51.8	45.9
January 2019 – February 2019	March 2019	50.1	50.7	52.2	54.8	<b>56.2</b>	54.9	54.5	49.7	52.6
February 2019 – March 2019	April 2019	47.7	50.5	49.7	<b>52.0</b>	51.5	48	47.2	45	49.7
<b>Average</b>		48.2	50.3	52.9	<b>54.5</b>	53.5	52.3	52.4	50.4	49.0

ตารางที่ 4.2 แสดงผลการทดสอบโมเดลที่ถูกกำหนดค่าความยาวของข้อมูลนำเข้าที่หลากหลาย ซึ่งผลการทดสอบพบว่าในการกำหนดความยาวของข้อมูลนำเข้าเท่ากับ 10 คาบเวลา ทำให้โมเดลมีประสิทธิภาพในการทำนายสูงที่สุดในเดือน มกราคม (56.1%) กุมภาพันธ์ (55.2%) และเมษายน (52.0%) ในขณะที่เดือนมีนาคม ค่าที่เหมาะสมซึ่งทำให้โมเดลมีประสิทธิภาพดีที่สุดคือการกำหนดความยาวของข้อมูลนำเข้าเท่ากับ 12 คาบเวลา เมื่อดูที่ค่าเฉลี่ยของทั้ง 4 เดือนพบว่าโมเดลที่มีการกำหนดความยาวของข้อมูลนำเข้าเท่ากับ 10 คาบเวลาให้ประสิทธิภาพความแม่นยำในการทำนายสูงที่สุดคือ 54.5% ดังนั้นการทดลองในขั้นตอนถัดไปต่อจากนี้จะมีการกำหนดความยาวของข้อมูลนำเข้าเท่ากับ 10 คาบเวลา ซึ่งเป็นค่าเหมาะสมที่ทำให้โมเดลมีความแม่นยำโดยรวมเฉลี่ยสูงที่สุดจากการทดลองในขั้นตอนนี้

#### 4.2.2 การกำหนดจำนวนข้อมูลที่เหมาะสมสำหรับการเรียนรู้ของโมเดล

เนื่องจากข้อมูลราคาอ้างอิงในการซื้อขายเงินตราต่างประเทศเป็นข้อมูลเป็นอนุกรมเวลา ดังนั้นการใช้ข้อมูลจำนวนมากเกินไปเพื่อให้โมเดลเรียนรู้นี้อาจรวมข้อมูลที่ซ้ำซ้อน ซึ่งจะส่งผลให้โมเดลมีประสิทธิภาพในการทำนายลดลง ดังนั้นการกำหนดจำนวนของข้อมูลที่เหมาะสมเพื่อให้โมเดลเรียนรู้ จึงเป็นอีกปัจจัยหนึ่งที่มีความสำคัญ ซึ่งจะช่วยให้ประสิทธิภาพความแม่นยำในการทำนายให้กับโมเดลได้ ในขั้นตอนนี้ผู้วิจัยได้กำหนดจำนวนของข้อมูลที่ใช้เป็นข้อมูลสำหรับให้โมเดลเรียนรู้ที่หลากหลาย ซึ่งเลือกกำหนดข้อมูลเป็นจำนวนวัน โดยในการทดลองจะกำหนดข้อมูลระหว่าง 5 – 90 วัน ผลลัพธ์ของการทดลองในขั้นตอนนี้แสดงในตารางที่ 4.3 ในส่วนของการทดสอบประสิทธิภาพโมเดลนั้นใช้ข้อมูลในเดือน มกราคม พ.ศ. 2562 ถึงเดือน เมษายน พ.ศ. 2562 โดยมาตรวัดที่ใช้วัดประสิทธิภาพของโมเดลคือค่า Accuracy

ตารางที่ 4.3 สรุปผลการทดสอบประสิทธิภาพ โมเดลที่มีการกำหนดจำนวนข้อมูลสำหรับการเรียนรู้ของโมเดลที่หลากหลาย

Testing periods	Amount of Training Data (Days)					
	5	7	14	30	60	90
January 2019	50.5	52.5	<b>62.7</b>	57.8	55.5	56.6
February 2019	47.3	55.7	61.9	<b>62.2</b>	60.6	58.8
March 2019	51.7	54.1	<b>58.5</b>	58.2	52.9	54.5
April 2019	49.5	54.2	<b>61.7</b>	58.5	55.3	57.6
<b>Average</b>	49.8	54.1	<b>61.2</b>	59.2	56.1	56.9



ตารางที่ 4.3 สรุปผลการทดสอบประสิทธิภาพโมเดลที่ถูกสร้างขึ้นโดยมีการกำหนดจำนวนข้อมูลสำหรับการเรียนรู้ของโมเดลที่แตกต่างกัน จากผลการทดลองพบว่า โมเดลที่ถูกสร้างขึ้น โดยใช้ข้อมูลสำหรับการเรียนรู้ จำนวน 14 วันมีประสิทธิภาพในการทำนายสูงที่สุดในเดือนมกราคม (62.7%) มีนาคม (58.8%) และเมษายน (61.2%) ส่วนเดือนกุมภาพันธ์นั้น จำนวนข้อมูลที่ทำให้โมเดลมีประสิทธิภาพในการทำนายมากที่สุดคือ 30 วัน ในขณะที่เมื่อดูจากค่าเฉลี่ยแล้ว การกำหนดข้อมูลสำหรับการเรียนรู้จำนวน 14 วันทำให้โมเดลทำนายได้แม่นยำมากที่สุดที่ 61.2% ดังนั้นค่าที่เหมาะสมที่สุดในการกำหนดจำนวนข้อมูลสำหรับการเรียนรู้ของโมเดลคือการใช้ข้อมูลจำนวน 14 วัน ซึ่งค่าพารามิเตอร์นี้จะถูกกำหนดในการสร้างโมเดลในขั้นตอนต่อ ๆ ไป

#### 4.2.3 การกำหนดระยะเวลาที่เหมาะสมเพื่อการปรับปรุงโมเดลให้ทันสมัย


โมเดลที่ถูกสร้างขึ้น โดยข้อมูลแบบอนุกรมเวลานั้นเมื่อใช้ไประยะหนึ่งจะพบว่าประสิทธิภาพในการทำนายจะมีค่าลดลงเนื่องจากมีการล้าสมัยของข้อมูล ดังนั้นเพื่อรักษาประสิทธิภาพในการทำนาย โมเดลจะต้องได้รับการปรับปรุงให้มีความทันสมัยอย่างต่อเนื่อง ในขั้นตอนนี้เป็นการทดลองเพื่อหาระยะเวลาที่เหมาะสมเพื่อทำการปรับปรุงข้อมูลให้ทันสมัย โดยการทดลองนั้นจะพัฒนาโมเดล โดยใช้พารามิเตอร์ที่เหมาะสมจากขั้นตอนที่ 4.2.1 และ 4.2.2 ซึ่งชุดข้อมูลที่นำมาใช้ในขั้นตอนนี้คือข้อมูลอนุกรมเวลาแบบไบนารีของเดือนมกราคม ถึง เดือนเมษายน พ.ศ. 2562 ข้อมูล 14 วันแรกของแต่ละเดือนจะถูกใช้เป็นข้อมูลสำหรับการเรียนรู้ ในขณะที่ข้อมูลแต่ละวันหลังจากนั้นจะถูกใช้เป็นข้อมูลทดสอบ มาตรวัดที่ใช้วัดประสิทธิภาพของโมเดลในขั้นตอนนี้คือค่า Accuracy ผลลัพธ์ของการทดสอบของกระบวนการในขั้นตอนนี้แสดงในตารางที่ 4-4

จากผลสรุปในตารางที่ 4.4 พบว่าโมเดลมีประสิทธิภาพในการทำนายสูงที่สุดในวันทำการทดสอบที่ 1 ของเดือนมกราคม (65.5%) มีนาคม (70.0%) และเมษายน (66.7%) ในขณะที่เดือนกุมภาพันธ์นั้น โมเดลมีประสิทธิภาพในการทำนายสูงที่สุดในวันทำการทดสอบที่ 2 (68.3%) เพื่อให้ทำการวิเคราะห์ข้อมูลได้ง่ายขึ้น ผู้วิจัยได้นำข้อมูลในตารางที่ 4-4 มาสร้างเป็นกราฟเส้นดังแสดงในรูปที่ 4.2

รูปที่ 4.2 แสดงกราฟเส้นของผลการทดสอบประสิทธิภาพความแม่นยำโดยรวมในการทำนายผลรายวันของข้อมูลเดือนมกราคม ถึงเดือนเมษายน พ.ศ. 2562 ซึ่งจากข้อมูลสรุปในรูปที่ 4.2 พบว่าในการทดสอบวันที่ 1 ของทุกเดือนโมเดลมีความแม่นยำในการทำนายโดยรวมเกิน 65% ซึ่งมีความเฉลี่ยของทั้ง 4 เดือนอยู่ที่ 67.5% ในขณะที่การทดสอบในวันที่ 2 ของแต่ละเดือนนั้น มีเพียงเดือนกุมภาพันธ์ (68.8%) และเดือนเมษายน (65.8%) เท่านั้นที่โมเดลมีความแม่นยำในการทำนาย


เกิน 65% แต่หากดูที่ค่าเฉลี่ยของทั้ง 4 เดือนนั้นความแม่นยำในการทำนายของโมเดลในการทดสอบวันที่ 2 นั้นมีค่ามากกว่า 65% โดยมีความแม่นยำในการทำนายที่ 65.4% ส่วนการทดสอบวันอื่น ๆ นั้นโมเดลมีความแม่นยำในการทำนายมากกว่า 65% ในขณะที่ความแม่นยำในการทำนายของโมเดลนั้นลดลงอย่างชัดเจนในวันทดสอบที่ 3 เป็นต้นไป

จากผลการทดลองในขั้นตอนนี้สามารถสรุปได้ว่าควรทำการปรับปรุงโมเดลให้ทันสมัยทุกวันหรืออย่างน้อยทุกสองวัน เพราะว่าจากผลการทดสอบในวันที่ 3 เป็นต้นไปนั้นประสิทธิภาพการทำงานของโมเดลลดลงอย่างชัดเจน



ตารางที่ 4.4 สรุปผลการทดสอบประสิทธิภาพโมเดลเพื่อการหาระยะเวลาที่เหมาะสมสำหรับการปรับปรุงโมเดลให้ทันสมัย

Training periods	Testing periods	Testing Days											
		1	2	3	4	5	6	7	8	9	10	11	12
2 – 15 January 2019	16 – 21 January 2019	65.8	64.2	60.8	50.0	50.0	49.2	55.8	49.2	55.8	49.2	54.2	53.3
1 – 14 February 2019	15 – 27 February 2019	67.5	68.3	50.8	53.3	47.5	49.2	56.7	58.3	51.7	51.7	-	-
1 – 14 March 2019	15 – 29 March 2019	70.0	63.3	51.7	57.5	50.0	55.0	55.0	47.5	54.2	48.3	60.8	-
1 – 14 April 2019	15 – 30 April 2019	66.7	65.8	57.5	53.3	55.8	56.7	46.7	50.8	56.7	45.8	60.0	57.5
<b>Average</b>		<b>67.5</b>	<b>65.4</b>	<b>55.2</b>	<b>53.5</b>	<b>50.8</b>	<b>52.5</b>	<b>53.5</b>	<b>51.5</b>	<b>54.6</b>	<b>48.8</b>	<b>58.3</b>	<b>55.4</b>



รูปที่ 4.2 กราฟสรุปผลการทดสอบประสิทธิภาพโมเดลเพื่อการหาระยะเวลาที่เหมาะสมเพื่อทำการปรับปรุงโมเดลให้ทันสมัย

#### 4.3 ผลการทดสอบประสิทธิภาพโมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไปเมื่อผ่านกระบวนการเพิ่มประสิทธิภาพโดยการใช้ผู้เชี่ยวชาญในการจำแนกข้อมูลตามลักษณะแนวโน้มการเคลื่อนไหวของราคาแต่ละประเภท

วิธีการเพิ่มประสิทธิภาพให้กับโมเดลอีกวิธีหนึ่งที่น่าสนใจในงานวิจัยนี้มีแนวคิดมาจากการที่นักลงทุนมักจะมีรูปแบบการลงทุนในแต่ละประเภทของแนวโน้มความเคลื่อนไหวของราคาอ้างอิงในช่วงเวลานั้น ๆ ในงานวิจัยนี้ผู้วิจัยได้จัดรูปแบบหรือประเภทแนวโน้มการเคลื่อนที่ของราคาอ้างอิงเป็น 3 ประเภทคือ 1) แนวโน้มแบบขาขึ้นอย่างต่อเนื่อง 2) แนวโน้มแบบผันผวน และ 3) แนวโน้มแบบขาลงอย่างต่อเนื่อง (รายละเอียดของแต่ละประเภทอธิบายไว้ในหัวข้อที่ 3.2.2.3) นอกจากนี้แนวคิดในการแบ่งประเภทของแนวโน้มการเคลื่อนที่ของราคาอ้างอิงนั้น เพื่อสร้างโมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไปให้มีความเหมาะสมกับแต่ละรูปแบบของแนวโน้ม โดยผู้วิจัยตั้งสมมุติฐานว่า ถ้าให้แต่ละโมเดลทำการเรียนรู้ข้อมูลที่มีลักษณะเฉพาะซึ่งก็คือแนวโน้มการเคลื่อนที่แต่ละประเภทจะช่วยให้อัลกอริทึมปัญญาประดิษฐ์ที่

นำมาใช้สร้าง โมเดลนั้นสามารถกำหนดค่าน้ำหนักได้เหมาะสมมากยิ่งขึ้น ซึ่งก็จะช่วยเพิ่มความแม่นยำในการทำนายให้กับโมเดล

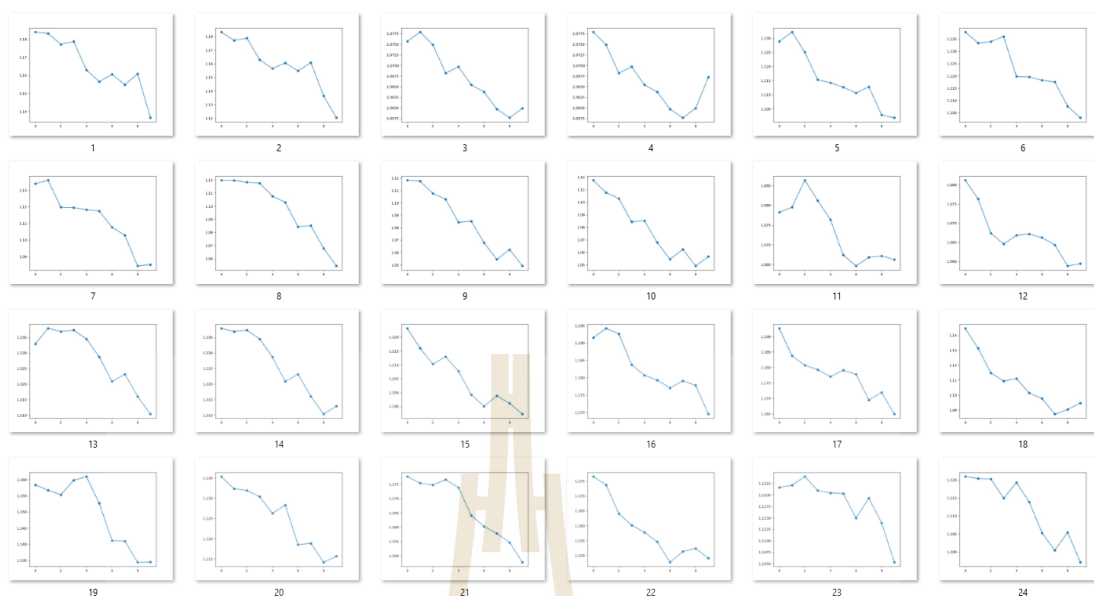
ดังนั้นในขั้นตอนนี้ข้อมูลแบบรูปภาพที่เตรียมไว้จะถูกตัดแยกออกเป็น 3 ชุดข้อมูลตามประเภทการเคลื่อนที่ของแนวโน้มที่กำหนดโดยผู้เชี่ยวชาญ ตัวอย่างรูปภาพของข้อมูลทั้ง 3 ประเภทที่ถูกคัดแยกโดยผู้เชี่ยวชาญแล้วนั้นแสดงรูปที่ 4.3 – 4.5



รูปที่ 4.3 ตัวอย่างรูปภาพข้อมูลประเภทแนวโน้มแบบขาขึ้นอย่างต่อเนื่องที่ถูกจำแนกโดยผู้เชี่ยวชาญ



รูปที่ 4.4 ตัวอย่างรูปภาพข้อมูลประเภทแนวโน้มแบบผันผวนที่ถูกจำแนกโดยผู้เชี่ยวชาญ



รูปที่ 4.5 ตัวอย่างรูปภาพข้อมูลประเภทแนวโน้มแบบขาลงอย่างต่อเนื่องที่ถูกจำแนกโดยผู้เชี่ยวชาญ

หลังจากนั้นข้อมูลอนุกรมเวลาแบบไปนารีจะถูกคัดแยก โดยใช้ตัวเลขอ้างอิงตำแหน่งจากข้อมูลรูปภาพที่ถูกคัดแยกโดยผู้เชี่ยวชาญ และนำไปสร้างเป็น โมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไปจำนวน 3 โมเดลโดยใช้อัลกอริทึม LSTM และ กำหนดค่าพารามิเตอร์ต่าง ๆ ตามผลที่ได้จากการทดลองในขั้นตอนก่อนหน้านี้ และโมเดลถูกปรับปรุงให้ทันสมัยทุกวัน จากนั้น โมเดลจะถูกทดสอบประสิทธิภาพในการทำนายด้วยข้อมูลย้อนหลัง 4 เดือน เริ่มตั้งแต่เดือนมกราคม พ.ศ. 2562 ถึงเดือนเมษายน พ.ศ. 2562 มาตรฐานที่ใช้วัดประสิทธิภาพของโมเดลคือค่า Accuracy ซึ่งผลการทดลองในขั้นตอนนี้สรุปไว้ดังตารางที่ 4.5 – 4.7

ตารางที่ 4-5 แสดงผลการทดสอบประสิทธิภาพโมเดลสำหรับทำนายข้อมูลที่มีลักษณะเป็นแนวโน้มแบบขาขึ้นอย่างต่อเนื่อง จากผลลัพธ์ในตารางพบว่า โมเดลสามารถทำนายได้แม่นยำสูงสุดคือ 82.5% (วันทดสอบที่ 18 เดือนมีนาคม) โดยค่าเฉลี่ยความแม่นยำของโมเดลในแต่ละเดือนมีค่าใกล้เคียงกันคือ เดือนมกราคม (68.6%) เดือนกุมภาพันธ์ (69.7%) เดือนมีนาคม (70.8%) และเดือนเมษายน (69.0%) นอกจากนี้จะเห็นว่าความแม่นยำในการทำนายเฉลี่ยของโมเดลในแต่ละวันตลอดทั้ง 4 เดือนมีค่ามากกว่า 65%

ตารางที่ 4.6 แสดงผลการทดสอบประสิทธิภาพโมเดลสำหรับทำนายข้อมูลที่มีลักษณะเป็นแนวโน้มแบบผันผวน จากผลลัพธ์ในตารางที่ 4.6 ในวันทดสอบที่ 5 และ 6 เดือนมีนาคม โมเดลสามารถทำนายได้แม่นยำสูงสุดคือ 82.5% โดยค่าความแม่นยำเฉลี่ยแต่ละเดือนของโมเดลในเดือน

มกราคมมีค่า 68.6% เดือนกุมภาพันธ์มีค่า 69.7% เดือนมีนาคมมีค่า 70.8% และเดือนเมษายนมีค่า 69.0% เช่นเดียวกับผลลัพธ์ของโมเดลสำหรับทำนายข้อมูลที่มีลักษณะเป็นแนวโน้มแบบขาขึ้นอย่างต่อเนื่อง ความแม่นยำในการทำนายเฉลี่ยของโมเดลในแต่ละวันตลอดทั้ง 4 เดือนมีค่ามากกว่า 65%

ตารางที่ 4.7 แสดงผลการทดสอบประสิทธิภาพโมเดลสำหรับทำนายข้อมูลที่มีลักษณะเป็นแนวโน้มแบบขาขึ้นอย่างต่อเนื่อง ซึ่งผลลัพธ์จากตารางแสดงให้เห็นว่าโมเดลสามารถทำนายได้แม่นยำสูงสุดคือ 80.0% ในวันทดสอบที่ 14 เดือนมีนาคม โดยค่าเฉลี่ยความแม่นยำของโมเดลในแต่ละเดือนมีดังนี้คือ เดือนมกราคมเท่ากับ 68.1% เดือนกุมภาพันธ์มีค่าเท่ากับ 69.0% เดือนมีนาคมมีค่า 71.8% และค่าเฉลี่ยความแม่นยำการทำนายในเดือนเมษายนมีค่าเท่ากับ 70.2% นอกจากนี้จะเห็นว่าความแม่นยำในการทำนายเฉลี่ยของโมเดลในแต่ละวันตลอดทั้ง 4 เดือนมีค่ามากกว่า 65%

จากผลลัพธ์ที่แสดงในตารางที่ 4.5 – 4.7 พบว่าโมเดลมีประสิทธิภาพในการทำนายเพิ่มขึ้นเมื่อสร้างโมเดลด้วยข้อมูลที่มีลักษณะเฉพาะเจาะจงตามรูปแบบของแนวโน้มการเคลื่อนไหวของราคาอ้างอิง โดยค่าเฉลี่ยความแม่นยำในการทำนายของโมเดลแต่ละโมเดลที่ทำนายข้อมูลทั้ง 4 เดือนมีค่า 69.5% สำหรับโมเดลทำนายข้อมูลที่มีลักษณะเป็นแนวโน้มแบบขาขึ้นอย่างต่อเนื่อง 69.8% สำหรับโมเดลทำนายข้อมูลที่มีลักษณะเป็นแนวโน้มแบบผันผวน และ 69.8% สำหรับโมเดลสำหรับทำนายข้อมูลที่มีลักษณะเป็นแนวโน้มแบบขาลงอย่างต่อเนื่อง

ถึงแม้ว่าทั้ง 3 โมเดลจะให้ผลลัพธ์ในการทำนายที่สูง แต่ว่าการใช้ผู้เชี่ยวชาญในการจำแนกข้อมูลนั้น ต้องสูญเสียทั้งเวลาและแรงงานของผู้เชี่ยวชาญในการคัดแยกซึ่งในการเทรดจริงไม่สามารถทำได้ทันภายในเวลา 5 นาทีได้ ดังนั้นงานวิจัยนี้ได้พัฒนาเครื่องมืออัตโนมัติที่สามารถจำแนกข้อมูลตามประเภทแนวโน้มการเคลื่อนไหวของราคา แทนที่การใช้ผู้เชี่ยวชาญ ซึ่งผลลัพธ์ของการทดลองแสดงในหัวข้อถัดไป

ตารางที่ 4.5 ผลการทดสอบประสิทธิภาพโมเดลสำหรับทำนายข้อมูลที่มีลักษณะเป็นแนวโน้มแบบขาขึ้นอย่างต่อเนื่อง (LSTM<sub>UP</sub>)

Testing periods	Testing Days																				
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	AVG
January 2019	65.0	69.2	68.3	66.7	65.8	72.5	71.7	69.2	73.3	62.5	69.2	71.7	73.3	70.0	75.0	65.8	64.2	64.2	65.8	68.3	68.6
February 2019	75.8	61.7	65.8	66.7	74.2	62.5	62.5	74.2	65.0	80.8	70.8	72.5	70.8	74.2	60.8	65.8	72.5	62.5	77.5	76.7	69.7
March 2019	66.7	65.0	77.5	75.8	60.0	61.7	70.8	58.3	62.5	73.3	62.5	75.8	75.0	78.3	78.3	67.5	80.0	82.5	71.7	73.3	70.8
April 2019	62.5	71.7	79.2	65.0	71.7	70.0	66.7	57.5	79.2	71.7	65.8	69.2	65.8	62.5	70.8	69.2	68.3	68.3	71.7	72.5	69.0
AVG	67.5	66.9	72.7	68.6	67.9	66.7	67.9	64.8	70.0	72.1	67.1	72.3	71.2	71.3	71.2	67.1	71.3	69.4	71.7	72.7	69.5

ตารางที่ 4.6 ผลการทดสอบประสิทธิภาพโมเดลสำหรับทำนายข้อมูลที่มีลักษณะเป็นแนวโน้มแบบผันผวน (LSTM<sub>SW</sub>)

Testing periods	Testing Days																				
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	AVG
January 2019	75.0	67.5	75.8	79.2	70.8	70.8	68.3	69.2	78.3	68.3	59.2	72.5	59.2	76.7	72.5	60.8	60.8	66.7	75.8	73.3	70.0
February 2019	65.8	74.2	70.8	66.7	60.8	72.5	64.2	71.7	68.3	75.0	75.8	58.3	67.5	66.7	75.8	70.0	69.2	70.0	61.7	65.8	68.5
March 2019	70.0	80.8	78.3	60.8	82.5	82.5	71.7	70.8	60.0	72.5	69.2	63.3	67.5	77.5	71.7	71.7	70.0	75.8	76.7	75.0	72.4
April 2019	73.3	70.0	66.7	70.0	65.0	73.3	65.8	69.2	73.3	66.7	70.0	61.7	72.5	64.2	72.5	65.0	60.8	62.5	68.3	70.0	68.0
AVG	71.0	73.1	72.9	69.2	69.8	74.8	67.5	70.2	70.0	70.6	68.6	64.0	66.7	71.3	73.1	66.9	65.2	68.8	70.6	71.0	69.8




ตารางที่ 4.7 ผลการทดสอบประสิทธิภาพโมเดลสำหรับทำนายข้อมูลที่มีลักษณะเป็นแนวโน้มแบบผันผวน (LSTM<sub>DN</sub>)

Testing periods	Testing Days																				
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	AVG
January 2019	66.7	68.3	65.0	60.0	66.7	70.0	67.5	72.5	77.5	67.5	80.0	70.8	67.5	66.7	76.7	55.0	58.3	75.0	68.3	62.5	<b>68.1</b>
February 2019	78.3	63.3	71.7	66.7	65.0	60.0	70.0	78.3	74.2	69.2	68.3	60.8	65.8	67.5	66.7	67.5	64.2	70.0	73.3	78.3	<b>69.0</b>
March 2019	75.8	73.3	74.2	70.8	74.2	69.2	70.0	78.3	69.2	65.0	70.0	75.0	69.2	<b>80.0</b>	69.2	65.8	65.8	73.3	77.5	70.8	<b>71.8</b>
April 2019	70.8	68.3	72.5	65.8	63.3	71.7	67.5	67.5	74.2	70.0	76.7	64.2	75.0	75.8	69.2	68.3	73.3	75.8	70.8	62.5	<b>70.2</b>
<b>AVG</b>	<b>72.9</b>	<b>68.3</b>	<b>70.9</b>	<b>65.8</b>	<b>67.3</b>	<b>67.7</b>	<b>68.8</b>	<b>74.2</b>	<b>73.8</b>	<b>67.9</b>	<b>73.8</b>	<b>67.7</b>	<b>69.4</b>	<b>72.5</b>	<b>70.5</b>	<b>64.2</b>	<b>65.4</b>	<b>73.5</b>	<b>72.5</b>	<b>68.5</b>	<b>69.8</b>



#### 4.4 การพัฒนาโมเดลสำหรับใช้เป็นเครื่องมืออัตโนมัติในการจำแนกประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนดโดยใช้อัลกอริทึมทางด้านปัญญาประดิษฐ์

ในขั้นตอนนี้ อัลกอริทึมที่ถูกเลือกมาใช้ในการพัฒนาโมเดลสำหรับใช้เป็นเครื่องมืออัตโนมัติในการจำแนกประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนดได้แก่ โครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Network, CNN) โครงข่ายประสาทเทียม (Artificial Neural Network, ANN) และเครื่องเวกเตอร์สนับสนุน (Support Vector Machine, SVM) ซึ่งผลการทดสอบประสิทธิภาพในการจำแนกข้อมูลตามประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนดของโมเดลทั้ง 3 โมเดลแสดงในรูปที่ 4.6



รูปที่ 4.6 ผลการทดสอบประสิทธิภาพโมเดลสำหรับใช้เป็นเครื่องมืออัตโนมัติในการจำแนกประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนดโดยใช้อัลกอริทึมทางด้านปัญญาประดิษฐ์

รูปที่ 4.6 แสดงผลการทดสอบประสิทธิภาพโมเดลสำหรับใช้เป็นเครื่องมืออัตโนมัติในการจำแนกประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนดโดยใช้อัลกอริทึมทางด้านปัญญาประดิษฐ์ จากรูปจะเห็นว่าโมเดลที่ถูกพัฒนาโดยใช้อัลกอริทึมโครงข่ายประสาท

แบบคอนโวลูชัน ( $TCM_{CNN}$ ) มีประสิทธิภาพความแม่นยำในการทำนายสูงสุดที่ 87.8% ตามมาด้วยโมเดลที่ถูกพัฒนาด้วยอัลกอริทึมเครื่องเวกเตอร์สนับสนุน ( $TCM_{SVM}$ ) ซึ่งมีค่าความแม่นยำอยู่ที่ 50.7% และโมเดลที่ถูกพัฒนาด้วยอัลกอริทึมโครงข่ายประสาทเทียม ( $TCM_{ANN}$ ) มีค่าความแม่นยำต่ำสุดที่ 49.9%

#### 4.5 การเปรียบเทียบประสิทธิภาพโมเดลสำหรับการทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไปที่ถูกสร้างขึ้นจากข้อมูลที่ผ่านมาการคัดแยกโดยใช้ ปัญญาประดิษฐ์และหลักการวิเคราะห์ทางเทคนิค

จากผลลัพธ์ในหัวข้อก่อนหน้านี้พบว่าโมเดล  $TCM_{CNN}$  ให้ผลลัพธ์ความแม่นยำในการทำนายสูงสุด ดังนั้นโมเดล  $TCM_{CNN}$  จะถูกใช้ในกระบวนการคัดแยกข้อมูลเพื่อสร้างโมเดลสำหรับการทำนายแนวโน้มความเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาถัดไป และวัดประสิทธิภาพในการทำนายเปรียบเทียบกับโมเดลที่ถูกสร้างโดยใช้หลักการวิเคราะห์ทางเทคนิคคือ ค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนักซับซ้อน (Exponential Moving Average, EMA) ในการคัดแยกข้อมูล ซึ่งโมเดลนี้จะถูกเรียกว่า  $TCM_{EMA}$  ผลลัพธ์การเปรียบเทียบประสิทธิภาพความแม่นยำในการทำนายของโมเดลทั้ง 2 ประเภทนี้โดยใช้มาตรวัดคือ Accuracy แสดงในตารางที่ 4.8 – 4.11

ผลลัพธ์ในตารางที่ 4.8 แสดงผลการเปรียบเทียบประสิทธิภาพความแม่นยำในการทำนายรายวันของโมเดล  $LSTM_{UP} + TCM_{CNN}$  และโมเดล  $LSTM_{UP} + TCM_{EMA}$  จากผลลัพธ์ในตารางสรุปได้ดังนี้

- เดือนมกราคม ค่าเฉลี่ยความแม่นยำในการทำนายรายวันของโมเดล  $LSTM_{UP} + TCM_{CNN}$  (68.4%) มีค่าน้อยกว่าโมเดล  $LSTM_{UP} + TCM_{EMA}$  (68.9%)
- เดือนกุมภาพันธ์ ค่าเฉลี่ยความแม่นยำในการทำนายรายวันของโมเดล  $LSTM_{UP} + TCM_{CNN}$  (70.2%) มีค่ามากกว่าโมเดล  $LSTM_{UP} + TCM_{EMA}$  (67.5%)
- เดือนมีนาคม ค่าเฉลี่ยความแม่นยำในการทำนายรายวันของโมเดล  $LSTM_{UP} + TCM_{CNN}$  (67.8%) มีค่ามากกว่าโมเดล  $LSTM_{UP} + TCM_{EMA}$  (67.7%)
- เดือนเมษายน ค่าเฉลี่ยความแม่นยำในการทำนายรายวันของโมเดล  $LSTM_{UP} + TCM_{CNN}$  (70.1%) มีค่ามากกว่าโมเดล  $LSTM_{UP} + TCM_{EMA}$  (69.4%)

ผลลัพธ์ในตารางที่ 4.9 แสดงผลการเปรียบเทียบประสิทธิภาพความแม่นยำในการทำนายรายวันของโมเดล  $LSTM_{SW} + TCM_{CNN}$  และโมเดล  $LSTM_{UP} + TCM_{EMA}$  จากผลลัพธ์ในตารางสรุปได้ดังนี้

- เดือนมกราคม ค่าเฉลี่ยความแม่นยำในการทำนายรายวันของโมเดล LSTM<sub>SW</sub> + TCM<sub>CNN</sub> (69.5%) มีค่ามากกว่าโมเดล LSTM<sub>SW</sub> + TCM<sub>EMA</sub> (68.5%)
- เดือนกุมภาพันธ์ ค่าเฉลี่ยความแม่นยำในการทำนายรายวันของโมเดล LSTM<sub>SW</sub> + TCM<sub>CNN</sub> (68.6%) มีค่าน้อยกว่าโมเดล LSTM<sub>SW</sub> + TCM<sub>EMA</sub> (68.8%)
- เดือนมีนาคม ค่าเฉลี่ยความแม่นยำในการทำนายรายวันของโมเดล LSTM<sub>SW</sub> + TCM<sub>CNN</sub> (69.4%) มีค่าน้อยกว่าโมเดล LSTM<sub>SW</sub> + TCM<sub>EMA</sub> (69.5%)
- เดือนเมษายน ค่าเฉลี่ยความแม่นยำในการทำนายรายวันของโมเดล LSTM<sub>SW</sub> + TCM<sub>CNN</sub> (70.0%) มีค่ามากกว่าโมเดล LSTM<sub>SW</sub> + TCM<sub>EMA</sub> (69.1%)

ผลลัพธ์ในตารางที่ 4.10 แสดงผลการเปรียบเทียบประสิทธิภาพความแม่นยำในการทำนายรายวันของโมเดล LSTM<sub>DN</sub> + TCM<sub>CNN</sub> และโมเดล LSTM<sub>DN</sub> + TCM<sub>EMA</sub> จากผลลัพธ์ในตารางสรุปได้ดังนี้

- เดือนมกราคม ค่าเฉลี่ยความแม่นยำในการทำนายรายวันของโมเดล LSTM<sub>DN</sub> + TCM<sub>CNN</sub> (67.9%) มีค่ามากกว่าโมเดล LSTM<sub>DN</sub> + TCM<sub>EMA</sub> (67.4%)
- เดือนกุมภาพันธ์ ค่าเฉลี่ยความแม่นยำในการทำนายรายวันของโมเดล LSTM<sub>DN</sub> + TCM<sub>CNN</sub> (69.2%) มีค่าน้อยกว่าโมเดล LSTM<sub>DN</sub> + TCM<sub>EMA</sub> (69.5%)
- เดือนมีนาคม ค่าเฉลี่ยความแม่นยำในการทำนายรายวันของโมเดล LSTM<sub>DN</sub> + TCM<sub>CNN</sub> (69.3%) มีค่ามากกว่าโมเดล LSTM<sub>DN</sub> + TCM<sub>EMA</sub> (67.6%)
- เดือนเมษายน ค่าเฉลี่ยความแม่นยำในการทำนายรายวันของโมเดล LSTM<sub>DN</sub> + TCM<sub>CNN</sub> (71.3%) มีค่ามากกว่าโมเดล LSTM<sub>DN</sub> + TCM<sub>EMA</sub> (67.3%)

ตารางที่ 4.11 ผลลัพธ์การเปรียบเทียบประสิทธิภาพในการทำนายรายเดือนของโมเดล LSTM ที่ใช้ข้อมูลในการเรียนรู้จากการจำแนกของ TCM<sub>CNN</sub> และ TCM<sub>EMA</sub> จากผลลัพธ์ในตารางพบว่า

- โมเดล LSTM<sub>UP</sub> + TCM<sub>CNN</sub> มีความแม่นยำในการทำนายมากกว่าโมเดล LSTM<sub>UP</sub> + TCM<sub>EMA</sub> ในเดือนกุมภาพันธ์ มีนาคม และเมษายน ในขณะที่เดือนมกราคม โมเดล LSTM<sub>UP</sub> + TCM<sub>EMA</sub> มีความแม่นยำในการทำนายมากกว่าโมเดล LSTM<sub>UP</sub> + TCM<sub>CNN</sub>
- โมเดล LSTM<sub>SW</sub> + TCM<sub>CNN</sub> มีความแม่นยำในการทำนายมากกว่าโมเดล LSTM<sub>SW</sub> + TCM<sub>EMA</sub> ในเดือนมกราคมและเมษายน ในขณะที่เดือนกุมภาพันธ์และ มีนาคม โมเดล LSTM<sub>SW</sub> + TCM<sub>EMA</sub> มีความแม่นยำในการทำนายมากกว่าโมเดล LSTM<sub>SW</sub> + TCM<sub>CNN</sub>

- โมเดล LSTM<sub>DN</sub> + TCM<sub>CNN</sub> มีความแม่นยำในการทำนายมากกว่าโมเดล LSTM<sub>DN</sub> + TCM<sub>EMA</sub> ในเดือนมกราคม มีนาคมและเมษายน ในขณะที่เดือนกุมภาพันธ์โมเดล LSTM<sub>DN</sub> + TCM<sub>EMA</sub> มีความแม่นยำในการทำนายมากกว่าโมเดล LSTM<sub>DN</sub> + TCM<sub>CNN</sub>

เมื่อพิจารณาที่ค่าเฉลี่ยความแม่นยำในการทำนายจากข้อมูลทั้ง 4 เดือน ดังแสดงในตารางที่ 4.11 พบว่าโมเดล LSTM ที่ใช้ข้อมูลในการเรียนรู้ที่ได้จากการจำแนกโดยใช้โมเดล TCM<sub>CNN</sub> มีประสิทธิภาพในการทำนายมากกว่าโมเดล LSTM ที่ใช้ข้อมูลในการเรียนรู้ที่ได้จากการจำแนกโดยใช้ TCM<sub>EMA</sub> จากผลการทดลองนี้สามารถสรุปได้ว่า โมเดลที่เหมาะสมที่สุดที่จะใช้เป็นเครื่องมือในการทำนายทิศทางราคาเคลื่อนไหวของราคาอ้างอิงในคาบเวลาถัดไปเพื่อกำหนดทิศทางในการซื้อขายตัวเลือกไบนารีคือ โมเดล LSTM ที่ใช้ข้อมูลในการเรียนรู้ที่ได้จากการจำแนกโดยใช้โมเดล TCM<sub>CNN</sub> ดังนั้นโมเดล LSTM<sub>UP</sub> + TCM<sub>CNN</sub> โมเดล LSTM<sub>SW</sub> + TCM<sub>CNN</sub> และโมเดล LSTM<sub>DN</sub> + TCM<sub>CNN</sub> จะถูกนำไปใช้ต่อไปในขั้นตอนการวัดประสิทธิภาพด้านการเงินของโมเดลในการซื้อขายตัวเลือกไบนารี

ตารางที่ 4.8 ผลลัพธ์การเปรียบเทียบประสิทธิภาพความแม่นยำในการทำนายรายวันของโมเดล LSTM<sub>UP</sub> + TCM<sub>CNN</sub> และโมเดล LSTM<sub>UP</sub> + TCM<sub>EMA</sub>

Testing periods	Models	Testing Days																				
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	AVG
Jan-19	LSTM <sub>UP</sub> + TCM <sub>CNN</sub>	68.3	63.3	71.7	71.7	73.3	65.8	70.0	68.3	68.3	61.7	70.0	70.0	69.2	65.0	67.5	67.5	67.5	66.7	69.2	72.5	68.4
	LSTM <sub>UP</sub> + TCM <sub>EMA</sub>	73.3	71.7	68.3	73.3	69.2	74.2	68.3	63.3	66.7	65.8	75.8	65.0	65.8	66.7	70.0	64.2	61.7	73.3	72.5	69.2	68.9
	LSTM <sub>UP</sub> + TCM <sub>CNN</sub>	69.2	75.0	65.8	73.3	68.3	65.8	70.8	71.7	71.7	65.0	69.2	64.2	75.0	65.8	70.8	75.0	76.7	70.8	71.7	68.3	70.2
	LSTM <sub>UP</sub> + TCM <sub>EMA</sub>	70.0	65.8	72.5	65.0	61.7	71.7	63.3	74.2	60.8	67.5	65.0	77.5	64.2	70.8	70.0	65.0	68.3	66.7	70.8	59.2	67.5
Mar-19	LSTM <sub>UP</sub> + TCM <sub>CNN</sub>	69.2	65.0	68.3	70.0	60.0	60.0	64.2	66.7	67.5	71.7	75.0	66.7	69.2	60.0	69.2	70.0	73.3	69.2	67.5	72.5	67.8
	LSTM <sub>UP</sub> + TCM <sub>EMA</sub>	65.0	74.2	70.8	68.3	66.7	64.2	69.2	70.0	65.8	70.8	70.0	63.3	68.3	67.5	65.8	61.7	68.3	67.5	63.3	72.5	67.7
	LSTM <sub>UP</sub> + TCM <sub>CNN</sub>	68.3	77.5	73.3	70.0	71.7	68.3	72.5	63.3	76.7	72.5	66.7	65.8	69.2	60.0	70.8	73.3	68.3	73.3	70.0	70.0	70.1
	LSTM <sub>UP</sub> + TCM <sub>EMA</sub>	65.0	70.0	68.3	65.8	77.5	73.3	68.3	70.0	71.7	72.5	70.0	68.3	67.5	75.0	68.3	65.0	74.2	60.0	69.2	68.3	69.4

ตารางที่ 4.9 ผลลัพธ์การเปรียบเทียบประสิทธิภาพในการทำนายรายวันของโมเดล LSTM<sub>SW</sub> + TCM<sub>CNN</sub> และโมเดล LSTM<sub>SW</sub> + TCM<sub>EMA</sub>

Testing periods	Models	Testing Days																				
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	AVG
Jan-19	LSTM <sub>SW</sub> + TCM <sub>AI</sub>	69.2	72.5	71.7	67.5	62.5	66.7	71.7	69.2	70.0	72.5	78.3	60.8	73.3	69.2	71.7	69.2	69.2	70.0	75.0	67.5	69.9
	LSTM <sub>SW</sub> + TCM <sub>EMA</sub>	68.3	64.2	60.8	73.3	74.2	70.8	69.2	65.0	66.7	66.7	67.5	72.5	61.7	70.0	70.0	73.3	76.7	68.3	63.3	68.3	68.5
Feb-19	LSTM <sub>SW</sub> + TCM <sub>AI</sub>	69.2	66.7	71.7	72.5	72.5	68.3	65.8	73.3	70.8	60.8	73.3	64.2	65.0	68.3	70.0	70.8	65.8	66.7	66.7	69.2	68.6
	LSTM <sub>SW</sub> + TCM <sub>EMA</sub>	63.3	70.8	65.0	64.2	69.2	66.7	66.7	70.0	70.8	65.8	72.5	61.7	68.3	79.2	59.2	72.5	69.2	72.5	68.3	74.2	68.8
Mar-19	LSTM <sub>SW</sub> + TCM <sub>AI</sub>	77.5	66.7	72.5	69.2	66.7	71.7	63.3	66.7	70.8	65.8	72.5	77.5	74.2	65.8	65.0	62.5	61.7	66.7	77.5	74.2	69.4
	LSTM <sub>SW</sub> + TCM <sub>EMA</sub>	70.8	70.0	75.8	70.0	64.2	70.0	70.8	71.7	71.7	74.2	60.8	65.0	70.0	65.0	70.8	69.2	70.0	70.8	68.3	70.0	69.5
Apr-19	LSTM <sub>SW</sub> + TCM <sub>AI</sub>	65.0	70.8	70.0	70.8	70.8	76.7	71.7	65.0	73.3	74.2	67.5	64.2	72.5	73.3	68.3	66.7	68.3	69.2	66.7	75.0	70.0
	LSTM <sub>SW</sub> + TCM <sub>EMA</sub>	65.8	74.2	67.5	68.3	66.7	69.2	65.0	62.5	72.5	68.3	67.5	64.2	70.0	67.5	65.0	74.2	71.7	71.7	74.2	75.0	69.1

ตารางที่ 4.10 ผลลัพธ์การเปรียบเทียบประสิทธิภาพในการทำนายรายวันของโมเดล LSTM<sub>DN</sub> + TCM<sub>CNN</sub> และโมเดล LSTM<sub>DN</sub> + TCM<sub>EMA</sub>

Testing periods	Models	Testing Days																			AVG	
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19		20
Jan-19	LSTM <sub>DN</sub> + TCM <sub>AI</sub>	65.0	66.7	68.3	68.3	70.8	71.7	63.3	68.3	65.8	70.8	62.5	67.5	70.0	63.3	70.0	75.0	56.7	73.3	67.5	72.5	67.9
	LSTM <sub>DN</sub> + TCM <sub>EMA</sub>	75.8	69.2	68.3	66.7	67.5	65.8	70.0	62.5	70.0	65.8	70.8	69.2	60.0	71.7	61.7	67.5	67.5	67.5	65.8	64.2	67.4
Feb-19	LSTM <sub>DN</sub> + TCM <sub>AI</sub>	66.7	71.7	72.5	69.2	73.3	64.2	75.8	68.3	73.3	66.7	65.8	65.8	77.5	70.0	67.5	71.7	65.0	67.5	60.8	70.8	69.2
	LSTM <sub>DN</sub> + TCM <sub>EMA</sub>	68.3	74.2	69.2	75.0	63.3	68.3	62.5	70.0	69.2	68.3	68.3	72.5	75.8	70.0	70.0	73.3	69.2	71.7	68.3	65.0	69.5
Mar-19	LSTM <sub>DN</sub> + TCM <sub>AI</sub>	64.2	70.0	73.3	65.8	64.2	68.3	73.3	70.0	72.5	72.5	70.8	65.8	65.8	69.2	72.5	74.2	67.5	71.7	67.5	66.7	69.3
	LSTM <sub>DN</sub> + TCM <sub>EMA</sub>	66.7	70.8	71.7	65.8	64.2	70.8	64.2	64.2	65.0	66.7	60.8	66.7	67.5	70.8	68.3	74.2	68.3	69.2	65.8	70.8	67.6
Apr-19	LSTM <sub>DN</sub> + TCM <sub>AI</sub>	66.7	73.3	70.0	72.5	65.0	72.5	70.0	74.2	70.8	70.8	68.3	70.0	70.0	75.0	75.0	68.3	69.2	70.0	79.2	74.2	71.3
	LSTM <sub>DN</sub> + TCM <sub>EMA</sub>	66.7	64.2	64.2	70.8	65.8	79.2	66.7	61.7	70.8	62.5	70.0	70.0	65.8	74.2	67.5	61.7	65.0	70.0	63.3	66.7	67.3



ตารางที่ 4.11 ผลลัพธ์การเปรียบเทียบประสิทธิภาพในการทำนายรายเดือนของโมเดล LSTM ที่ใช้ข้อมูลในการเรียนรู้จากการจำแนกของ  $TCM_{CNN}$  และ  $TCM_{EMA}$

	January	February	March	April	Average
$LSTM_{UP} + TCM_{CNN}$	68.4	<b>70.2</b>	<b>67.8</b>	<b>70.1</b>	<b>69.1</b>
$LSTM_{UP} + TCM_{EMA}$	<b>68.9</b>	67.5	67.7	69.4	68.4
$LSTM_{SW} + TCM_{CNN}$	<b>69.9</b>	68.6	69.4	<b>70</b>	<b>69.5</b>
$LSTM_{SW} + TCM_{EMA}$	68.5	<b>68.8</b>	<b>69.5</b>	69.1	69.0
$LSTM_{DN} + TCM_{CNN}$	<b>67.9</b>	69.2	<b>69.3</b>	<b>71.3</b>	<b>69.4</b>
$LSTM_{DN} + TCM_{EMA}$	67.4	<b>69.5</b>	67.6	67.3	68.0

#### 4.6 ผลการวัดประสิทธิภาพด้านการเงินในการซื้อขายตัวเลือกไบนารี

สิ่งที่สำคัญที่สุดและเป็นเป้าหมายหลักของงานวิจัยนี้คือการที่เครื่องมือและกลยุทธ์ต่าง ๆ ที่ได้นำเสนอในงานวิจัยนี้สามารถใช้เพื่อสร้างผลกำไรให้กับนักลงทุนในการซื้อขายตัวเลือกไบนารีได้ ดังนั้นในขั้นตอนสุดท้ายของงานวิจัยคือ การนำโมเดล  $LSTM_{UP}$ ,  $LSTM_{SW}$ ,  $LSTM_{DN}$  และโมเดล  $TCM_{CNN}$  รวมทั้งกลยุทธ์ในการเทรดและกลยุทธ์ในการตัดขาดทุนมาทดสอบประสิทธิภาพในการซื้อขายตัวเลือกไบนารี โดยกระบวนการวัดประสิทธิภาพนั้นจะแบ่งเป็น 2 ขั้นตอนคือ การทดสอบแบบย้อนกลับ และการทดสอบแบบไปข้างหน้า (รายละเอียดอธิบายไว้ในหัวข้อที่ 3.2.5) ซึ่งผลการทดสอบทั้ง 2 ขั้นตอนอธิบายในหัวข้อที่ 4.6.1 และ 4.6.2

##### 4.6.1 ผลการทดสอบแบบย้อนกลับ

กระบวนการทดสอบแบบย้อนกลับเป็นการวัดประสิทธิภาพในการทำกำไรของเครื่องมือและกลยุทธ์ต่าง ๆ ซึ่งเป็นกระบวนการที่นักลงทุนส่วนใหญ่นิยมทำเพื่อประเมินว่าสามารถใช้เครื่องมือและกลยุทธ์ที่คิดค้นขึ้นมานั้นไปใช้ทำกำไรในการเทรดในสภาวะแวดล้อมจริงได้หรือไม่ โดยกระบวนการทดสอบย้อนกลับนั้น จะเป็นการจำลองการเทรดจากข้อมูลย้อนหลัง ในงานวิจัยนี้ได้ใช้ข้อมูลย้อนหลังของราคาอ้างอิงของการซื้อขายและเปลี่ยนแปลงเงินตราต่างประเทศคู่เงิน EURUSD คาบเวลาราย 5 นาที ตั้งแต่วันที่ 2 มกราคม พ.ศ. 2562 จนถึงวันที่ 30 เมษายน พ.ศ. 2562 มาใช้ทดสอบ โดยมีการกำหนดเงื่อนไขในการเทรดดังนี้

- 1) จำนวนเงินลงทุนเริ่มแรกเท่ากับ 500 ดอลลาร์
- 2) คู่เงินที่ใช้เทรดคือ EURUSD

- 3) คาบเวลาที่ใช้เทรดคือ ราย 5 นาที
- 4) ในหนึ่งวันจะเริ่มเทรดตั้งแต่เวลา 13.00 น. จนถึงเวลา 23.00 น. (120 ครั้งต่อวัน)
- 5) จำนวนเงินที่จะลงทุนในแต่ละรอบการเทรดและการคำนวณกำไรหรือขาดทุน ใช้ข้อมูลดังแสดงในตารางที่ 3.1
- 6) ตัดขาดทุนเมื่อเทรดแพ้ติดต่อกันจำนวน 6 ครั้ง

การจำลองการเทรดจะแบ่งเป็น 4 ครั้ง ๆ ละ 1 เดือน การวัดผลในการจำลองการเทรดแต่ละเดือนจะวัดด้วยมาตรวัดคือ Confusion Matrix, Accuracy, Precision, Recall, F-Measure, จำนวนครั้งของการเทรดชนะในแต่ละรอบที่มีการเพิ่มเงินลงทุน สรุปผลกำไรหรือขาดทุนในแต่ละวัน และผลสรุปกำไรหรือขาดทุนประจำเดือน จากการทดลองได้ผลลัพธ์ดังรูปที่ 4.7

ผลการจำลองการเทรดเดือน มกราคม พ.ศ. 2562

**Confusion Matrix**

<b>Output Class</b>	Down (0)	924	402
	Up (1)	398	916
		Down (0)	Up (1)
		<b>Target Class</b>	

รูปที่ 4.7 Confusion Matrix แสดงผลการทดสอบแบบย้อนกลับในเดือน มกราคม พ.ศ. 2562

รูปที่ 4.7 แสดงตาราง Confusion Matrix ซึ่งบ่งบอกถึงผลลัพธ์ที่โมเดลทำนายจากข้อมูลที่ใช้ทดสอบทั้งสิ้นจำนวน 2,640 ข้อมูล โมเดลได้ทำนายได้ถูกต้องจำนวน 1,840 ข้อมูล แบ่งเป็นทำนายถูกต้องสำหรับข้อมูลแนวโน้มการของราคาอ้างอิงแบบขาขึ้นจำนวน 916 ข้อมูล และแบบขาลงจำนวน 924 ข้อมูล ค่าในตาราง Confusion Matrix จะถูกนำไปคิดเป็นค่าความแม่นยำในการทำนายดังแสดงในตารางที่ 4.12

ตารางที่ 4.12 สรุปผลการทดสอบประสิทธิภาพโมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไปโดยใช้ค่าจากมาตรวัดต่าง ๆ ในเดือน มกราคม พ.ศ. 2562

Class	Accuracy (%)	Precision (%)	Recall (%)	F-Measure (%)
Up (1)	69.7	69.7	69.9	69.8
Down (0)		69.7	69.5	69.6
<i>Average</i>		69.7	69.7	69.7

ตารางที่ 4.12 แสดงผลลัพธ์ในด้านความแม่นยำในการทำนายของโมเดล ซึ่งโมเดลมีความแม่นยำโดยรวม (Accuracy) อยู่ที่ 69.7% นอกจากนี้จะเห็นว่าเมื่อสนใจเฉพาะส่วนที่ทำนายโมเดลสามารถทำนายคลาส Up ได้ดีเท่ากับคลาส Up (ค่า Precision ของ Down สูงที่สุดเป็น 69.7%) และเมื่อดูความครอบคลุมของการทำนายข้อมูลพบว่า โมเดลสามารถทำนายคลาส Up ได้ดีที่สุด (ค่า Recall ของ Up เป็น 69.9%)


ตารางที่ 4.13 จำนวนครั้งที่เทรดชนะ ณ คำสั่งซื้อต่าง ๆ และจำนวนครั้งของการตัดขาดทุนของการจำลองการเทรดในเดือน มกราคม พ.ศ. 2562

Win at trading order	Total wins
1	1,386
2	279
3	127
4	28
5	16
6 (Cut Loss)	4

ตารางที่ 4.13 แสดงจำนวนครั้งที่โมเดลทำนายได้ถูกต้องและชนะการเทรด ณ คำสั่งซื้อลำดับต่าง ๆ ในการจำลองการเทรดของเดือน มกราคม พ.ศ. 2562 จากผลลัพธ์ในตารางที่ 4.13 พบว่าโมเดลทำนายได้ถูกต้องในคำสั่งซื้อครั้งแรกจำนวน 1,386 ครั้ง ในขณะที่โมเดลทำนายผิดพลาดต่อกันถึง 6 ครั้งทำให้ต้องทำการตัดขาดทุนเป็นจำนวนทั้งหมด 4 ครั้ง ซึ่งผลสรุปกำไรขาดทุนแต่ละวันของการทดสอบแบบย้อนกลับในเดือนนี้แสดงในตารางที่ 4.14 และรูปที่ 4.8

ตารางที่ 4.14 สรุปผลกำไร/ขาดทุนแต่ละวันของการทดสอบแบบย้อนกลับในเดือน มกราคม พ.ศ. 2562

Date	Profit/Loss (\$)	Equity (\$)	Date	Profit/Loss (\$)	Equity (\$)
2 January 2019	81.2	581.2	17 January 2019	87.2	1,363.6
3 January 2019	81.6	662.8	18 January 2019	83.8	1,447.4
4 January 2019	17.0	679.8	21 January 2019	81.6	1,529.0
7 January 2019	86.0	765.8	22 January 2019	80.4	1,609.4
8 January 2019	14.6	780.4	23 January 2019	85.2	1,694.6
9 January 2019	79.2	859.6	24 January 2019	85.6	1,780.2
10 January 2019	90.0	949.6	25 January 2019	12.2	1,792.4
11 January 2019	85.0	1,034.6	28 January 2019	83.8	1,876.2
14 January 2019	80.8	1,115.4	29 January 2019	87.0	1,963.2
15 January 2019	81.2	1,196.6	30 January 2019	76.2	2,039.4
16 January 2019	79.8	1,276.4	31 January 2019	19.0	2,058.4
			<b>Total</b>	<b>1,558.4</b>	



รูปที่ 4.8 กราฟแสดงจำนวนเงินคงเหลือจากการทดสอบแบบย้อนกลับแต่ละวันในเดือน มกราคม พ.ศ. 2562

จากผลลัพธ์ที่แสดงในตารางที่ 4.14 และรูปที่ 4.8 สรุปได้ว่าเครื่องมือและกลยุทธ์ที่ใช้ในการเทรดและการตัดขาดทุนที่ได้นำเสนอในงานวิจัยนี้ สามารถสร้างผลกำไรได้อย่างต่อเนื่อง โดยวันที่สามารถทำกำไรได้มากที่สุดคือวันที่ 10 มกราคม พ.ศ. 2562 ซึ่งทำกำไรได้ถึง 90 ดอลลาร์ จากผลการเทรดตลอดทั้งเดือนมกราคมพบว่า เครื่องมือและกลยุทธ์ที่ใช้ในการเทรดและการตัดขาดทุนที่ได้นำเสนอ สามารถทำให้เงินลงทุนเพิ่มขึ้นจาก 500 ดอลลาร์ไปเป็น 2,058.4 ดอลลาร์ คิดเป็นกำไรทั้งสิ้น 1,558.4 ดอลลาร์

#### ผลการจำลองการเทรดเดือน กุมภาพันธ์ พ.ศ. 2562

**Confusion Matrix**

<b>Output Class</b>	Down (0)	878	379
	Up (1)	334	809
		Down (0)	Up (1)
		<b>Target Class</b>	

รูปที่ 4.9 Confusion Matrix แสดงผลการทดสอบแบบย้อนกลับในเดือน กุมภาพันธ์ พ.ศ. 2562

รูปที่ 4.9 แสดงตาราง Confusion Matrix ซึ่งบ่งบอกถึงผลลัพธ์ที่โมเดลทำนาย จากข้อมูลที่ใช้ทดสอบทั้งสิ้นจำนวน 2,400 ข้อมูลนั้น โมเดลได้ทำนายได้ถูกต้องจำนวน 1,687 ข้อมูล แบ่งเป็นทำนายถูกต้องสำหรับข้อมูลแนวโน้มการของราคาอ้างอิงแบบขาขึ้นจำนวน 809 ข้อมูล และแบบขาลงจำนวน 878 ข้อมูล ค่าในตาราง Confusion Matrix จะถูกนำไปคิดเป็นค่าความแม่นยำในการทำนายดังแสดงในตารางที่ 4.15

ตารางที่ 4.15 สรุปผลการทดสอบประสิทธิภาพโมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไปโดยใช้ค่าจากมาตรวัดต่าง ๆ ในเดือน กุมภาพันธ์ พ.ศ. 2562

Class	Accuracy (%)	Precision (%)	Recall (%)	F-Measure (%)
Up (1)	70.3	69.8	72.4	71.1
Down (0)		70.8	68.1	69.4
<i>Average</i>		70.3	70.3	70.3

ตารางที่ 4.15 แสดงผลลัพธ์ในด้านความแม่นยำในการทำนายของโมเดล ซึ่งโมเดลมีความแม่นยำโดยรวม (Accuracy) อยู่ที่ 70.3% นอกจากนี้จะเห็นว่าเมื่อสนใจเฉพาะส่วนที่ทำนายโมเดลสามารถทำนายคลาส Down ได้ดีกว่าคลาส Up (ค่า Precision ของ Down สูงที่สุดเป็น 70.8%) และเมื่อดูความครอบคลุมของการทำนายข้อมูลพบว่า โมเดลสามารถทำนายคลาส Down ได้ดีที่สุด (ค่า Recall ของ Up เป็น 72.4%)


ตารางที่ 4.16 จำนวนครั้งที่เทรดชนะ ณ คำสั่งซื้อต่าง ๆ และจำนวนครั้งของการตัดขาดทุนของการจำลองการเทรดในเดือน กุมภาพันธ์ พ.ศ. 2562

Win at trading order	Total wins
1	1,295
2	225
3	112
4	39
5	9
6 (Cut Loss)	7

ตารางที่ 4.16 แสดงจำนวนครั้งที่เทรดชนะ ณ คำสั่งซื้อต่าง ๆ และจำนวนครั้งของการตัดขาดทุนของการจำลองการเทรดในเดือน กุมภาพันธ์ พ.ศ. 2562 จากการลัพธ์ในตารางที่ 4.16 พบว่าโมเดลทำนายได้ถูกต้องในคำสั่งซื้อครั้งแรกจำนวน 1,295 ครั้ง ในขณะที่โมเดลทำนายผิดพลาดต่อกันถึง 6 ครั้งทำให้ต้องทำการตัดขาดทุนเป็นจำนวนทั้งหมด 7 ครั้ง ซึ่งผลสรุปกำไรขาดทุนแต่ละวันของการทดสอบแบบย้อนกลับในเดือนนี้แสดงในตารางที่ 4.17 และรูปที่ 4.10

ตารางที่ 4.17 สรุปผลลัพธ์กำไรขาดทุนแต่ละวันของการทดสอบแบบย้อนกลับในเดือน กุมภาพันธ์ พ.ศ. 2562

Date	Profit/Loss (\$)	Equity (\$)	Date	Profit/Loss (\$)	Equity (\$)
1 February 2019	11.8	511.8	15 February 2019	44.2	1,207.2
4 February 2019	13.2	525.0	18 February 2019	-45.8	1,161.4
5 February 2019	73.0	598.0	19 February 2019	85.4	1,246.8
6 February 2019	93.8	691.8	20 February 2019	88.6	1,335.4
7 February 2019	83.8	775.6	21 February 2019	-55.8	1,279.6
8 February 2019	85.0	860.6	22 February 2019	80.4	1,360.0
11 February 2019	82.0	942.6	25 February 2019	84.2	1,444.2
12 February 2019	81.4	1,024.0	26 February 2019	80.8	1,525.0
13 February 2019	83.4	1,107.4	27 February 2019	82.8	1,607.8
14 February 2019	55.6	1,163.0	28 February 2019	71.6	1,679.4
			<b>Total</b>	<b>1,179.4</b>	



รูปที่ 4.10 กราฟแสดงจำนวนเงินคงเหลือจากการทดสอบแบบย้อนกลับแต่ละวัน ในเดือน กุมภาพันธ์ พ.ศ. 2562

จากผลลัพธ์ที่แสดงในตารางที่ 4.17 และรูปที่ 4.10 สรุปได้ว่าเครื่องมือและกลยุทธ์ที่ใช้ในการเทรดและการตัดขาดทุนที่ได้นำเสนอในงานวิจัยนี้ สามารถสร้างผลกำไรได้อย่างต่อเนื่อง โดยวันที่สามารถทำกำไรได้มากที่สุดคือวันที่ 6 ของเดือนซึ่งทำกำไรได้ถึง 93.8 ดอลลาร์ ในขณะที่มีการเทรดขาดทุนในวันที่ 15 และ 21 ของเดือนเป็นจำนวนเงิน -45.8 และ -55.8 ดอลลาร์ตามลำดับ จากผลการเทรดตลอดทั้งเดือนกุมภาพันธ์พบว่า เครื่องมือและกลยุทธ์ที่ใช้ในการเทรดและการตัดขาดทุนที่ได้นำเสนอ สามารถทำให้เงินลงทุนเพิ่มขึ้นจาก 500 ดอลลาร์ไปเป็น 1,679.4 ดอลลาร์ คิดเป็นกำไรทั้งสิ้น 1,179.4 ดอลลาร์

#### ผลการจำลองการเทรดเดือน มกราคม พ.ศ. 2562

**Confusion Matrix**

<b>Output Class</b>	Down (0)	900	416
	Up (1)	384	820
		Down (0)	Up (1)
		<b>Target Class</b>	

รูปที่ 4.11 Confusion Matrix แสดงผลการทดสอบแบบย้อนกลับในเดือน มีนาคม พ.ศ. 2562

รูปที่ 4.11 แสดงตาราง Confusion Matrix ซึ่งบ่งบอกถึงผลลัพธ์ที่โมเดลทำนาย จากข้อมูลที่ใช้ทดสอบทั้งสิ้นจำนวน 2,520 ข้อมูลนั้น โมเดลได้ทำนายได้ถูกต้องจำนวน 1,720 ข้อมูล แบ่งเป็นทำนายถูกต้องสำหรับข้อมูลแนวโน้มการของราคาอ้างอิงแบบขาขึ้นจำนวน 820 ข้อมูล และแบบขาลงจำนวน 900 ข้อมูล ค่าในตาราง Confusion Matrix จะถูกนำไปคิดเป็นค่าความแม่นยำในการทำนายดังแสดงในตารางที่ 4.18



ตารางที่ 4.18 สรุปผลการทดสอบประสิทธิภาพโมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไปโดยใช้ค่าจากมาตรวัดต่าง ๆ ในเดือน มีนาคม พ.ศ. 2562

Class	Accuracy (%)	Precision (%)	Recall (%)	F-Measure (%)
Up (1)	68.3	68.4	70.1	69.2
Down (0)		68.1	66.3	67.2
<i>Average</i>		68.2	68.2	68.2

ตารางที่ 4.18 แสดงผลลัพธ์ในด้านความแม่นยำในการทำนายของโมเดล ซึ่งโมเดลมีความแม่นยำโดยรวม (Accuracy) อยู่ที่ 68.3% นอกจากนี้จะเห็นว่าเมื่อสนใจเฉพาะส่วนที่ทำนายโมเดลสามารถทำนายคลาส Down ได้ดีกว่าคลาส Up (ค่า Precision ของ Up สูงที่สุดเป็น 68.4%) และเมื่อดูความครอบคลุมของการทำนายข้อมูลพบว่า โมเดลสามารถทำนายคลาส Up ได้ดีที่สุด (ค่า Recall ของ Up เป็น 70.1%)


ตารางที่ 4.19 จำนวนครั้งที่เทรดชนะ ณ คำสั่งซื้อต่าง ๆ และจำนวนครั้งของการตัดขาดทุนของการจำลองการเทรดในเดือน มีนาคม พ.ศ. 2562

Win at trading order	Total wins
1	1,298
2	235
3	134
4	29
5	15
6 (Cut Loss)	9

ตารางที่ 4.19 แสดงจำนวนครั้งที่เทรดชนะ ณ คำสั่งซื้อต่าง ๆ และจำนวนครั้งของการตัดขาดทุนของการจำลองการเทรดในเดือน มีนาคม พ.ศ. 2562 จากผลลัพธ์ในตารางที่ 4.19 พบว่าโมเดลทำนายได้ถูกต้องในคำสั่งซื้อครั้งแรกจำนวน 1,298 ครั้ง ในขณะที่โมเดลทำนายผิดพลาดต่อกันถึง 6 ครั้งทำให้ต้องทำการตัดขาดทุนเป็นจำนวนทั้งหมด 9 ครั้ง ซึ่งผลสรุปกำไรขาดทุนแต่ละวันของการทดสอบแบบย้อนกลับในเดือนนี้แสดงในตารางที่ 4.20 และรูปที่ 4.12

ตารางที่ 4.20 สรุปผลลัพธ์กำไรขาดทุนแต่ละวันของการทดสอบแบบย้อนกลับในเดือน มีนาคม พ.ศ. 2562

Date	Profit/Loss (\$)	Equity (\$)	Date	Profit/Loss (\$)	Equity (\$)
1 March 2019	78.0	578.0	18 March 2019	83.0	1,359.8
4 March 2019	20.8	598.8	19 March 2019	81.4	1,441.2
5 March 2019	81.4	680.2	20 March 2019	82.6	1,523.8
6 March 2019	87.2	767.4	21 March 2019	13.0	1,536.8
7 March 2019	86.0	853.4	22 March 2019	81.0	1,617.8
8 March 2019	81.6	935.0	25 March 2019	15.6	1,633.4
11 March 2019	86.8	1,021.8	26 March 2019	-120.8	1,512.6
12 March 2019	76.6	1,098.4	27 March 2019	10.6	1,523.2
13 March 2019	82.6	1,181.0	28 March 2019	80.2	1,603.4
14 March 2019	84.4	1,265.4	29 March 2019	14.6	1,618.0
15 March 2019	11.4	1,276.8	<b>Total</b>	<b>1,118.0</b>	



รูปที่ 4.12 กราฟแสดงจำนวนเงินคงเหลือจากการทดสอบแบบย้อนกลับแต่ละวันในเดือน มีนาคม พ.ศ. 2562

จากผลลัพธ์ที่แสดงในตารางที่ 4.20 และรูปที่ 4.12 สรุปได้ว่าเครื่องมือและกลยุทธ์ที่ใช้ในการเทรดและการตัดขาดทุนที่ได้นำเสนอในงานวิจัยนี้ สามารถสร้างผลกำไรได้อย่างต่อเนื่อง โดยวันที่สามารถทำกำไรได้มากที่สุดคือวันที่ 6 ของเดือนซึ่งทำกำไรได้ถึง 87.2 ดอลลาร์ ในขณะที่มีการเทรดขาดทุนในวันที่ 26 ของเดือนเป็นจำนวนเงิน -120.8 ดอลลาร์ จากผลการเทรดตลอดทั้งเดือนกุมภาพันธ์พบว่า เครื่องมือและกลยุทธ์ที่ใช้ในการเทรดและการตัดขาดทุนที่ได้นำเสนอ สามารถทำให้เงินลงทุนเพิ่มขึ้นจาก 500 ดอลลาร์ไปเป็น 1,618.0 ดอลลาร์ คิดเป็นกำไรทั้งสิ้น 1,118.0 ดอลลาร์

#### ผลการจำลองการเทรดเดือน มกราคม พ.ศ. 2562

**Confusion Matrix**

<b>Output Class</b>	Down (0)	933	438
	Up (1)	405	864
		Down (0)	Up (1)
		<b>Target Class</b>	

รูปที่ 4.13 Confusion Matrix แสดงผลการเทรดในเดือน เมษายน พ.ศ. 2562

รูปที่ 4.13 แสดงตาราง Confusion Matrix ซึ่งบ่งบอกถึงผลลัพธ์ที่โมเดลทำนาย จากข้อมูลที่ใช้ทดสอบทั้งสิ้นจำนวน 2,640 ข้อมูลนั้น โมเดลได้ทำนายได้ถูกต้องจำนวน 1,797 ข้อมูล แบ่งเป็นทำนายถูกต้องสำหรับข้อมูลแนวโน้มการของราคาอ้างอิงแบบขาขึ้นจำนวน 864 ข้อมูล และแบบขาลงจำนวน 933 ข้อมูล ค่าในตาราง Confusion Matrix จะถูกนำไปคิดเป็นค่าความแม่นยำในการทำนายดังแสดงในตารางที่ 4.21

ตารางที่ 4.21 สรุปผลการทดสอบประสิทธิภาพโมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไปโดยใช้ค่าจากมาตรวัดต่าง ๆ เดือน เมษายน พ.ศ. 2562

Class	Accuracy (%)	Precision (%)	Recall (%)	F-Measure (%)
Up (1)	68.1	68.1	69.7	68.9
Down (0)		68.1	66.4	67.2
<i>Average</i>		68.1	68.0	68.0

ตารางที่ 4.21 แสดงผลลัพธ์ในด้านความแม่นยำในการทำนายของโมเดล ซึ่งโมเดลมีความแม่นยำโดยรวม (Accuracy) อยู่ที่ 68.1% นอกจากนี้จะเห็นว่าเมื่อสนใจเฉพาะส่วนที่ทำนายโมเดลสามารถทำนายคลาส Down ได้กั้นเท่ากับ Up (ค่า Precision ของ Down สูงที่สุดเป็น 68.1%) และเมื่อดูความครอบคลุมของการทำนายข้อมูลพบว่า โมเดลสามารถทำนายคลาส Up ได้ดีที่สุด (ค่า Recall ของ Up เป็น 69.7%)


ตารางที่ 4.22 จำนวนครั้งที่เทรดชนะ ณ คำสั่งซื้อต่าง ๆ และจำนวนครั้งของการตัดขาดทุนของการจำลองการเทรดในเดือน เมษายน พ.ศ. 2562

Win at trading order	Total wins
1	1,348
2	249
3	140
4	38
5	12
6 (Cut Loss)	10

ตารางที่ 4.22 แสดงจำนวนครั้งที่เทรดชนะ ณ คำสั่งซื้อต่าง ๆ และจำนวนครั้งของการตัดขาดทุนของการจำลองการเทรดในเดือน เมษายน พ.ศ. 2562 จากผลลัพธ์ในตารางที่ 4-22 พบว่าโมเดลทำนายได้ถูกต้องในคำสั่งซื้อครั้งแรกจำนวน 1,348 ครั้ง ในขณะที่โมเดลทำนายผิดพลาดต่อกันถึง 6 ครั้งทำให้ต้องทำการตัดขาดทุนเป็นจำนวนทั้งหมด 10 ครั้ง ซึ่งผลสรุปกำไรขาดทุนแต่ละวันของการทดสอบแบบย้อนกลับในเดือนนี้แสดงในตารางที่ 4.23 และรูปที่ 4.14

ตารางที่ 4.23 สรุปผลกำไร/ขาดทุนแต่ละวันของการทดสอบแบบย้อนกลับในเดือน เมษายน พ.ศ. 2562

Date	Profit/Loss (\$)	Equity (\$)	Date	Profit/Loss (\$)	Equity (\$)
1 April 2019	11.0	511.0	16 April 2019	81.4	1,015.8
2 April 2019	12.2	523.2	17 April 2019	81.2	1,097.0
3 April 2019	-65.6	457.6	18 April 2019	77.6	1,174.6
4 April 2019	96.8	554.4	19 April 2019	80.2	1,254.8
5 April 2019	81.8	636.2	22 April 2019	83.6	1,338.4
8 April 2019	82.2	718.4	23 April 2019	13.0	1,351.4
9 April 2019	13.8	732.2	24 April 2019	83.0	1,434.4
10 April 2019	86.6	818.8	25 April 2019	14.4	1,448.8
11 April 2019	16.0	834.8	26 April 2019	14.8	1,463.6
12 April 2019	83.8	918.6	29 April 2019	83.0	1,546.6
15 April 2019	15.8	934.4	30 April 2019	84.4	1,631.0
			<b>Total</b>	<b>1,131.0</b>	



รูปที่ 4.14 กราฟแสดงจำนวนเงินคงเหลือจากการทดสอบแบบย้อนกลับแต่ละวันเดือน เมษายน พ.ศ. 2562

จากผลลัพธ์ที่แสดงในตารางที่ 4.20 และรูปที่ 4.12 สรุปได้ว่าเครื่องมือและกลยุทธ์ที่ใช้ในการเทรดและการตัดขาดทุนที่ได้นำเสนอในงานวิจัยนี้ สามารถสร้างผลกำไรได้อย่างต่อเนื่อง โดยวันที่สามารถทำกำไรได้มากที่สุดคือวันที่ 4 ของเดือนซึ่งทำกำไรได้ถึง 96.8 ดอลลาร์ ในขณะที่มีการเทรดขาดทุนในวันที่ 3 ของเดือนเป็นจำนวนเงิน -65.6 ดอลลาร์ จากผลการเทรดตลอดทั้งเดือนกุมภาพันธ์พบว่า เครื่องมือและกลยุทธ์ที่ใช้ในการเทรดและการตัดขาดทุนที่ได้นำเสนอ สามารถทำให้เงินลงทุนเพิ่มขึ้นจาก 500 ดอลลาร์ไปเป็น 1,631.0 ดอลลาร์ คิดเป็นกำไรทั้งสิ้น 1,131.0 ดอลลาร์

จากผลการทดสอบแบบย้อนกลับซึ่งเมื่อดูผลลัพธ์ของการทดสอบทั้ง 4 เดือนพบว่า ในการเทรดแต่ละเดือนพอร์ตการลงทุนมีอัตราการเติบโตอย่างต่อเนื่อง และในแต่ละเดือนสามารถทำกำไรสุทธิอยู่ที่ 1,558.4 ดอลลาร์สำหรับเดือนมกราคม 1,179.4 ดอลลาร์สำหรับเดือนกุมภาพันธ์ 1,118.0 ดอลลาร์ในเดือนมีนาคม และ 1,131.0 ดอลลาร์ในเดือนเมษายน จากผลลัพธ์ดังกล่าวทำให้สามารถสรุปได้ว่า เครื่องมือรวมทั้งกลยุทธ์ต่าง ๆ ที่งานวิจัยนี้ได้นำเสนอ นั้น มีความเป็นไปได้ที่จะสามารถนำไปใช้เพื่อสร้างทำกำไรให้กับนักลงทุนในการซื้อขายตัวเลือกไบนารีได้ อย่างไรก็ตาม การเทรดในโลกแห่งความเป็นจริงนั้นแตกต่างกับการจำลองการเทรด ดังนั้นในขั้นตอนถัดไปเป็นการทดสอบโดยการนำเครื่องมือรวมทั้งกลยุทธ์ต่าง ๆ ที่นำเสนอไปทดลองให้นักลงทุนใช้ในการเทรดตัวเลือกไบนารีในสภาวะแวดล้อมจริงและเงินลงทุนจริง เพื่อเป็นการพิสูจน์ว่าเครื่องมือที่งานวิจัยนี้ได้พัฒนาขึ้นนั้นสามารถนำไปใช้ในการซื้อขายตัวเลือกไบนารีได้จริง

#### 4.6.2 ผลการทดสอบแบบไปข้างหน้า

ในขั้นตอนนี้เป็นการทดลองนำเครื่องมือรวมทั้งกลยุทธ์ทั้งหมดที่นำเสนอในงานวิจัยนี้ไปให้นักลงทุนใช้ในการเทรดตัวเลือกไบนารีในสภาวะแวดล้อมจริงและใช้เงินลงทุนจริง โดยการเทรดนั้นมีการกำหนดเงื่อนไขและรายละเอียดของการทดลองไว้ดังนี้

- 1) โบรกเกอร์ที่ใช้ในการเทรดคือ Olymp Trade (<https://olymptrade.com>)
- 2) จำนวนเงินลงทุนเริ่มแรกเท่ากับ 500 ดอลลาร์ เมื่อฝากเงินเข้าไปในพอร์ตลงทุนทางโบรกเกอร์จะให้โบนัสฝากเงินครั้งแรกเพิ่มอีก 39 ดอลลาร์ ซึ่งเงินโบนัสสามารถใช้ในการเทรดได้ แต่ไม่สามารถถอนออกมาจากพอร์ตลงทุนได้
- 3) คู่เงินที่ใช้เทรดคือ EURUSD
- 4) คาบเวลาที่ใช้เทรดคือ ราย 5 นาที
- 5) ระยะเวลาในการทดลองเทรดคือ ตั้งแต่ วันที่ 25 มิถุนายน ถึงวันที่ 31 กรกฎาคม พ.ศ. 2562

- 6) จำนวนเงินที่จะลงทุนในแต่ละรอบการเทรดและการคำนวณกำไรหรือขาดทุน  
ใช้ข้อมูลดังแสดงในตารางที่ 3.1
- 7) ตัดขาดทุนเมื่อเทรดแพ้ติดต่อกันจำนวน 6 ครั้ง
- ผลการทดสอบแบบไปข้างหน้าในขั้นตอนนี้แสดงรายละเอียดในตารางที่ 4.24 และ  
รูปที่ 4.15

ตารางที่ 4.24 สรุปผลลัพธ์กำไรขาดทุนแต่ละวันของการทดสอบแบบไปข้างหน้าเริ่มตั้งแต่วันที่ 25  
มิถุนายน ถึงวันที่ 31 กรกฎาคม พ.ศ. 2562

Date	Profit / Loss (\$)	Equity (\$)	Date	Profit / Loss (\$)	Equity (\$)
25 June 2019	-14.39	524.61	12 July 2019	90.26	773.01
26 June 2019	25.20	549.81	15 July 2019	44.18	817.19
27 June 2019	21.00	570.81	16 July 2019	25.71	842.90
28 June 2019	-103.17	467.64	17 July 2019	19.13	862.03
1 July 2019	0.82	468.46	18 July 2019	29.31	891.34
2 July 2019	15.92	484.38	19 July 2019	103.30	994.64
3 July 2019	17.01	501.39	24 July 2019	35.91	1,030.55
4 July 2019	9.74	511.13	25 July 2019	24.20	1,054.75
5 July 2019	17.00	528.13	26 July 2019	137.42	1,192.17
8 July 2019	0.80	528.93	29 July 2019	52.12	1,244.29
9 July 2019	74.75	603.68	30 July 2019	111.91	1,356.20
10 July 2019	33.51	637.19	31 July 2019	48.18	1,404.38
11 July 2019	45.56	682.75	<b>Total</b>	<b>865.38</b>	

ตารางที่ 4.24 แสดงผลสรุปกำไรขาดทุนแต่ละวันของการทดสอบแบบไปข้างหน้า  
ตั้งแต่วันที่ 25 มิถุนายน ถึงวันที่ 31 กรกฎาคม พ.ศ. 2562 จากข้อมูลที่แสดงในตารางพบว่า นัก  
ลงทุนสามารถสร้างผลกำไรได้ 23 วันจากการเทรด 25 วัน ซึ่งวันที่ 26 กรกฎาคม 2562 นักลงทุนทำ  
กำไรได้มากที่สุดจำนวนเงิน 137.42 ดอลลาร์ ในขณะที่วันที่ 25 และ 28 มิถุนายน 2562 นักลงทุน  
ขาดทุนจากการเทรดเป็นจำนวนเงิน 14.39 และ 103.17 ดอลลาร์ตามลำดับ นอกจากนี้จากผลการ  
เทรดในระยะเวลาดังกล่าวพบว่า จากเงินลงทุนเริ่มต้นในพอร์ตการลงทุน 539 ดอลลาร์ เมื่อครบ

กำหนดการทดลองแล้ว เงินลงทุนในพอร์ตการลงทุนเพิ่มขึ้นเป็น 1,404.38 ดอลลาร์ คิดเป็นผลกำไรที่นักลงทุนทำได้เป็นจำนวนเงินทั้งสิ้น 865.38 ดอลลาร์ ดังแสดงในรูปที่ 4.15

#### 4.7 การอภิปรายผลการทดลอง

วัตถุประสงค์หลักของงานวิจัยนี้คือการพัฒนาเครื่องมือและกลยุทธ์ที่นักลงทุนสามารถใช้เป็นตัวช่วยเพื่อทำกำไรในการซื้อขายตัวเลือกไบนารีได้ ซึ่งกระบวนการวิจัยได้นำเสนอขั้นตอนในการเตรียมข้อมูลและกระบวนการที่ใช้ในการพัฒนาโมเดลเพื่อใช้ในการกำหนดทิศทางการลงทุนในการซื้อขายตัวเลือก โดยใช้ทฤษฎีการเรียนรู้เชิงลึกได้แก่ LSTM และนำเสนอวิธีการต่าง ๆ ที่ใช้ในการเพิ่มประสิทธิภาพให้กับโมเดล LSTM นอกจากนี้ยังได้นำเสนอกลยุทธ์ที่ใช้ในการเทรดและการบริหารจัดการเงินในพอร์ตการลงทุนรวมทั้งกลยุทธ์ที่ใช้ในการตัดขาดทุนที่เหมาะสมกับการลงทุนในรูปแบบของการซื้อขายตัวเลือกไบนารี จากผลลัพธ์ที่ได้จากการทดลองทำให้สามารถสรุปเป็นประเด็นต่าง ๆ ที่น่าสนใจได้หลายประเด็น ดังต่อไปนี้


- 1) ผลสรุปที่ได้จากการทดสอบประสิทธิภาพโมเดล LSTM สำหรับใช้ในการทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไปที่ถูกสร้างขึ้นโดยกระบวนการพื้นฐานและที่ยังไม่ได้ผ่านการเพิ่มประสิทธิภาพ พบว่าโมเดลมีความแม่นยำในการทำนายเฉลี่ยเพียง 52.5% ซึ่งยังไม่เพียงพอสำหรับนำไปใช้งานจริง ดังนั้นจะต้องทำการปรับปรุงประสิทธิภาพให้โมเดลมีความแม่นยำมากกว่า 65%
- 2) ผลการทดสอบพารามิเตอร์ที่เหมาะสมกับการสร้างโมเดลในประเด็นของการกำหนดความยาวของข้อมูลนำเข้าที่เหมาะสมพบว่า สามารถทำให้ความแม่นยำในการทำนายเฉลี่ยของโมเดลเพิ่มขึ้นเป็น 54.5% เมื่อทำการกำหนดความยาวของข้อมูลนำเข้าเท่ากับ 10 คาบเวลา
- 3) ผลการทดสอบประสิทธิภาพโมเดลเมื่อกำหนดจำนวนข้อมูลที่เหมาะสมสำหรับการเรียนรู้เพื่อพัฒนาโมเดลพบว่า สามารถทำให้ความแม่นยำในการทำนายเฉลี่ยของโมเดลเพิ่มขึ้นเป็น 61.2% เมื่อกำหนดจำนวนข้อมูลสำหรับการเรียนรู้เท่ากับ 14 วัน
- 4) จากผลลัพธ์ในการทดสอบประสิทธิภาพด้านความแม่นยำในการทำนายรายวันของโมเดลพบว่า เมื่อเวลาผ่านไปประสิทธิภาพความแม่นยำในการทำนายของโมเดลเริ่มลดลง อ้างอิงจากผลการทดลองในตารางที่ 4.4 จะเห็นว่าตั้งแต่วันที่ 2 ของการใช้งานนั้น โมเดลจะมีความแม่นยำในการทำนายลดลงและลดลงอย่างมากตั้งแต่วันที่ 3 เป็นต้นไป โดยมีเพียงในวันที่ 1 และวันที่ 2 เท่านั้นที่โมเดลมีความแม่นยำในการทำนายเฉลี่ยมากกว่า 65% (67.5% ในวันที่ 1 และ 65.4% ในวันที่ 2) ที่เป็นเช่นนี้อาจเป็น



เพราะว่าข้อมูลที่ใช้ในการเรียนรู้ของโมเดลเริ่มล่าช้า ดังนั้นในการนำโมเดลไปใช้งานจริงนักลงทุนต้องทำการปรับปรุง โมเดลให้ทันสมัยอยู่เสมอ โดยเวลาที่เหมาะสมที่สุดในการปรับปรุงโมเดลให้ทันสมัยคือ ทุกวัน หรือ อย่างช้าที่สุดคือทุก 2 วัน

- 5) วิธีการสุดท้ายที่ผู้วิจัยนำเสนอเพื่อเพิ่มประสิทธิภาพในการทำนายให้โมเดล LSTM คือการพัฒนาโมเดลให้มีความเฉพาะเจาะจงและเหมาะสมกับข้อมูลแนวโน้มความเคลื่อนไหวของราคาอ้างอิงแต่ละประเภท โดยประเภทของแนวโน้มความเคลื่อนไหวของราคาในงานวิจัยนี้ได้กำหนดให้มีทั้งหมด 3 ประเภทคือ แนวโน้มแบบขาขึ้นอย่างต่อเนื่อง แนวโน้มแบบผันผวน และแนวโน้มแบบขาลงอย่างต่อเนื่อง ดังนั้นข้อมูลที่เตรียมไว้จะผ่านการจำแนกโดยผู้เชี่ยวชาญก่อน จากนั้นนำข้อมูลที่ถูกจำแนกแต่ละประเภทไปพัฒนาโมเดล LSTM จำนวน 3 โมเดล จากผลการทดลองพบว่าค่าเฉลี่ยความแม่นยำในการทำนายของโมเดล LSTM ทั้ง 3 โมเดลเพิ่มขึ้นมาเป็น 69.7%
- 6) จากข้อสรุปในข้อที่ 5 พบว่าการจำแนกข้อมูลแล้วสร้าง โมเดลที่เฉพาะเจาะจงตามประเภทของข้อมูลนั้นช่วยเพิ่มประสิทธิภาพความแม่นยำในการทำนายให้กับโมเดล LSTM ได้ แต่ทว่าการที่ต้องใช้ผู้เชี่ยวชาญในการคัดแยกข้อมูลนั้นเป็นเรื่องยาก ซึ่งจะทำให้เสียเวลาและแรงงานของผู้เชี่ยวชาญ นอกจากนี้ยังอาจจะทำให้ประมวลผลข้อมูลไม่ทันในระยะเวลา 5 นาทีซึ่งจะทำให้ส่งคำสั่งซื้อขายไม่ทันเวลา ดังนั้นผู้วิจัยจึงได้นำเสนอการพัฒนาเครื่องมืออัตโนมัติที่สามารถใช้ในการจำแนกประเภทของข้อมูลแทนที่การใช้ผู้เชี่ยวชาญ โดยเครื่องมือดังกล่าวถูกสร้างขึ้นโดยใช้ทฤษฎีด้านปัญญาประดิษฐ์ เปรียบเทียบกับเครื่องมือที่ถูกสร้างโดยการให้ทฤษฎีการวิเคราะห์ทางเทคนิค ในขั้นตอนแรกของกระบวนการนี้ผู้วิจัยได้สร้างโมเดลสำหรับใช้ในการจำแนกประเภทของข้อมูลโดยใช้อัลกอริทึมทางด้านปัญญาประดิษฐ์คือ CNN, SVM และ ANN โดยผลการเปรียบเทียบประสิทธิภาพความแม่นยำในการจำแนกของโมเดลทั้ง 3 พบว่า โมเดลมีความแม่นยำในการจำแนกสูงที่สุด (87.8%)
- 7) ผลการทดสอบประสิทธิภาพความแม่นยำในการทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไปของโมเดล LSTM ที่ถูกสร้างขึ้นจากข้อมูลที่ผ่านการคัดแยกโดยใช้ ปัญญาประดิษฐ์ ( $TCM_{CNN}$ ) และหลักการวิเคราะห์ทางเทคนิคคือ ค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนักซับซ้อน ( $TCM_{EMA}$ ) (หัวข้อที่ 4.5) พบว่าโมเดลทั้ง 2 รูปแบบให้ประสิทธิภาพความแม่นยำในการทำนายที่ใกล้เคียงกัน โดยที่โมเดล LSTM ที่ใช้ข้อมูลในการเรียนรู้จากการจำแนกของ  $TCM_{CNN}$  มีความแม่นยำในการทำนายเฉลี่ยสูงกว่าที่โมเดล LSTM ที่ใช้ข้อมูลในการเรียนรู้จากการจำแนกของ  $TCM_{EMA}$  อยู่ 0.86%

- 8) เมื่อเปรียบเทียบค่าเฉลี่ยความแม่นยำในการทำนายของโมเดล LSTM ที่ใช้ข้อมูลที่คัดแยกโดยผู้เชี่ยวชาญกับโมเดล LSTM ที่ใช้ข้อมูลที่ผ่านการคัดแยกโดยเครื่องมือ  $TCM_{CNN}$  พบว่าโมเดล LSTM ที่ใช้ข้อมูลที่ผ่านการคัดแยกโดยโมเดล  $TCM_{CNN}$  มีค่าเฉลี่ยความแม่นยำในการทำนายต่ำกว่าโมเดล LSTM ที่ใช้ข้อมูลที่คัดแยกโดยผู้เชี่ยวชาญอยู่เพียงแค่ 0.37% แต่ข้อได้เปรียบในการใช้โมเดล LSTM ที่ใช้ข้อมูลที่ผ่านการคัดแยกโดยโมเดล  $TCM_{CNN}$  คือการทำงานที่รวดเร็วและเป็นระบบอัตโนมัติ
- 9) จากผลการทดสอบแบบย้อนกลับสรุปได้ว่าเครื่องมือและกลยุทธ์ที่นำเสนอในงานวิจัยนี้ สามารถสร้างผลกำไรได้อย่างต่อเนื่องจากการจำลองการเทรดโดยใช้ข้อมูลย้อนหลัง นอกจากนี้ผลสรุปด้านประสิทธิภาพความแม่นยำในการทำนายของโมเดลมีค่าใกล้เคียงกับผลการทดลองในขั้นตอนการสร้างและการเพิ่มประสิทธิภาพโมเดล แต่สิ่งที่มีความสำคัญที่ทำให้สร้างผลกำไรได้คือ กลยุทธ์การในการเทรดและการบริหารจัดการเงินในพอร์ตลงทุนรวมทั้งกลยุทธ์ในการตัดขาดทุน เมื่อสังเกตผลสรุปจำนวนครั้งที่เทรดชนะ ณ คำสั่งซื้อขายแต่ละรอบพบว่า จำนวนครั้งของการตัดขาดทุนในการจำลองการเทรดพบว่าในแต่ละเดือนมีการตัดขาดทุนอยู่บ่อยครั้ง ซึ่งถ้านักลงทุนไม่มีกลยุทธ์การในการเทรดและการบริหารจัดการเงินในพอร์ตลงทุนรวมทั้งกลยุทธ์ในการตัดขาดทุนที่เหมาะสมอาจทำให้นักลงทุนไม่สามารถสร้างผลกำไรไปและอาจขาดทุนได้
- 10) การทดสอบแบบไปข้างหน้าเป็นการทดสอบว่าโมเดลและกลยุทธ์ต่าง ๆ ที่นำเสนอในงานวิจัยนี้สามารถนำไปใช้สร้างกำไรให้กับนักลงทุนในสภาวะแวดล้อมจริงของการซื้อขายตัวเลือกโบนารีได้หรือไม่ บ่อยครั้งที่เครื่องมือและกลยุทธ์ในการเทรดที่นักลงทุนคิดค้นขึ้นมาขึ้นให้ผลลัพธ์ที่ดีและสามารถสร้างผลกำไรได้เมื่อทำการทดสอบแบบย้อนกลับ แต่เมื่อนักลงทุนนำไปใช้เทรดจริงกลับทำให้นักลงทุนขาดทุน ดังนั้นจึงต้องมีการทดสอบแบบไปข้างหน้าเพื่อเป็นการพิสูจน์ว่าสิ่งทีมงานวิจัยนี้นำเสนอนั้นสามารถนำไปใช้งานได้จริง จากผลการทดสอบแบบไปข้างหน้าพบว่าเครื่องมือและกลยุทธ์ที่ได้จากงานวิจัยนี้สามารถสร้างผลกำไรให้กับนักลงทุนได้อย่างต่อเนื่องตลอดระยะเวลาในการทดสอบ แต่มีข้อสังเกตว่าผลการเทรดในช่วงแรกมีการขาดทุนอยู่บ้างเป็นเพราะว่านักลงทุนมีความลังเลและไม่ทำตามเงื่อนไขข้อกำหนดต่าง ๆ ที่กลยุทธ์การเทรดและการตัดขาดทุนกำหนดไว้ แต่เมื่อนักลงทุนทำตามกลยุทธ์และข้อกำหนดอย่างมีวินัยทำให้กลับมาทำกำไรได้อย่างต่อเนื่อง



รูปที่ 4.15 ผลการวัดประสิทธิภาพด้านการเงินของโมเดลในการซื้อขายตัวเลือกใบนารีแบบไปข้างหน้า

## บทที่ 5

### บทสรุป

งานวิจัยนี้ได้นำความรู้ทางด้านปัญญาประดิษฐ์ โดยเฉพาะเทคนิคการเรียนรู้เชิงลึกได้แก่ หน่วยความจำระยะสั้นระยะยาว มาประยุกต์เพื่อพัฒนาเป็น โมเดลสำหรับทำนายทิศทาง การเปลี่ยนแปลงราคาอ้างอิงในคาบเวลาถัดไปของสกุลเงินในตลาดการซื้อขายแลกเปลี่ยนเงินตรา ต่างประเทศ ซึ่งโมเดลนี้จะช่วยให้นักลงทุนสามารถกำหนดทิศทางในการลงทุนแต่ละครั้งในการ ซื้อขายตัวเลือกไบนารีได้ นอกจากนี้ยังได้นำเสนอวิธีการต่าง ๆ ในการเพิ่มประสิทธิภาพให้กับ โมเดล ซึ่งทำให้โมเดลมีประสิทธิภาพในการทำนายข้อมูลได้อย่างแม่นยำมากขึ้น ในด้านการ การสร้างผลกำไรในการลงทุนซื้อขายตัวเลือกไบนารี งานวิจัยนี้ได้นำเสนอกลยุทธ์ที่ใช้ในการลงทุนซึ่ง เป็นการประยุกต์ใช้ทฤษฎีแบบ Martingale และได้นำเสนอกลยุทธ์ในการตัดขาดทุนที่เหมาะสมกับ การลงทุนในการซื้อขายตัวเลือกไบนารี นอกจากการวัดประสิทธิภาพด้านความแม่นยำในการ ทำนายของ โมเดลแล้ว ที่สำคัญที่สุดงานวิจัยนี้ได้ทำการวัดประสิทธิภาพในด้านการทำกำไรสำหรับ การลงทุนในการซื้อขายตัวเลือกไบนารี ทั้งการวัดประสิทธิภาพด้วยการจำลองการเทรดจากข้อมูล ย้อนหลัง (Backward Test) และการทดลองเทรดจริง (Forward Test) จากผลการศึกษาทั้งหมด สามารถสรุปผลการวิจัยได้ดังนี้

#### 5.1 สรุปผลการวิจัย

เป้าหมายหลักของงานวิจัยนี้คือการพัฒนาเครื่องมือที่สามารถใช้เป็นตัวช่วยให้นักลงทุนทำ กำไรในการซื้อขายตัวเลือกไบนารีได้ ซึ่งกระบวนการวิจัยได้นำเสนอขั้นตอนในการเตรียมข้อมูล และขั้นตอนการพัฒนาโมเดลเพื่อใช้ในการกำหนดทิศทางการลงทุนในการซื้อขายตัวเลือกไบนารี โดยใช้ทฤษฎีการเรียนรู้เชิงลึกได้แก่ LSTM และยังสามารถนำเสนอวิธีการต่าง ๆ ที่ใช้ในการเพิ่ม ประสิทธิภาพให้กับโมเดล นอกจากนี้ยังได้นำเสนอกลยุทธ์ที่ใช้ในการเทรดและกลยุทธ์ที่ใช้ในการ ตัดขาดทุนที่เหมาะสมกับการลงทุนในรูปแบบของการซื้อขายตัวเลือกไบนารี สุดท้ายเครื่องมือ รวมทั้งกลยุทธ์ต่าง ๆ ที่นำเสนอได้ถูกนำมาประเมินประสิทธิภาพในด้านการสร้างผลกำไรในการ ซื้อขายตัวเลือกไบนารี โดยการทดสอบทั้งในรูปแบบของการจำลองการเทรดโดยใช้ข้อมูล ย้อนหลัง และการให้นักลงทุนทดลองใช้เครื่องมือและกลยุทธ์เหล่านี้ในการเทรดโดยใช้เงินลงทุน จริงภายใต้สภาพแวดล้อมจริง ซึ่งระเบียบวิธีการในการดำเนินงานวิจัยสามารถสรุปได้ดังนี้

- 1) การเตรียมข้อมูล การแปลงข้อมูล และการกำหนดคำนิยามให้กับข้อมูล เพื่อใช้เป็นข้อมูลสำหรับการพัฒนาและทดสอบประสิทธิภาพของโมเดล รวมทั้งการทดสอบประสิทธิภาพในการสร้างผลกำไรในการซื้อขายตัวเลือกไปนารีของเครื่องมือและกลยุทธ์ที่นำเสนอในงานวิจัยนี้
- 2) การพัฒนาโมเดลสำหรับทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไปโดยใช้อัลกอริทึม LSTM ซึ่งโมเดลนี้จะถูกใช้เพื่อทำนายทิศทางในการเคลื่อนไหวของราคาในคาบเวลาถัดไป เพื่อให้นักลงทุนสามารถระบุว่าส่งคำสั่งซื้อหรือขายในการลงทุนแต่ละครั้ง
- 3) การเพิ่มประสิทธิภาพให้กับโมเดล LSTM ด้วยวิธีการต่าง ๆ ดังนี้
  - การกำหนดความยาวของข้อมูลนำเข้าสำหรับการพัฒนาโมเดล LSTM
  - การกำหนดจำนวนข้อมูลที่เหมาะสมสำหรับการเรียนรู้ของโมเดล LSTM
  - การกำหนดระยะเวลาที่ต้องทำการปรับปรุงโมเดล LSTM ให้มีความทันสมัยเพื่อรักษาประสิทธิภาพความแม่นยำในการทำนาย
  - การจำแนกข้อมูลที่จะใช้ในการพัฒนาโมเดล LSTM ตามลักษณะแนวโน้มการเคลื่อนไหวของราคาแต่ละประเภท
- 4) การพัฒนาเครื่องมืออัตโนมัติสำหรับการจำแนกข้อมูลตามประเภทของแนวโน้มความเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนด (TCM) เพื่อใช้ในการจำแนกประเภทของข้อมูลนำเข้าสำหรับโมเดล LSTM แทนที่การใช้ผู้เชี่ยวชาญ
- 5) เปรียบเทียบประสิทธิภาพความแม่นยำในการทำนายแนวโน้มการเปลี่ยนแปลงของราคาอ้างอิงในช่วงเวลาถัดไปของโมเดล LSTM ที่ถูกสร้างขึ้นจากข้อมูลที่ผ่านการคัดแยกโดยใช้ปัญญาประดิษฐ์ด้วยอัลกอริทึม CNN ( $TCM_{CNN}$ ) และหลักการวิเคราะห์ทางเทคนิคคือ ค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนักซับซ้อน ( $TCM_{EMA}$ )
- 6) การทดสอบแบบย้อนกลับ เป็นการจำลองการเทรดโดยการใช้ข้อมูลย้อนหลัง เพื่อวัดประสิทธิภาพในด้านการทำกำไรหรือขาดทุนของเครื่องมือ และกลยุทธ์ต่าง ๆ ที่นำมาใช้ในการเทรด
- 7) การทดสอบแบบไปข้างหน้า เป็นการทดสอบว่าโมเดลและกลยุทธ์ต่าง ๆ ที่นำเสนอสามารถนำไปใช้สร้างกำไรให้กับนักลงทุนในสภาวะแวดล้อมจริงได้หรือไม่ โดยการให้นักลงทุนใช้เครื่องมือ และกลยุทธ์ต่าง ๆ ที่นำเสนอไปใช้ในการซื้อขายตัวเลือกไปนารีภายใต้สภาพแวดล้อมในการลงทุนจริงด้วยเงินลงทุนจริง

ตารางที่ 5.1 ผลสรุปประสิทธิภาพความแม่นยำของโมเดลที่ได้รับการพัฒนาและเพิ่มประสิทธิภาพด้วยวิธีการต่าง ๆ ในงานวิจัยนี้

ลำดับที่	วิธีการ	Input Length (Periods)	Amount of Training Data (Days)	Update Frequency (Days)	Average Accuracy (%)
1	โมเดล LSTM พื้นฐาน	30	90	-	52.5
2	โมเดล LSTM ที่ผ่านการเพิ่มประสิทธิภาพโดยการกำหนดความยาวของข้อมูลนำเข้าสำหรับการพัฒนาโมเดล	10	90	-	54.5
3	โมเดล LSTM ที่ผ่านการเพิ่มประสิทธิภาพโดยการกำหนดจำนวนข้อมูลที่เหมาะสมสำหรับการเรียนรู้ของโมเดล	10	14	-	61.2
4	โมเดล LSTM ที่ผ่านการเพิ่มประสิทธิภาพโดยการกำหนดระยะเวลาที่ต้องทำการปรับปรุงโมเดลให้มีความทันสมัยเพื่อรักษาประสิทธิภาพในการทำนาย	10	14	1	67.5
5	โมเดล LSTM ที่ผ่านการเพิ่มประสิทธิภาพโดยการใช้อำนาจที่ผ่านการจำแนกตามประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงโดยผู้เชี่ยวชาญในการจำแนก	10	14	1	69.7

จากผลการทดลองที่แสดงในตารางที่ 5.1 สามารถสรุปได้ดังนี้

- 1) โมเดล LSTM พื้นฐานที่ยังไม่ได้กำหนดพารามิเตอร์ที่เหมาะสมให้ประสิทธิภาพความแม่นยำในการทำนายเพียง 52.5% ซึ่งยังไม่สามารถนำไปใช้งานได้ ดังนั้นต้องทำการปรับปรุงประสิทธิภาพให้โมเดลมีความแม่นยำในการทำนายมากกว่า 65% เสียก่อน
- 2) โมเดล LSTM ให้ประสิทธิภาพความแม่นยำในการทำนายเพิ่มจาก 52.5% เป็น 54.5% เมื่อกำหนดความยาวของข้อมูลนำเข้าสำหรับการพัฒนาโมเดลเท่ากับ 10 คาบเวลา
- 3) โมเดล LSTM ให้ประสิทธิภาพความแม่นยำในการทำนายเพิ่มจาก 54.5% เป็น 61.2% เมื่อกำหนดจำนวนข้อมูลที่เหมาะสมสำหรับการเรียนรู้ของ โมเดลเท่ากับ 14 วัน
- 4) การปรับปรุงโมเดลให้ทันสมัยทุกวันสามารถเพิ่มประสิทธิภาพความแม่นยำในการทำนายเพิ่มจาก 61.2% เป็น 67.5%
- 5) โมเดล LSTM ที่ถูกพัฒนาให้มีความเฉพาะเจาะจงและเหมาะสมกับประเภทของแนวโน้มความเคลื่อนไหวของราคาอ้างอิงในช่วงเวลานั้น ๆ โดยประเภทของแนวโน้มความเคลื่อนไหวของราคาในงานวิจัยนี้ ผู้วิจัยได้กำหนดให้มีทั้งหมด 3 ประเภทได้แก่ แนวโน้มแบบขาขึ้นอย่างต่อเนื่อง แนวโน้มแบบผันผวน และแนวโน้มแบบขาลงอย่างต่อเนื่อง ข้อมูลที่ผ่านการจำแนกโดยผู้เชี่ยวชาญและนำไปสร้างโมเดล LSTM จำนวน 3 โมเดล จากผลการทดลองพบว่าวิธีการที่นำเสนอ สามารถเพิ่มประสิทธิภาพความแม่นยำในการทำนายให้โมเดล LSTM ทั้ง 3 โมเดล โดยความแม่นยำในการทำนายเฉลี่ยเพิ่มขึ้นจาก 67.5% เป็น 69.7%

ถึงแม้ว่าการจำแนกข้อมูลเพื่อพัฒนาโมเดลที่เฉพาะเจาะจงตามประเภทของข้อมูลนั้นช่วยเพิ่มประสิทธิภาพความแม่นยำในการทำนายให้กับโมเดลได้ แต่ทว่าการที่ต้องใช้ผู้เชี่ยวชาญในการคัดแยกข้อมูลนั้น ในการใช้งานจริงเป็นเรื่องยาก ซึ่งจะทำให้เสียเวลาและแรงงานของผู้เชี่ยวชาญ และอาจจะทำให้ประมวลผลข้อมูลไม่ทันในระยะเวลา 5 นาที ดังนั้นงานวิจัยนี้จึงได้นำเสนอการพัฒนาเครื่องมืออัตโนมัติที่สามารถใช้ในการจำแนกประเภทของข้อมูล (TCM) แทนที่การใช้ผู้เชี่ยวชาญ โดยการใช้ทฤษฎีความรู้ด้านปัญญาประดิษฐ์สาขาการเรียนรู้เชิงลึกและการเรียนรู้ของเครื่อง ได้แก่ CNN SVM และ ANN เปรียบเทียบกับการใช้ทฤษฎีการวิเคราะห์ทางเทคนิค คือ EMA

ตารางที่ 5.2 สรุปผลการทดสอบประสิทธิภาพโมเดลสำหรับใช้เป็นเครื่องมืออัตโนมัติในการจำแนกประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนดโดยใช้อัลกอริทึมทางด้านปัญญาประดิษฐ์

ลำดับที่	วิธีการ	Accuracy (%)
1	TCM <sub>SVM</sub>	50.7
2	TCM <sub>ANN</sub>	49.9
3	TCM <sub>CNN</sub>	87.8

ตารางที่ 5.2 แสดงผลสรุปประสิทธิภาพในการจำแนกข้อมูลของโมเดลที่ถูกพัฒนาโดยใช้ทฤษฎีด้านปัญญาประดิษฐ์ ได้แก่ CNN SVM และ ANN จากผลการทดลองสรุปได้ว่าโมเดลที่ถูกพัฒนาด้วยอัลกอริทึม CNN มีประสิทธิภาพด้านความแม่นยำในการจำแนกข้อมูลมากที่สุดคือ 87.8%

ในส่วนของสร้างเป็นเครื่องมืออัตโนมัติสำหรับการจำแนกประเภทแนวโน้มการเคลื่อนไหวของราคาอ้างอิงในช่วงเวลาที่กำหนดเพื่อแทนที่การใช้ผู้เชี่ยวชาญโดยใช้หลักการวิเคราะห์ทางเทคนิคด้วย EMA นั้น ผู้วิจัยได้กำหนดเงื่อนไขสำหรับการจำแนกประเภทแนวโน้มของข้อมูลดังนี้

- 1) ข้อมูลจะถูกจำแนกอยู่ในรูปแบบของ Upward Trend เมื่อนำค่า EMA ของราคาอ้างอิงในคาบปัจจุบันลบด้วยค่า EMA ของราคาอ้างอิงในคาบเริ่มต้นของช่วงเวลาที่กำหนดแล้วมีค่ามากกว่าหรือเท่ากับ 10 และอัตราส่วนแนวโน้มของราคาขาขึ้น (1) และขาลง (0) ของแต่ละคาบเวลาในช่วงเวลาที่กำหนดมีที่ 70% ต่อ 30%
- 2) ข้อมูลจะถูกจำแนกอยู่ในรูปแบบของ Sideways เมื่อนำค่า EMA ของราคาอ้างอิงในคาบปัจจุบันลบด้วยค่า EMA ของราคาอ้างอิงในคาบเริ่มต้นของช่วงเวลาที่กำหนดแล้วมีค่าน้อยกว่า 10 และอัตราส่วนแนวโน้มของราคาขาขึ้น (1) และขาลง (0) ของแต่ละคาบเวลาในช่วงเวลาที่กำหนดมีที่ 60% ต่อ 40% หรือ 40% ต่อ 60%
- 3) ข้อมูลจะถูกจำแนกอยู่ในรูปแบบของ Downward Trend เมื่อนำค่า EMA ของราคาอ้างอิงในคาบปัจจุบันลบด้วยค่า EMA ของราคาอ้างอิงในคาบเริ่มต้นของช่วงเวลาที่กำหนดแล้วมีค่าน้อยกว่าหรือเท่ากับ -10 และอัตราส่วนแนวโน้มขาขึ้น (1) และขาลง (0) ของแต่ละคาบเวลาในช่วงเวลาที่กำหนดมีที่ 30% ต่อ 70%



ตารางที่ 5.3 สรุปผลลัพธ์การเปรียบเทียบประสิทธิภาพความแม่นยำในการทำนายของโมเดล LSTM ที่ใช้ข้อมูลในการเรียนรู้จากการจำแนกโดยใช้ผู้เชี่ยวชาญ  $TCM_{CNN}$  และ  $TCM_{EMA}$

ลำดับที่	วิธีการ	Average Accuracy (%)
1	โมเดล LSTM ที่ใช้ข้อมูลที่คัดแยกโดยผู้เชี่ยวชาญ	69.7
2	โมเดล LSTM ที่ใช้ข้อมูลที่ผ่านการคัดแยกโดยโมเดล $TCM_{CNN}$	69.3
3	โมเดล LSTM ที่ใช้ข้อมูลที่ผ่านการคัดแยกโดยโมเดล $TCM_{EMA}$	68.5

ตารางที่ 5.3 แสดงผลลัพธ์จากการเปรียบเทียบประสิทธิภาพความแม่นยำในการทำนายของโมเดล LSTM ที่ใช้ข้อมูลในการเรียนรู้จากการจำแนกโดยใช้ผู้เชี่ยวชาญ  $TCM_{CNN}$  และ  $TCM_{EMA}$  ซึ่งจากผลลัพธ์ที่ในตาราง สามารถสรุปได้เป็น 2 ประเด็นดังนี้

- 1) โมเดล LSTM ที่ใช้ข้อมูลที่คัดแยกโดยผู้เชี่ยวชาญมีประสิทธิภาพในการทำนายสูงที่สุดที่ 69.7% ตามมาด้วยโมเดล LSTM ที่ใช้ข้อมูลที่ผ่านการคัดแยกโดยโมเดล  $TCM_{CNN}$  และโมเดล LSTM ที่ใช้ข้อมูลที่ผ่านการคัดแยกโดยโมเดล  $TCM_{EMA}$  ตามลำดับ
- 2) โมเดล LSTM ที่ใช้ข้อมูลที่ผ่านการจำแนกโดยโมเดล  $TCM_{CNN}$  มีค่าเฉลี่ยความแม่นยำในการทำนายต่ำกว่าโมเดล LSTM ที่ใช้ข้อมูลที่คัดแยกโดยผู้เชี่ยวชาญอยู่เพียงแค่ 0.4% แต่ข้อได้เปรียบในการใช้โมเดล LSTM ที่ใช้ข้อมูลที่ผ่านการจำแนกโดยโมเดล  $TCM_{CNN}$  คือได้การทำงานที่เป็นอัตโนมัติโดยไม่ต้องใช้ผู้เชี่ยวชาญในกระบวนการจำแนกข้อมูล

ดังนั้น โมเดล LSTM ที่ใช้ข้อมูลที่ผ่านการคัดแยกโดยโมเดล  $TCM_{CNN}$  จะถูกใช้เป็นเครื่องมือในการกำหนดทิศทางในการซื้อขายตัวเลือกไบนารีร่วมกับกลยุทธ์ในการเทรดและกลยุทธ์ในการตัดขาดทุนเพื่อทำการทดสอบด้านการเงิน ซึ่งผลสรุปในการทดสอบประสิทธิภาพในการสร้างผลกำไรให้กับนักลงทุนในการซื้อขายตัวเลือกไบนารีแสดงในตารางที่ 5.4 และตารางที่ 5.5

ตารางที่ 5.4 สรุปความแม่นยำของโมเดลที่ได้รับการพัฒนาและเพิ่มประสิทธิภาพด้วยวิธีการต่าง ๆ ที่นำเสนอในงานวิจัยนี้ด้วยการทดสอบแบบย้อนกลับ

Month	Average Accuracy (%)	Initial Equity (\$)	Final Equity (\$)	Total Profit/Loss (\$)
January 2019	69.7	500	2,058.4	1,558.4
February 2019	70.3	500	1,679.4	1,179.4
March 2019	68.3	500	1,618.0	1,118.0
April 2019	68.1	500	1,631.0	1,131.0

ตารางที่ 5.5 สรุปความแม่นยำของโมเดลที่ได้รับการพัฒนาและเพิ่มประสิทธิภาพด้วยวิธีการต่าง ๆ ที่นำเสนอในงานวิจัยนี้ด้วยการทดสอบแบบไปข้างหน้า

Trading Date	Average Accuracy (%)	Initial Equity (\$)	Final Equity (\$)	Total Profit/Loss (\$)
25 June - 31 July 2019	68.5	539.0	1,404.38	865.38

จากการเปรียบเทียบผลลัพธ์ในตารางที่ 5.4 และ 5.5 จะเห็นว่าโมเดล LSTM + TCM<sub>CNN</sub> มีความแม่นยำในการทำนายใกล้เคียงกันเมื่อใช้ในการจำลองการเทรดและการเทรดจริง แต่เมื่อดูที่ผลกำไรจากการเทรดพบว่า ในการจำลองการเทรดสามารถสร้างผลกำไรได้มากกว่าในการเทรดจริงอยู่ค่อนข้างมาก ผลที่ออกมาเช่นนี้เกิดจากมีบางช่วงเวลาที่นักลงทุนไม่ได้ส่งคำสั่งซื้อขาย และในบางช่วงเวลานักลงทุนไม่ได้กำหนดเงินลงทุนในแต่ละรอบที่ลงทุนตามที่กลยุทธ์การเทรดได้กำหนดไว้ จึงทำให้ได้ผลกำไรน้อยกว่าการจำลองการเทรด

## 5.2 ข้อเสนอแนะ

จากผลการศึกษาที่ได้ในงานวิจัยนี้สามารถสรุปเป็นประเด็นต่าง ๆ ที่เป็นการเสนอแนะเพื่อการต่อยอดงานวิจัยได้ดังต่อไปนี้

- 1) ในขั้นตอนการเพิ่มประสิทธิภาพให้กับโมเดล LSTM ด้วยการกำหนดค่าพารามิเตอร์ต่าง ๆ ที่เหมาะสมนั้น ในงานวิจัยนี้ได้ทำการหาค่าที่เหมาะสมด้วยการกำหนดค่าที่หลากหลายแล้ววัดผลเพื่อหาค่าที่ให้ผลลัพธ์ที่ดี แต่ค่าที่ได้นั้นอาจจะยังไม่ใช่ค่าพารามิเตอร์ที่ทำให้โมเดลมีประสิทธิภาพที่ดีที่สุด ดังนั้นการต่อยอดงานวิจัยจากจุดนี้คือ การประยุกต์ใช้หลักการ Optimization ต่าง ๆ หรือการคิดค้นอัลกอริทึมแบบ Heuristic มาเพื่อค้นหาค่าพารามิเตอร์ที่เหมาะสมที่สุด ซึ่งทำให้โมเดล LSTM มีประสิทธิภาพความแม่นยำในการทำนายสูงที่สุด
- 2) ด้านการใช้เครื่องมือและกลยุทธ์ที่ได้รับจากงานวิจัยนี้ในการซื้อขายตัวเลือกไปในรานั้น ผู้วิจัยนี้ได้กำหนดกลยุทธ์ในการตัดขาดทุนที่เหมาะสมกับจำนวนเงินลงทุนเริ่มต้นที่ 500 ดอลลาร์สหรัฐ แต่หากนักลงทุนมีเงินลงทุนเริ่มต้นมากกว่าหรือน้อยกว่า 500 ดอลลาร์ก็สามารถเลือกจุดที่จะทำการตัดขาดทุนและสามารถกำหนดจุดตัดขาดทุนที่เหมาะสมได้โดยเทียบเคียงจากตารางที่ 3-1 นอกจากนี้ยังสามารถเพิ่มหรือลดเปอร์เซ็นต์ในการตัดขาดทุนตามความเสี่ยงที่นักลงทุนแต่ละรายสามารถยอมรับได้ แต่ต้องทำการทดสอบแบบย้อนกลับก่อนที่จะนำไปใช้ในการเทรดจริง มิเช่นนั้นอาจทำให้นักลงทุนขาดทุนได้
- 3) ในงานวิจัยนี้ผู้วิจัยได้ใช้ข้อมูลการซื้อขายคาบเวลาราย 5 นาทีในการทำการวิจัยสำหรับนักลงทุนบางคนระยะเวลา 5 นาทีอาจจะไม่เพียงพอในการเตรียมข้อมูลและใช้เครื่องมือเพื่อทำนายทิศทางราคาในคาบเวลาถัดไป ดังนั้นนักลงทุนสามารถปรับไปใช้ข้อมูลในคาบเวลาที่มากขึ้นเช่น คาบเวลาราย 15 นาที หรือ 30 นาที เป็นต้น
- 4) การเทรดในภาวะแวดล้อมจริงด้วยเงินลงทุนจริงนั้น จิตวิทยาในการลงทุนเป็นสิ่งที่สำคัญ นักลงทุนอาจมีความกังวลว่าจะเทรดแพ้และทำให้ขาดทุนจึงทำให้บางครั้งไม่ได้ทำตามข้อกำหนดและเงื่อนไขในการเทรดที่กลยุทธ์ได้กำหนดไว้ เป็นเหตุให้เกิดการขาดทุนดังเช่นในการทดสอบแบบไปข้างหน้าในงานวิจัยนี้ ดังนั้นนักลงทุนจำเป็นต้องทำตามเงื่อนไขและข้อกำหนดที่ระบุไว้ในกลยุทธ์การเทรดและการตัดขาดทุนอย่างมีวินัย
- 5) ในงานวิจัยนี้ผู้วิจัยใช้ข้อมูลการซื้อขายแลกเปลี่ยนเงินตราต่างประเทศคู่สกุลเงิน EURUSD ในการทำวิจัย แต่สิ่งที่ได้จากงานวิจัยนี้สามารถนำไปประยุกต์ได้กับข้อมูล

อื่น ๆ ที่มีระบุไว้ในการซื้อขายตัวเลือกไบนารีเพื่อเพิ่มโอกาสในการลงทุนที่หลากหลายให้กับนักลงทุน ยกตัวอย่างเช่น ข้อมูลการซื้อขายสินทรัพย์ในตลาดหุ้น และตลาดอนุพันธ์ ข้อมูลการซื้อขายแลกเปลี่ยนโลหะมีค่าเช่น เงินและทองคำ ข้อมูลการซื้อขายแลกเปลี่ยนสกุลเงินดิจิทัล เป็นต้น

- 6) ถึงแม้ว่างานวิจัยนี้มีเป้าหมายเพื่อพัฒนาเครื่องมือและกลยุทธ์เพื่อใช้เป็นเครื่องมือในการทำกำไรให้กับนักลงทุนในการซื้อขายตัวเลือกไบนารี แต่โมเดลและวิธีการเพิ่มประสิทธิภาพให้โมเดล LSTM ที่ใช้ในการทำนายทิศทางราคาส่งออกของราคาที่จะเกิดขึ้นในอนาคตนั้นสามารถนำไปประยุกต์ใช้ในการลงทุนประเภทอื่น ๆ ได้ เช่น การลงทุนในตลาดหุ้น ตลาดการซื้อขายเงินตราต่างประเทศหรือการซื้อขายสกุลเงินดิจิทัล เป็นต้น แต่เนื่องจากรูปแบบการลงทุนแต่ละประเภทมีความแตกต่างกัน ดังนั้นอีกด้านหนึ่งของการต่อยอดงานวิจัยนี้คือ การคิดค้นและพัฒนากลยุทธ์การลงทุนและกลยุทธ์ในการตัดขาดทุนที่เหมาะสมกับการลงทุนประเภทอื่น ๆ

## รายการอ้างอิง

- Abarbanell, J. S., & Bushee, B. J. (1997). Fundamental analysis, future earnings, and stock prices. **Journal of Accounting Research**, 35(1), 1–24.
- Abbey, B. S., & Doukas, J. A. (2012). Is technical analysis profitable for individual currency traders? **Journal of Portfolio Management**, 39(1), 142.
- Agatonovic-Kustrin, S., & Beresford, R. (2000). Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. **Journal of Pharmaceutical and Biomedical Analysis**, 22(5), 717–727.
- Anand, S., Chin, W.-N., & Khoo, S.-C. (2001). Charting patterns on price history. In **ACM SIGPLAN Notices** (Vol. 36, pp. 134–145).
- Appel, G. (2003). Become your own technical analyst: how to identify significant market turning points using the Moving Average Convergence-Divergence indicator or MACD. **The Journal of Wealth Management**, 6(1), 27–36.
- Baasher, A. A., & Fakhr, M. W. (2011, October). Forex trend classification using machine learning techniques. In **Proceedings of the 11th WSEAS international conference on Applied computer science** (pp. 41-47).
- Babu, N. R., Babu, C. B. A., Reddy, D. P., & Gowtham, M. (2015). Comparison of ANFIS and ARIMA model for weather forecasting. **Indian Journal of Science and Technology**, 8(S2), 70-73.
- Basheer, I. A., & Hajmeer, M. (2000). Artificial neural networks: fundamentals, computing, design, and application. **Journal of Microbiological Methods**, 43(1), 3–31.
- Bebis, G., & Georgiopoulos, M. (1994). Feed-forward neural networks. **IEEE Potentials**, 13(4), 27–31.
- Bernard, V. L., & Thomas, J. K. (1990). Evidence that stock prices do not fully reflect the implications of current earnings for future earnings. **Journal of Accounting and Economics**, 13(4), 305–340.
- Bollinger, J. (1992). Using bollinger bands. **Stocks & Commodities**, 10(2), 47–51.

- Bontempi, G., Taieb, S. Ben, & Le Borgne, Y.-A. (2012). Machine learning strategies for time series forecasting. **In European Business Intelligence Summer School** (pp. 62–77).
- Brillinger, D. R. (1981). **Time series: data analysis and theory** (Vol. 36). Siam.
- Bulkowski, T. N. (2011). **Encyclopedia of chart patterns** (Vol. 225). John Wiley & Sons.
- Burges, C., Shaked, T., Renshaw, E., Lazier, A., Deeds, M., Hamilton, N., & Hullender, G. (2005). Learning to rank using gradient descent. **In Proceedings of the 22nd international conference on Machine learning** (pp. 89–96).
- Cao, D. Z., Pang, S. L., & Bai, Y., H. (2005). Forecasting exchange rate using support vector machines. **In Proceedings of the 2005 International Conference on Machine Learning and Cybernetics**, 6, 3448–3452.
- Caruana, R., & Niculescu-Mizil, A. (2006, June). An empirical comparison of supervised learning algorithms. **In Proceedings of the 23rd International Conference on Machine Learning** (pp. 161-168).
- Chen, H., Chong, T. T. L., & Duan, X. (2010). A principal-component approach to measuring investor sentiment. **Quantitative Finance**, 10(4), 339–347.
- Chenoweth, T., Obradovic, Z., & Lee, S. (1995). Technical trading rules as a prior knowledge to a neural networks prediction system for the S&P 500 index. In **Northcon 95. IEEE Technical Applications Conference and Workshops Northcon95** (p. 111).
- Chong, T. T. L., & Ng, W. K. (2008). Technical analysis and the London stock exchange: testing the MACD and RSI rules using the FT30. **Applied Economics Letters**, 15(14), 1111–1114.
- Czekalski, P., Niezabitowski, M., & Styblinski, R. (2015, May). ANN for FOREX forecasting and trading. **In Proceedings of the 2015 International Conference on Control Systems and Computer Science (CSCS)**, (pp. 322-328).
- de Almeida, B. J., Neves, R. F., & Horta, N. (2018). Combining Support Vector Machine with Genetic Algorithms to optimize investments in Forex markets with high leverage. **Applied Soft Computing**, 64, 596-613.
- de Brito, R. F., & Oliveira, A. L. (2014, July). Sliding window-based analysis of multiple foreign exchange trading systems by using soft computing techniques. **In Proceedings of**

- the 2014 International Joint Conference on Neural Networks (IJCNN) (pp. 4251-4258).
- Di, X. (2014). Stock Trend Prediction with Technical Indicators using SVM. **Independent WorN Report, Stanford Univ.**
- Eng, M. H., Li, Y., Wang, Q.-G., & Lee, T. H. (2008). Forecast Forex with ANN using fundamental data. **Information Management, Innovation Management and Industrial Engineering (ICIII'08)** (Vol. 1, pp. 279–282).
- Franses, P. H., & Van Griensven, K. (1998). Forecasting exchange rates using neural networks for technical trading rules. **Studies in Nonlinear Dynamics & Econometrics**, 2(4).
- FX Accumulator. (2015). Interpreting a Currency Pair (Online). Available: <http://https://fxaccumulator.com/interpreting-a-currency-pair/> [2019, September 3]
- Golfinvz. (2016). **การวิเคราะห์รูปแบบเทียน** Candle Stick Chart Patterns (Online). Available: <http://https://https://www.investorz.com/metastock-advancedget-amibroker/candle-stick-chart-patterns-t33037.html> [2019, September 1]
- Gorgulho, A., Neves, R., & Horta, N. (2011). Applying a GA kernel on optimizing technical analysis rules for stock picking and portfolio composition. **Expert Systems with Applications**, 38(11), 14072–14085.
- Graves, A. (2012). Supervised sequence labelling. **Supervised Sequence Labelling with Recurrent Neural Networks** (pp. 5–13).
- Graves, A., Mohamed, A., & Hinton, G. (2013). Speech recognition with deep recurrent neural networks. **Acoustics, Speech and Signal Processing (ICASSP)** (pp. 6645–6649).
- Grebenkov, D. S., & Serror, J. (2014). Following a trend with an exponential moving average: Analytical results for a Gaussian model. **Physica A: Statistical Mechanics and its Applications**, 394, 288-303.
- Guides, T. S. (2019). Williams Percent Range Strategy-2 Approaches.
- Gulli, A., & Pal, S. (2017). **Deep Learning with Keras**. Packt Publishing Ltd.
- Handa, R., Shrivastava, A. K., & Hota, H. S. (2019). Financial Time Series Forecasting using Back Propagation Neural Network and Deep Learning Architecture. **Int. J. Recent Technol. Eng**, 8, 3487-3492.
- Hayes, A. (2019). **Moving Average (MA)**. Retrieved from [https:// investopedia.com/](https://investopedia.com/)

- Hearst, M. A., Dumais, S. T., Osuna, E., Platt, J., & Scholkopf, B. (1998). Support vector machines. **IEEE Intelligent Systems and Their Applications**, 13(4), 18–28.
- Hochreiter, S. (1998). The vanishing gradient problem during learning recurrent neural nets and problem solutions. **International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems**, 6(02), 107–116.
- Hsu, C. W., & Lin, C. J. (2002). A comparison of methods for multiclass support vector machines. **IEEE Transactions on Neural Networks**, 13(2), 415–425.
- Huisu, J., Lee, J., Ko, H., & Lee, W. (2018). Predicting bitcoin prices by using rolling window lstm model. **In Proceedings of KDD Data Science in Fintech Workshop**, article 4.
- Hunter, J. S. (1986). The exponentially weighted moving average. **Journal of quality technology**, 18(4), 203-210.
- Hutson, J. K. (1983). TRIX-Triple Exponential Smoothing Oscillator. **Technical Analysis of Stocks and Commodities**, 105–108.
- Ismail, Z., Jamaluddin, F., & Jamaludin, F. (2008). Time series regression model for forecasting Malaysian electricity load demand. **Asian J. Math. Stat**, 1(3), 139–149.
- Jacque, L. L. (2013). **Management and control of foreign exchange risk**. Springer Science & Business Media.
- Kaltwasser, P. R. (2010). Uncertainty about fundamentals and herding behavior in the FOREX market. **Physica A: Statistical Mechanics and its Applications**, 389(6), 1215-1222.
- Kamruzzaman, J., & Sarker, R. (2003a). Comparing ANN based models with ARIMA for prediction of forex rates. **Asor Bulletin**, 22(2), 2–11.
- Kamruzzaman, J., & Sarker, R. A. (2003b). Forecasting of currency exchange rates using ANN: A case study. **In Proceedings of the 2003 International Conference on Neural Networks and Signal Processing**, 2003., Vol. 1, pp. 793–797.
- Kamruzzaman, J., & Sarker, R. A. (2004a). ANN-based forecasting of foreign currency exchange rates. **Neural Information Processing-Letters and Reviews**, 3(2), 49–58.
- Kamruzzaman, J., & Sarker, R. A. (2004b). Application of support vector machine to forex monitoring. **IEEJ Transactions on Electronics, Information and Systems**, 124(10), 1944–1951.



- Kamruzzaman, J., Sarker, R. A., & Ahmad, I. (2003). SVM based models for predicting foreign currency exchange rates. **Third IEEE International Conference on Data Mining**, 557–560.
- Kannan, K. S., Sekar, P. S., Sathik, M. M., & Arumugam, P. (2010). Financial stock market forecast using data mining techniques. **In Proceedings of the International Multiconference of Engineers and Computer Scientists**, 1, 4.
- Kilgallen, T. (2012). Testing the simple moving average across commodities, global stock indices, and currencies. **The Journal of Wealth Management**, 15(1), 82-100.
- Kipruto, G. K., Mung'atu, J. K., Orwa, G. O., & Gathimba, N. W. (2018). Application of artificial neural network (ANN) in modeling foreign currency exchange rates. **International Journal of Scientific Research and Management**, 6(10), M-2018.
- ŁadyŻyński, P., Żbikowski, K., & Grzegorzewski, P. (2013). Stock trading with random forests, trend detection tests and force index volume indicators. **In International Conference on Artificial Intelligence and Soft Computing** (pp. 441-452).
- Lai, R. K., Fan, C.-Y., Huang, W.-H., & Chang, P.-C. (2009). Evolving and clustering fuzzy decision tree for financial time series data forecasting. **Expert Systems with Applications**, 36(2), 3761–3773.
- Lambert, D. R. (1983). Commodity channel index: Tool for trading cyclic trends. **Technical Analysis of Stocks & Commodities**, 1, 47.
- Lavanya, V., & Parveentaj, M. (2013). Foreign currency exchange rate (FOREX) using neural network. **International Journal of Science and Research**, 2(10), 174-177.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. **Nature**, 521(7553), 436.
- Lequeux, P. (2007). Real trading volume and price action in the foreign exchange markets. **In Forecasting Volatility in The Financial Markets** (pp. 187-199).
- Lerman, K., & Gilder, A. (2009). System and method for forecasting fluctuations in future data and particularly for forecasting security prices by news analysis. **Google Patents**.
- Leung, H., & Haykin, S. (1991). The complex backpropagation algorithm. **IEEE Transactions on Signal Processing**, 39(9), 2101–2104.
- Leung, J. M. J., & Chong, T. T. L. (2003). **An empirical comparison of moving average envelopes and Bollinger Bands**. *Applied Economics Letters*, 10(6), 339-341.

- Li, L. K., Shao, S., & Zheleva, T. (2008). A state space search algorithm and its application to learn the short-term foreign exchange rates. **Applied Mathematical Sciences**, 2 (3 5), 1705-1728.
- Liu, P., Qiu, X., & Huang, X. (2016). Recurrent neural network for text classification with multi-task learning. **ArXiv:1605.05101**.
- Lo, A. W., Mamaysky, H., & Wang, J. (2000). Foundations of technical analysis: Computational algorithms, statistical inference, and empirical implementation. **The Journal of Finance**, 55(4), 1705–1765.
- Marshall, B. R., Young, M. R., & Rose, L. C. (2006). Candlestick technical trading strategies: Can they create value for investors?. **Journal of Banking & Finance**, 30(8), 2303-2323.
- Martingale Trading Strategy. (2019). **The Martingale Strategy: A Negative Progression System**. Retrieved from <https://admiralmarkets.com/education/articles/forex-strategy/martingale-strategy-a-negative-progression-system>
- Mazumdar, J., & Harley, R. G. (2008). Recurrent neural networks trained with backpropagation through time algorithm to estimate nonlinear load harmonic currents. **IEEE Trans. Industrial Electronics**, 55(9), 3484–3491.
- McNally, S., Roche, J., & Caton, S. (2018, March). Predicting the price of bitcoin using machine learning. **In Proceedings of the International Conference on Parallel, Distributed and Network-based Processing (PDP)** (pp. 339-343).
- Meyer, D., & Wien, F. H. T. (2015). Support vector machines. **The Interface to Libsvm in Package E1071**, 28.
- Moghaddam, A. H., Moghaddam, M. H., & Esfandyari, M. (2016). Stock market index prediction using artificial neural network. **Journal of Economics, Finance and Administrative Science**, 21(41), 89–93.
- Mucaj, R. (2017). Ann vs arima in time series: exchange rate forecasting. **International Journal of Arts & Sciences**, 10(1), 565-571.
- Müller, U. A. (1991). Specially weighted moving averages with repeated application of the ema operator. **Internal Document UAM**. 1991--10-14, Olsen & Associates, Switzerland.
- Nayak, R. K., Mishra, D., & Rath, A. K. (2015). A Naive SVM-KNN based stock market trend reversal analysis for Indian benchmark indices. **Applied Soft Computing**, 35, 670–680.

- Noble, W. S. (2006). What is a support vector machine? **Nature Biotechnology**, 24(12), 1565.
- Nyoni, T. (2018). Modeling and forecasting Naira/USD exchange rate in Nigeria: A Box-Jenkins ARIMA approach. Munich University Library – Munich Personal (RePEc Archive (MRPA), paper no. 88622.)
- Pascanu, R., Mikolov, T., & Bengio, Y. (2012). Understanding the exploding gradient problem. **CoRR**, Abs/1211.5063, 2.
- Pathberiya, H. A., Tilakaratne, C. D., & Hansen, L. L. (2017, September). An intelligent system for forex trading: Hybrid ANN with GARCH and intrinsic mode functions. **In 2017 Intelligent Systems Conference (IntelliSys)** (pp. 436-445).
- Pee, M. H. (2001). Trend detection index. **Technical Analysis of Stocks and Commodities**, 19(10), 54–61.
- Pongsena, W., Ditsayabut, P., Kerdprasop, N., & Kerdprasop, K. (2018). An analysis of the co-movement of price change volatility in forex market. **In Proceedings of the World Congress on Engineering 2018**, 1.
- Raina, R., Madhavan, A., & Ng, A. Y. (2009). Large-scale deep unsupervised learning using graphics processors. **In Proceedings of the 26th Annual International Conference on Machine Learning** (pp. 873–880).
- Rani, S. J., & Haragopal, V. V. (2016). Forecasting Exchange Rates using Neural Networks. **International Journal of Information & Computation Technology**, 6, 35-44.
- Russell, S., & Yoon, V. (2005). Heterogeneous agent development: A multi-agent system for testing stock trading algorithms. **AMCIS 2005 Proceedings**, 283.
- Shu, C., He, D., & Cheng, X. (2015). One currency, two markets: the renminbi's growing influence in Asia-Pacific. **China Economic Review**, 33, 163–178.
- Scholkopf, B., & Smola, A. J. (2001). **Learning with kernels: support vector machines, regularization, optimization, and beyond**. MIT press.
- Sidehabi, S., Indrabayu, W., & Tandingan, S. (2016, November). Statistical and machine learning approach in forex prediction based on empirical data. **In Proceedings of the International Conference on Computational Intelligence and Cybernetics (CYBERNETICSCOM)**, (pp. 63-68).

- Stankevičiūtė, J., Maknickienė, N., & Maknickas, A. (2014). Investigation of exchange market prediction model based on highlow daily data. **In Proceedings of the 2014 The 8th International Scientific Conference "Business and Management"**, 15–16.
- Stasinakis, C., & Sermpinis, G. (2014). Financial forecasting and trading strategies: a survey. **In Computational Intelligence Techniques for Trading and Investment** (pp. 42-60). Routledge.
- Suykens, J. A. K., & Vandewalle, J. (1999). Least squares support vector machine classifiers. **Neural Processing Letters**, 9(3), 293–300.
- Thu, T. N. T., & Xuan, V. D. (2018a). Using support vector machine in FoRex predicting. **In Proceedings of the 2018 IEEE International Conference on Innovative Research and Development (ICIRD)** (pp. 1-5).
- Thu, T. N. T., & Xuan, V. D. (2018b). Supervised support vector machine in predicting foreign exchange trading. **International Journal of Intelligent Systems and Applications**, 10(9), 48.
- Trading Strategy Guides (2019). **Williams Percent Range Strategy - 2 Approaches**. Retrieved from <https://tradingstrategyguides.com/williams-percent-range-strategy>
- Tsay, R. S. (2005). **Analysis of financial time series** (Vol. 543). John Wiley & Sons.
- Weerathunga, H. P. S. D., & Silva, A. T. P. (2018, September). DRNN-ARIMA approach to short-term trend forecasting in forex market. **In Proceedings of the 2018 18th International Conference on Advances in ICT for Emerging Regions (ICTer)** (pp. 287-293).
- Wei, W. W. S. (2006). Time series analysis. **The Oxford Handbook of Quantitative Methods in Psychology: Vol. 2**.
- Xiao, Y., Xiao, J., Liu, J., & Wang, S. (2014). A multiscale modeling approach incorporating ARIMA and ANNs for financial market volatility forecasting. **Journal of Systems Science and Complexity**, 27(1), 225-236.
- Yao, J., & Tan, C. L. (2000). A case study on using neural networks to perform technical forecasting of forex. **Neurocomputing**, 34(1–4), 79–98.

Yu, L., Wang, S., & Lai, K. K. (2007). A hybrid ga-based svm model for foreign exchange market tendency exploration. **Foreign-Exchange-Rate Forecasting with Artificial Neural Networks**, 155–173.





ภาคผนวก

บทความวิจัยที่ได้รับการตีพิมพ์เผยแพร่

มหาวิทยาลัยเทคโนโลยีสุรนารี

1. **ชื่อบทความ:** The Co-Movement of Price Change Volatility in Foreign Exchange Market: An Empirical Statistic Based Approach

**แหล่งตีพิมพ์:** Book Chapter in H.A. Sulaiman et al. (Eds.), Lecture Notes in Computer, Communication and Control Technology, Malaysia Technical Scientist Association (eISBN: 978-967-2348-08-5)

**หน้า:** 246 – 251

#### บทคัดย่อ

Foreign exchange or Forex is the largest global distribution market in the world where all currencies are traded. This market not only produces profits, or losses, for the currency traders but also influences the exchange rate of currencies across the world. This research focuses on using the historical data of Forex to identify the strength of the association between the currencies pairwise based on statistical analysis approaches. At the end of the analysis, the top ten strongest relations of the co-movement between the currency pairs are identified. In addition, the results of our analysis have confirmed that these relations are significant correlations. The knowledge discovered in this research is beneficial for the Forex traders in terms of enhancing their competence in order to increase their trading profits.

มหาวิทยาลัยเทคโนโลยีสุรนารี

2. **ชื่อบทความ:** An Analysis of the Co-movement of Price Change Volatility in Forex Market  
**แหล่งตีพิมพ์:** Proceedings of the World Congress on Engineering 2018 Vol 1  
**หน้า:** 218 – 222

### บทคัดย่อ

Foreign exchange or Forex is the largest global distribution market in the world where all currencies are traded. This market not only produces profits or losses for the traders but also influences the exchange rate of currencies around the world. This research focuses on using the historical data of Forex to identify the strength of the relation and the currency co-movement between pairwise of currencies based on statistical analysis approaches. The empirical results have identified the top ten strongest relations between the currency pairs. In addition, the strong co-movement of price change between the EURUSD and others currency pairwise are identified. The results of our analysis are confirmed that these relations are significant correlations. The knowledge discovered in this research is beneficial for the Forex traders in terms of providing the empirical statistic evidences in order enhance their knowledge. This will make it possible to increase their trading profits.



3. **ชื่อบทความ:** Developing A Forex Expert Advisor Based on Japanese Candlestick Patterns and Technical Trading Strategies

**แหล่งตีพิมพ์:** International Journal of Trade, Economics and Finance, Vol. 9, No. 6, December 2018

**หน้า:** 238 – 243

### บทคัดย่อ

Foreign Exchange or Forex market is considered the largest trading market in the world. Trading in the Forex market, traders need to have a good trading strategy in order to make profits and be a successful trader. However, there are some factors that create limitations for many traders, such as, trading behaviors, emotions, and time. The development of Expert Advisor or EA allows automation of the analytical and trading processes under the MT4 platform. An EA with a good trading instruction can provide the ability to make profits and fulfill the limitations of human trades. In this research, we propose a novel EA that performs an automatically trade following the trading strategy. Our trading strategy is the combination between technical analysis including the ancient but powerful Japanese candlestick patterns and the modern technical indicators. The results of the evaluation by using the strategy tester function in the MT4 platform reveal that the proposed EA performs a good performance as it makes approximately 150 percent growth in a year. In addition, we perform an extensive experimentation in order to compare the performance of the proposed EA with the existing two EAs. The results show that the proposed EA have a better performance than both existing EAs testing in the same period of time and currency pairwise.

4. **ชื่อบทความ:** Deep Learning for Financial Time-Series Data Analytics: An Image Processing Based Approach

**แหล่งตีพิมพ์:** International Journal of Machine Learning and Computing, Vol. 10, No. 1 (January 2020)

**หน้า:** 51 – 56

### บทคัดย่อ

Forex or Foreign Exchange is the largest financial market with a huge amount of daily trading volume. Traditionally, the tool or strategy that Forex traders usually used is divided into Fundamental Analysis and Technical Analysis. Presently, the world computational technological advance, such as Artificial Intelligence plays a significant role in the financial domain. The various existing research applies Machine Learning and Deep Learning to develop powerful models that can be used as a tool for traders in order to develop their trading tools or strategies. However, most existing models are developed targeting for the stock market. There are still lag of research that applies the modern Machine Learning or Deep Learning for predicting the movement of the price in the Forex market. In this paper, we propose a novel predicting model based on Deep Convolutional Neural Network that can be effectively used as a tool in order to make the profits for Forex traders. We evaluate the performance of the proposed CNN model from two perspectives. The first perspective is to evaluate the accuracy of the prediction and the second perspective is to evaluate the ability to make profits. The experimental results show that in term of accuracy of the prediction, our proposed CNN model provide the accuracy up to approximately 77%. This result is similar to the C5.0 algorithm, which is a rule-based algorithm of Machine Learning. The results are different in a trivial fraction. In terms of financial perspective, the proposed CNN model performs well as it produces approximately \$69K for one and a half year (from January 2017 to September 2018).

5. **ชื่อบทความ:** Development of A Model for Predicting the Direction of Daily Price Changes in the Forex Market Using Long Short-Term Memory  
**แหล่งตีพิมพ์:** International Journal of Machine Learning and Computing, Vol. 10, No. 2 (February 2020)

### บทคัดย่อ

Forex is the largest global financial market in the world. Traditionally, fundamental and technical analysis are strategies that the Forex traders often used. Nowadays, advanced computational technology, Artificial Intelligence (AI) has played a significant role in the financial domain. Various applications based on AI technologies particularly machine learning and deep learning have been constantly developed. As the historical data of the Forex are time-series data where the values from the past affect the values that will appear in the future. Several existing works from other domains of applications have proved that the Long-Short Term Memory (LSTM), which is a particular kind of deep learning that can be applied to modeling time series, provides better performance than traditional machine learning algorithms. In this paper, we aim to develop a powerful predictive model targeting to predicts the daily price changes of the currency pairwise in the Forex market using LSTM. Besides, we also conduct an extensive experiment with the intention to demonstrate the effect of various factors contributing to the performance of the model. The experimental results show that the optimized LSTM model accurately predicts the direction of the future price up to 61.25 percent.

## ประวัติผู้เขียน

ชื่อ-นามสกุล	นายวรรณะ พงษ์เสนา
วัน-เดือน-ปี เกิด	12 ธันวาคม พ.ศ. 2526
สถานที่เกิด	อำเภอเมือง จังหวัดนครราชสีมา
สถานที่อยู่ปัจจุบัน	บ้านเลขที่ 511/47 หมู่บ้านธนบดี ซอยสามยอด ตำบล สุรนารี อำเภอเมืองนครราชสีมา จังหวัดนครราชสีมา รหัสไปรษณีย์ 30000
ตำแหน่งหน้าที่การงาน	อาจารย์
สถานที่ทำงานปัจจุบัน	มหาวิทยาลัยราชภัฏศรีสะเกษ อำเภอเมือง จังหวัดศรีสะเกษ รหัสไปรษณีย์ 33000
อีเมล	pongseana@hotmail.com
เบอร์โทรศัพท์ (มือถือ)	090-319-9889
ประวัติการศึกษา	
พ.ศ. 2555	วิศวกรรมศาสตรมหาบัณฑิต (วิศวกรรมคอมพิวเตอร์) สาขาวิชาวิศวกรรมคอมพิวเตอร์ มหาวิทยาลัยเทคโนโลยีสุรนารี จังหวัดนครราชสีมา
พ.ศ. 2552	วิศวกรรมศาสตรบัณฑิต (วิศวกรรมคอมพิวเตอร์) สาขาวิชาวิศวกรรมคอมพิวเตอร์ มหาวิทยาลัยเทคโนโลยีสุรนารี จังหวัดนครราชสีมา