



## โครงการ

# การเรียนการสอนเพื่อเสริมประสบการณ์

ชื่อโครงการ การศึกษาเชิงเปรียบเทียบของสถาปัตยกรรมโครงข่ายประสาทเทียมเชิงลึก  
ในการทำนายแนวโน้มรายวันของอัตราแลกเปลี่ยนคู่เงินดอลลาร์  
สหรัฐอเมริกากับเยนญี่ปุ่น

A comparative study of deep neural network architectures  
for forex daily trend prediction on USD/JPY currency pair

ชื่อนิสิต นายบุญยวัศ ศรีสมพงษ์ 5833639723

นายสรวิศ เลิศอำไพสกุลวงศ์ 5833664323

ภาควิชา คณิตศาสตร์และวิทยาการคอมพิวเตอร์

สาขาวิชา วิทยาการคอมพิวเตอร์

ปีการศึกษา 2561

คณะวิทยาศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

บทคัดย่อและแฟ้มข้อมูลฉบับเต็มของโครงงานทางวิชาการที่เก็บอยู่ในคลังข้อมูลปัญญา (CUIR)

เป็นแฟ้มข้อมูลของนิสิตเจ้าของโครงงานทางวิชาการที่ส่งผ่านทางคณะที่สังกัด

The abstract and full text of senior projects in Chulalongkorn University Intellectual Repository(CUIR)  
are the senior project authors' files submitted through the faculty.

การศึกษาเชิงเปรียบเทียบของสถาปัตยกรรมโครงข่ายประสาทเทียมเชิงลึกในการทำนายแนวโน้มรายวัน  
ของอัตราแลกเปลี่ยนคู่เงินดอลลาร์สหรัฐอเมริกากับเยนญี่ปุ่น

นาย บุญยวัศ ศรีสมพงษ์  
นาย สรวิส เลิศอำไพสกุลวงศ์

โครงการนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิทยาศาสตรบัณฑิต  
สาขาวิทยาการคอมพิวเตอร์ ภาควิชาคณิตศาสตร์และวิทยาการคอมพิวเตอร์  
คณะวิทยาศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย  
ปีการศึกษา 2561  
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

A comparative study of deep neural network architectures for forex daily trend  
prediction on USD/JPY currency pair

Bunyawat Srisompong

Sorawit Lertumpaisakulwong

A Project Submitted in Partial Fulfillment of the Requirements  
for the Degree of Bachelor of Science Program in Computer Science

Department of Mathematics and Computer Science

Faculty of Science

Chulalongkorn University

Academic Year 2018

Copyright of Chulalongkorn University



นายบุญยวัศ ศรีสมพงษ์, นายสรวิศ เลิศอำไพสกุลวงศ์:การศึกษาเชิงเปรียบเทียบของสถาปัตยกรรมโครงข่ายประสาทเทียมเชิงลึกในการทำนายแนวโน้มรายวันของอัตราแลกเปลี่ยนคู่เงินดอลลาร์สหรัฐอเมริกากับเยนญี่ปุ่น. (A comparative study of deep neural network architectures for forex daily trend prediction on USD/JPY currency pair) อ.ที่ปรึกษาโครงการ : อ.ดร.นฤมล ประทานวณิช, 56 หน้า.

โครงการวิจัย เรื่อง “การศึกษาเชิงเปรียบเทียบของสถาปัตยกรรมโครงข่ายประสาทเทียมเชิงลึกในการทำนายแนวโน้มรายวันของอัตราแลกเปลี่ยนคู่เงินดอลลาร์สหรัฐอเมริกากับเยนญี่ปุ่น” มีวัตถุประสงค์ คือ เพื่อเปรียบเทียบสถาปัตยกรรม 4 แบบ คือ 1. Feed Forward Neural Network 2. Convolutional Neural Network 3. Long Short-Term Memory และ 4. Convolutional Long Short-Term Memory เพื่อประเมินความทนทานของโมเดลคณะผู้จัดทำได้ฝึกสอนแต่ละโมเดล 10 ครั้งด้วยการเริ่มต้นแบบสุ่ม คณะผู้จัดทำได้ประเมินการทำงานของแต่ละสถาปัตยกรรมทั้งในด้านความแม่นยำในการจำแนกและกำไรที่ได้รับทั้งหมดโดยยึดการตัดสินใจของโมเดล โดยทุกสถาปัตยกรรมสามารถให้ผลได้ดีกว่าเทคนิคการเรียนรู้ของเครื่องแบบดั้งเดิมอย่างเช่น random forest และ SVM ในทั้งสองด้าน ซึ่ง CNN แบบ 64 ตัวกรองสามารถให้ผลลัพธ์การทำนายได้ดีที่สุด โดยสามารถทำกำไรได้ 28% โดยประมาณจากกำไรทั้งหมด 93,841 จุดโดยไม่เกิดการขาดทุนในการทดลองทั้ง 10 การทดลอง สถาปัตยกรรมที่รองลงมาคือ FFNN ในขณะที่สถาปัตยกรรมอื่น ๆ รวมทั้งเทคนิคการเรียนรู้ของเครื่องแบบดั้งเดิมที่ถูกทดสอบในโครงการนี้สามารถทำกำไรได้น้อยกว่าหรือเกิดการขาดทุนในบางการทดลอง

ภาควิชา...คณิตศาสตร์และวิทยาการคอมพิวเตอร์...ลายมือชื่อนิสิต..... *Pomyat S...*  
ลายมือชื่อนิสิต..... *สรวิศ เลิศอำไพสกุลวงศ์*  
สาขาวิชา...วิทยาการคอมพิวเตอร์...ลายมือชื่อ อ.ที่ปรึกษาโครงการ..... *น.ย.*  
ปีการศึกษา.....2561.....

# # 5833639723, 5833664323: MAJOR MATHEMATICS / COMPUTER SCIENCE


KEYWORDS : Neural Network / FOREX / Trend Prediction

FIRSTNAME LASTNAME, Sorawit Lertumpaisakulwong: A comparative study of deep neural network architectures for forex daily trend prediction on USD/JPY currency pair. ADVISOR : Naruemon Pratanwanich, Ph.D., 56 pp.

The objective of this project is to compare four neural network architectures; Feed Forward Neural Networks (FFNN), Convolutional Neural Networks (CNN), Long Short-Term Memory networks (LSTM) and Convolutional Long Short-Term Memory networks for forex trends prediction. To assess model robustness, we trained each model ten times with random initialisations. We evaluated the performance of each architecture in the aspect of classification accuracy of predicting forex trends and the traditional machine learning techniques such as random forests and support vector machines (SVMs) in both aspects. The CNN with 64 filters yielded the best prediction; making approximately 28% of the total profit of 93,841 points without loss across the ten experiments, followed by FFNNs, while other neural network architectures including the traditional models tested in this project gained less profit and sometimes experienced loss.

Department : Mathematics and Computer Science..... Student's Signature 

Student's Signature Sorawit Lertumpaisakulwong

Field of Study : ...Computer Science..... Advisor's Signature 

Academic Year : ...2018.....

## กิตติกรรมประกาศ

โครงการการศึกษาเชิงเปรียบเทียบของสถาปัตยกรรมโครงข่ายประสาทเทียมเชิงลึกในการทำนายแนวโน้มรายวันของอัตราแลกเปลี่ยนคู่เงินดอลลาร์สหรัฐอเมริกากับเยนญี่ปุ่นสามารถสำเร็จลุล่วงไปได้ด้วยความอนุเคราะห์อย่างยิ่งของ อาจารย์ ดร.นฤมล ประทานวณิช อาจารย์ที่ปรึกษาโครงการ และ ผู้ช่วยศาสตราจารย์ ดร.จิตยา หวานวารี ซึ่งเสียสละเวลาให้ความรู้ คำปรึกษา และสนับสนุนด้วยความเอาใจใส่อย่างยิ่งจนทำให้โครงการสำเร็จลุล่วงได้ด้วยดี

ขอขอบพระคุณ กรรมการคุมสอบ ผู้ช่วยศาสตราจารย์ ดร.มนนัธ พงษ์พานิช และ อาจารย์ โชติรส สุรพลชัย ผู้เป็นกรรมการคุมสอบที่ช่วยแนะแนวทางต่าง ๆ ที่เป็นประโยชน์ต่อโครงการนี้

สุดท้ายขอขอบคุณทุกท่านที่ไม่ได้กล่าวนามไว้ข้างต้น ที่ให้การสนับสนุนในด้านต่าง ๆ ที่คอยผลักดันให้โครงการสำเร็จลุล่วงไปได้ด้วยดี

## สารบัญ

กิตติกรรมประกาศ.....	ฉ
สารบัญตาราง .....	ญ
สารบัญภาพ.....	ฎ
บทที่ 1 บทนำ.....	1
1.1    ความเป็นมาและเหตุผลการวิจัย .....	1
1.2    วัตถุประสงค์ของการวิจัย .....	5
1.3    ขอบเขตการวิจัย.....	5
1.4    ขั้นตอนการวิจัย.....	5
1.5    ประโยชน์ที่คาดว่าจะได้รับ .....	5
บทที่ 2 งานวิจัยที่เกี่ยวข้อง .....	7
2.1    การทำนายในตลาดแลกเปลี่ยนเงินตราต่างประเทศ.....	7
2.2    การทำนายอนุกรมเวลาทางการเงิน.....	7
2.3    โครงข่ายประสาทเทียมเชิงลึกสำหรับการทำนายอนุกรมเวลาทางการเงิน.....	8
บทที่ 3 การรวบรวมและจัดเตรียมข้อมูล.....	15
3.1    ขั้นตอนการเก็บข้อมูล.....	15
3.2    อินดิเคเตอร์ .....	16
3.3    การปรับช่วงของข้อมูล.....	20
3.4    ลำดับของอินดิเคเตอร์ (sequence of indicators).....	20
บทที่ 4 วิธีการวิจัย.....	22
4.1    ระบบการลงทุนของงานวิจัย .....	22
4.2    โครงสร้างของโครงข่ายประสาทเทียม.....	22
4.3    การทดลอง .....	23



4.4	การวัดผลการวิจัย.....	24
บทที่ 5	ผลการวิจัย.....	25
5.1	ผลของการดำเนินการวิจัย.....	25
5.2	เปรียบเทียบความสามารถของแต่ละสถาปัตยกรรม.....	28
5.3	สรุปผลของการดำเนินการวิจัย.....	30
บทที่ 6	ข้อสรุปและข้อเสนอแนะ.....	31
6.1	สรุปผลการดำเนินงาน.....	31
6.2	ปัญหาของงานวิจัยและวิธีการแก้ไข.....	31
	รายการอ้างอิง.....	32
	แบบเสนอหัวข้อโครงการ รายวิชา 2301399 Project Proposal.....	35
	ปีการศึกษา 2561.....	35
	เอกสารอ้างอิง.....	42
	ประวัติผู้เขียน.....	43



## สารบัญตาราง

	หน้า
ตารางที่ 3.1 สูตรการคำนวณและช่วงระยะเวลาของพีเจอร์ที่ใช้เป็นข้อมูลนำเข้า .....	18
ตารางที่ 5.1 สรุปโมเดลที่ดีที่สุดจากความถูกต้องเฉลี่ย.....	29
ตารางที่ 5.2 สรุปโมเดลที่ดีที่สุดจากกำไรเฉลี่ย .....	30

## สารบัญญภาพ

	หน้า
รูปที่ 1.1 รูปแบบแท่งขาขึ้น .....	2
รูปที่ 1.2 รูปแบบแท่งขาลง .....	3
รูปที่ 1.3 แนวโน้มขาขึ้นแบบที่ 1 .....	3
รูปที่ 1.4 แนวโน้มขาขึ้นแบบที่ 2 .....	4
รูปที่ 1.5 แนวโน้มขาลงแบบที่ 1 .....	4
รูปที่ 1.6 แนวโน้มขาลงแบบที่ 2 .....	4
รูปที่ 2.1 เซลล์ประสาท กับ เซลล์ประสาทเทียม .....	8
รูปที่ 2.2 ตัวอย่างโครงสร้างของโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า .....	9
รูปที่ 2.3 ตัวอย่างโครงสร้างของโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าเชิงลึก .....	10
รูปที่ 2.4 ตัวอย่างโครงสร้างของโครงข่ายประสาทเทียมตอนโวลูชัน .....	12
รูปที่ 2.5 ตัวอย่างโครงสร้างของหน่วยความจำระยะสั้นแบบยาว .....	13
รูปที่ 3.1 วิธีการเก็บข้อมูล .....	15
รูปที่ 3.2 ขั้นตอนการตั้งชื่อไฟล์ที่จะดาวน์โหลด .....	16
รูปที่ 3.3 ตัวอย่างข้อมูล 3 แถวแรก .....	17
รูปที่ 3.4 ข้อมูลก่อนการปรับให้อยู่ในรูปของลำดับของดินดิเคเตอร์ .....	20
รูปที่ 3.5 การเรียงข้อมูลให้อยู่ในรูปแบบของลำดับแบบที่ 1 ของวันที่ n .....	21
รูปที่ 3.6 การเรียงข้อมูลให้อยู่ในรูปแบบของลำดับแบบที่ 2 ของวันที่ n .....	21
รูปที่ 4.1 ระบบการลงทุนของงานวิจัย .....	22
รูปที่ 4.2 การทดลองฝึกสอนโมเดล 10 ครั้ง .....	24
รูปที่ 5.1 แสดงการเปรียบเทียบค่าความถูกต้อง .....	27
รูปที่ 5.2 แสดงการเปรียบเทียบกำไร .....	28

# บทที่ 1

## บทนำ

### 1.1 ความเป็นมาและเหตุผลการวิจัย

ตลาดแลกเปลี่ยนเงินตราต่างประเทศ (Foreign Exchange Market) เป็นตลาดการเงินที่ใหญ่ที่สุดในบรรดาตลาดการลงทุนทั้งหมด ด้วยการซื้อขายมากกว่าหนึ่งล้านล้านดอลลาร์สหรัฐต่อวัน [1] การทำนายอัตราแลกเปลี่ยนเงินตราต่างประเทศนั้น ทำให้เกิดการทดลองและทฤษฎีต่าง ๆ เป็นจำนวนมาก ซึ่งอัตราแลกเปลี่ยนเงินตราต่างประเทศนั้นจะขึ้นกับหลาย ๆ ปัจจัยด้วยกัน ไม่ว่าจะเป็น สภาพเศรษฐกิจ การเมืองหรือแม้แต่ปัจจัยทางด้านจิตวิทยา ปัจจัยเหล่านี้ค่อนข้างซับซ้อน ดังนั้นการทำนายการเปลี่ยนแปลงของอัตราแลกเปลี่ยนจึงทำได้ยาก มีนักวิจัยและนักลงทุนหลายคนได้พยายามอย่างต่อเนื่องเพื่อที่จะอธิบายการเคลื่อนที่ของอัตราแลกเปลี่ยน ทำให้เกิดการพัฒนาวิธีทำนายหลากหลายรูปแบบขึ้น การวิเคราะห์ทางเทคนิค (technical analysis) และการวิเคราะห์ปัจจัยพื้นฐาน (fundamental analysis) เป็นวิธีการหลักที่นิยมในการทำนายทางการเงิน ซึ่งเหมือนกับตลาดการลงทุนอื่น ๆ อย่างเช่น ตลาดหุ้น ตลาดแลกเปลี่ยนเงินตราระหว่างประเทศมีรูปแบบเฉพาะตัว การหาโมเดลเพื่อให้เหมาะสมกับรูปแบบของตลาดแลกเปลี่ยนเงินตราต่างประเทศจึงมีความน่าสนใจ

การวิเคราะห์ทั้ง 2 ประเภท มีความแตกต่างกัน ดังนี้ การวิเคราะห์ปัจจัยพื้นฐาน นักลงทุนจะต้องพิจารณาถึงสถานะทางการเงินของประเทศนั้น ๆ และศึกษาผลกระทบของอุปสงค์และอุปทานของแต่ละคู่เงินส่วนการวิเคราะห์ทางเทคนิคนั้นจะพิจารณาตัวแปรต่าง ๆ ตัวอย่างเช่น ทิศทางการเคลื่อนที่ของอัตราแลกเปลี่ยน ซึ่งสามารถระบุได้โดยการใช้ตัวชี้วัดเชิงเทคนิค (technical indicators) ต่าง ๆ รูปแบบของกราฟปริมาณการซื้อขาย เป็นต้น สุดท้ายผลการวิเคราะห์ที่ได้จะนำมาใช้ตัดสินใจในการลงทุน

งานวิจัยที่ผ่านมาได้มีการนำตัวชี้วัดหรือราคาในอดีตมาใช้เป็นข้อมูลขาเข้า (features) ของตัวแบบ (models) Jingtao Yao และ Chew Lim Tan [2] ได้ประยุกต์ใช้โครงข่ายประสาทเทียม (artificial neural networks) ในการทำนายอัตราแลกเปลี่ยนระหว่างดอลลาร์สหรัฐกับอีก 5 สกุลเงินหลัก โดยได้มีการทำการทดลองบนโมเดลที่ใช้อัตราแลกเปลี่ยนรายสัปดาห์ในอดีตและปัจจุบันเพื่อทำนายอัตราแลกเปลี่ยนในสัปดาห์ข้างหน้า และได้ทำการทดลองบนโมเดลที่ใช้อินดิเคเตอร์เชิงเทคนิค ซึ่งโมเดลที่ใช้อินดิเคเตอร์ได้ผลลัพธ์ที่ดีกว่าโมเดลที่ใช้ราคาในอดีตเพียงอย่างเดียวอย่างเห็นได้ชัด Patel และคณะ [3] ได้ทำการทดลองกับหุ้น โดยใช้อินดิเคเตอร์เป็นข้อมูลนำเข้าเช่นเดียวกันแต่มีการกำหนดเงื่อนไขเพื่อเปลี่ยนตัวเลขที่เป็นจำนวนจริงของค่าอินดิเคเตอร์ไปเป็นค่า +1 หมายถึงแนวโน้ม

ขาขึ้น หรือ -1 หมายถึงแนวโน้มขาลง จากนั้นถึงนำไปใช้งานกับโมเดลต่างๆ คือ Feed forward model, SVM model, Random forest และ Naive-Bayes classifier ซึ่งได้ความแม่นยำสูงถึง 90%

ข้อมูลขาออกที่จะทำนาย (Target) แบ่งได้หลัก ๆ 2 ประเภท คือ การทำนายแนวโน้มและการทำนายราคาเป้าหมาย โดยการทำนายแนวโน้มคือการทำนายทิศทางของตลาด มีงานวิจัยที่นำอินดิเคเตอร์มาใช้ในการทำนายแนวโน้มในอนาคต แต่ผลสรุปของการทดลองนี้กล่าวว่า โครงข่ายประสาทเทียมให้ผลลัพธ์แย่ที่สุด [3] ซึ่งผู้จัดทำคิดว่าเป็นผลมาจากการออกแบบโครงข่ายประสาทเทียมที่ยังไม่ดีเท่าที่ควร ในส่วนการทำนายราคาเป้าหมาย คือการใช้ข้อมูลในอดีตมาคาดการณ์ราคาในอนาคต โดยมีงานวิจัยที่นำราคาและอินดิเคเตอร์ในอดีตมาใช้ในการทำนายเป้าหมายของราคาในอนาคต [2]


จากงานวิจัยที่ผ่านมา มีงานที่ทำการทดลองในตลาดหุ้นและตลาดแลกเปลี่ยนเงินตราต่างประเทศซึ่งมีทั้งการทำนายแนวโน้มและการทำนายราคาเป้าหมาย โดยมีหลายโมเดลถูกนำมาทดลองหนึ่งในนั้นก็คือ โครงข่ายประสาทเทียมเชิงลึก (deep neural networks) ในโครงการนี้ผู้ดำเนินการสนใจที่จะนำโครงข่ายประสาทเทียมเชิงลึกมาเปรียบเทียบความสามารถในการทำนายแนวโน้มของราคาในตลาดแลกเปลี่ยนเงินตราต่างประเทศของคู่เงินดอลลาร์สหรัฐอเมริกากับเยนญี่ปุ่น โดยมีรูปแบบข้อมูลขาเข้าเป็นอินดิเคเตอร์หรือราคาในอดีต และมีรูปแบบข้อมูลขาออกเป็นแนวโน้มของอัตราแลกเปลี่ยน

### ลักษณะข้อมูล

ชุดข้อมูลที่ใช้ นำมาจากโปรแกรม Metatrader 4 โดยการใช้ภาษา MQL4 ในการเข้าถึงข้อมูล ข้อมูลที่นำมาใช้ประกอบด้วย ราคาเปิด ราคาปิด ราคาสูงสุด ราคาต่ำสุด และ อินดิเคเตอร์

### รูปแบบกราฟแท่งเทียน

1. แท่งเทียนสีขาวแสดงถึงราคาปิดอยู่สูงกว่าราคาเปิด เรียกว่า แท่งขาขึ้น ดังรูปที่ 1



รูปที่ 1.1 รูปแบบแท่งขาขึ้น

2. แท่งเทียนสีดำแสดงถึงราคาปิดอยู่ต่ำกว่าราคาเปิด หรือจะเรียกว่า แท่งขาลง




รูปที่ 1.2 รูปแบบแท่งขาลง


### แนวโน้มราคา

ในโครงการนี้ จะสนใจที่ราคาเปิดเป็นหลัก สามารถพิจารณาแนวโน้มจากราคาเปิดได้ 2 แบบ ดังนี้

1. พิจารณากราฟราคาเปิดวันที่ T ถ้าราคาเปิดของวันที่ T+1 อยู่สูงกว่าราคาเปิดของวันที่ T เหตุการณ์นี้จะเรียกว่า วันที่ T มีแนวโน้มขาขึ้น ซึ่งเป็นไปได้ 2 ลักษณะดังรูปที่ 3 และ 4




รูปที่ 1.3 แนวโน้มขาขึ้นแบบที่ 1

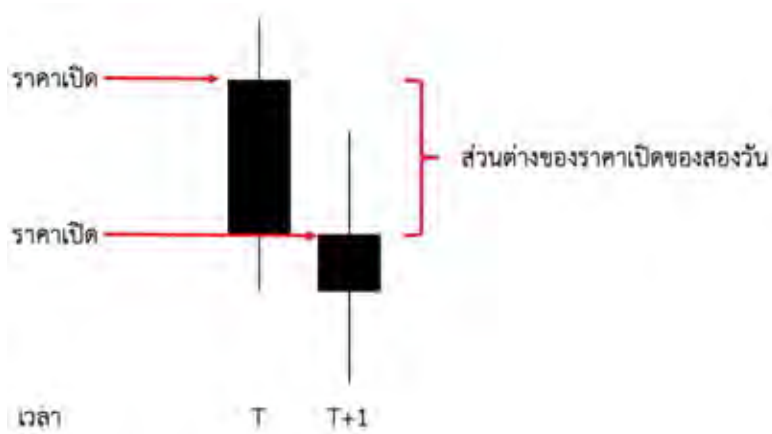


รูปที่ 1.4 แนวโน้มขาขึ้นแบบที่ 2

2. พิจารณากราฟราคาเปิดวันที่ T ปรากฏว่าราคาเปิดของวันที่ T+1 อยู่ต่ำกว่าราคาเปิดของวันที่ T เหตุการณ์นี้จะเรียกว่า วันที่ T มีแนวโน้มขาลง



รูปที่ 1.5 แนวโน้มขาลงแบบที่ 1



รูปที่ 1.6 แนวโน้มขาลงแบบที่ 2



## 1.2 วัตถุประสงค์ของการวิจัย

เพื่อเปรียบเทียบสถาปัตยกรรมของโครงข่ายประสาทเทียม 4 แบบ ได้แก่ 1. Feed Forward Neural Network 2. Convolutional Neural Network 3. Long Short-Term Neural Network และ 4. Convolutional Long Short-Term Memory Neural Network ในการทำนายแนวโน้มของอัตราการแลกเปลี่ยนของคู่เงินดอลลาร์สหรัฐอเมริกากับเยนญี่ปุ่น

## 1.3 ขอบเขตการวิจัย

1. ทำนายแนวโน้มในแต่ละวัน (ขึ้นหรือลง) โดยจะเปิดและปิดคำสั่งซื้อขายที่ราคาเปิดของทุกวัน
2. ใช้ชุดข้อมูลซึ่งประกอบด้วย ราคาเปิด ราคาปิด ราคาสูงสุด ราคาต่ำสุดและอินดิเคเตอร์ โดยจะใช้ข้อมูลตั้งแต่วันที่ 4 มกราคม พ.ศ. 2553 ถึงวันที่ 28 ธันวาคม พ.ศ. 2561 ไม่รวมวันเสาร์ อาทิตย์และวันหยุดเทศกาล

## 1.4 ขั้นตอนการวิจัย

1. ศึกษางานวิจัยและบทความทางวิชาการที่เกี่ยวข้องกับงานที่พัฒนา
2. ระบุปัญหาและข้อเสียที่เกิดขึ้นจากงานวิจัยก่อนหน้า
3. วิเคราะห์พีเจอร์และออกแบบสถาปัตยกรรมโครงข่ายประสาทเทียมแบบต่าง ๆ
4. พัฒนาและทดสอบความถูกต้องของโมเดล
5. ทดสอบโมเดลโดยการวัดกำไรจากชุดข้อมูลทดสอบ
6. วิเคราะห์ผลการทดสอบและปรับปรุงโมเดลเพื่อเพิ่มประสิทธิภาพในการทำนาย
7. จัดทำเอกสารรายงาน

## 1.5 ประโยชน์ที่คาดว่าจะได้รับ

ประโยชน์ที่ได้รับจากการวิจัยในครั้งนี้มีดังนี้

1. ประโยชน์ต่อนิสิตที่ทำโครงการ
  - 1.1. ได้ศึกษาสถาปัตยกรรมโครงข่ายประสาทเทียมรูปแบบต่าง ๆ
  - 1.2. ได้นำความรู้จากการเรียนมาประยุกต์ใช้ในการออกแบบโมเดล
  - 1.3. ได้ศึกษางานวิจัยที่เกี่ยวข้องด้านการลงทุน
2. ประโยชน์ที่ได้จากโครงการที่พัฒนาขึ้น
  - 2.1. ได้พัฒนาองค์ความรู้ทางธุรกิจซึ่งสามารถนำไปประยุกต์ใช้กับการลงทุน

## 1.6 โครงสร้างของรายงาน

รายงานฉบับนี้มีทั้งหมด 6 บท โดย บทที่ 1 จะกล่าวถึง ความเป็นมาและเหตุผลการวิจัย บทที่ 2 จะกล่าวถึง งานวิจัยที่เกี่ยวข้อง บทที่ 3 จะกล่าวถึง ขั้นตอนการรวบรวมและเก็บข้อมูล บทที่ 4 จะกล่าวถึง ขั้นตอนการวิจัย บทที่ 5 จะกล่าวถึง สรุปผลการดำเนินการวิจัย บทที่ 6 จะกล่าวถึง ข้อเสนอแนะ

## บทที่ 2

### งานวิจัยที่เกี่ยวข้อง

ในบทนี้จะกล่าวถึงงานวิจัยที่เกี่ยวข้องกับระบบการเรียนการสอนแบบห้องเรียนกลับด้านและการเรียนการสอนระบบใหม่นี้

#### 2.1 การทำนายในตลาดแลกเปลี่ยนเงินตราต่างประเทศ

ตลาดแลกเปลี่ยนเงินตราต่างประเทศ (Foreign Exchange Market) เป็นตลาดการเงินที่ใหญ่ที่สุดในบรรดาตลาดการลงทุนทั้งหมด ด้วยมีการซื้อขายสูงถึง 5.09 ล้านล้านดอลลาร์สหรัฐโดยเฉลี่ยในแต่ละวันในเดือนเมษายน 2016 [1] ซึ่งการซื้อขายที่เกิดขึ้นในตลาดเป็นปัจจัยหนึ่งที่ทำให้อัตราแลกเปลี่ยนในคู่สกุลเงินต่าง ๆ มีการเปลี่ยนแปลงตลอดเวลา ทำให้การทำนายอัตราแลกเปลี่ยนจึงเป็นสิ่งที่ทำได้ยากและเป็นสิ่งที่ท้าทาย โดย Burton G. Malkiel [7] ได้นำเสนอว่า รูปแบบต่าง ๆ ที่เราสามารถทำนายได้นั้นเกิดขึ้นอยู่ตลอดเวลา เราสามารถที่จะเรียนรู้และใช้มันเพื่อการทำนายได้

#### 2.2 การทำนายอนุกรมเวลาทางการเงิน

ข้อมูลอนุกรมเวลา (time series data) เป็นข้อมูลที่มีการเปลี่ยนแปลงไปตามเวลา ซึ่งในปัจจุบันนักวิจัยจำนวนมากได้ให้ความสนใจในปัญหาที่แตกต่างกันไปยกตัวอย่างเช่น การรู้จำเสียงพูด การสร้างคำบรรยายจากวิดีโอ การรู้จำการกระทำของมนุษย์ ข้อมูลทางการเงินที่มีลักษณะเป็นข้อมูลอนุกรมเวลา (financial time series data) ยกตัวอย่างเช่น อัตราแลกเปลี่ยนในตลาดแลกเปลี่ยนเงินตราต่างประเทศ และ ราคาหุ้นในตลาดหลักทรัพย์ เป็นสิ่งที่นักวิจัยจำนวนมากให้ความสนใจในการทำนายพวกมันทำให้มีงานวิจัยต่าง ๆ เกิดขึ้น โดยได้มีการนำเทคนิคการเรียนรู้ของเครื่อง (Machine Learning Technique) มาใช้ ยกตัวอย่างเช่น ในปี 2010 Mehdi Shashei และ Mehdi Bijari [5] ได้ใช้ โครงข่ายประสาทเทียม (Artificial Neuron Network – ANN) มาใช้ในการทำนายอนุกรมเวลา (Time Series Forecasting) โดยใช้กับชุดข้อมูลอย่าง เวลาพระอาทิตย์ขึ้น ราคาหุ้นในตลาดหลักทรัพย์ และ อัตราแลกเปลี่ยนระหว่างคู่เงิน GBP/USD ในปี 2011 Areej Baasher และ Mohamed Waleed Fakhr [4] จัดทำงานวิจัยที่ใช้เทคนิคการเรียนรู้ของเครื่องในการทำนายแนวโน้มของตลาดแลกเปลี่ยนเงินตราต่างประเทศ ในปี 2015 Jigar Patel และคณะ [3] ได้นำเสนองานที่ใช้ตัวแบบชนิดต่าง ๆ ได้แก่ ANN SVM


และ naïve-Bayes ในการทำนายทิศทางของการเคลื่อนที่ของราคาหุ้นและดัชนีหุ้น นอกจากนี้ในปี 2000 Jingtao Yao และ Chew Lim Tan [2] ได้นำเสนองานที่แสดงให้เห็นถึงหลักฐานที่แสดงได้ให้เห็นว่าตัว

แบบโครงข่ายประสาทเทียมสามารถนำมาประยุกต์ใช้ได้กับการทำนายอัตราแลกเปลี่ยนในตลาดแลกเปลี่ยนเงินตราระหว่างประเทศ

## 2.3 โครงข่ายประสาทเทียมเชิงลึกสำหรับการทำนายอนุกรมเวลาทางการเงิน

### 2.3.1 โครงข่ายประสาทเทียม (Artificial Neural Network)

โครงข่ายประสาทเทียม เป็นโมเดลที่เกิดจากการจำลองการทำงานของสมองซึ่งประกอบด้วยเซลล์ประสาท (neuron) จำนวนมากที่เชื่อมต่อกัน



รูปที่ 2.1 เซลล์ประสาท กับ เซลล์ประสาทเทียม  
(อ้างอิงจาก <http://cs231n.github.io/neural-networks-1/>)


ในโครงข่ายประสาทเทียมจะใช้เซลล์ประสาทเทียม (artificial neuron) หรือ เพอร์เซปตรอน (perceptron) หรือ โหนด (node) ที่เชื่อมต่อกัน โหนดจะรับค่านำเข้าถ่วงน้ำหนัก (weighted input) นำไปหาผลรวมแล้วจึงส่งเข้า ฟังก์ชันกระตุ้น (activation function) และได้ค่าข้อมูลออกมา

$$f(x) = f\left(\sum_{i=1}^n w_i x_i + b\right)$$

โดย  $x_i$  คือค่านำเข้า  $w_i$  คือค่าน้ำหนักของแต่ละค่ารับเข้า (corresponding weight)  $b$  คือ ไบแอส (bias) และ  $n$  คือจำนวนค่ารับเข้าทั้งหมด ซึ่งโหนดสามารถเรียนรู้ที่จะปรับค่าน้ำหนักและไบแอสเพื่อให้ส่งผลลัพธ์ที่เหมาะสมออกมาได้

ในการสร้างโครงข่ายประสาทเทียม เราสามารถสร้างโครงข่ายประสาทเทียมได้โดยการเชื่อมต่อโหนดหลาย ๆ โหนดเข้าด้วยกัน โครงสร้างโดยทั่วไปประกอบด้วย ชั้นข้อมูลเข้า (input layer) ชั้นซ่อน (hidden layer) และ ชั้นข้อมูลออก (output layer) โดยในแต่ละชั้นจะมีโหนดที่เชื่อมต่อกับทุกโหนดที่อยู่ในชั้นก่อน

หน้าและเชื่อมต่อกับทุกโหนดที่อยู่ชั้นถัดไป ซึ่งภายในชั้นซ่อนจะเป็นที่ที่การเรียนรู้ส่วนใหญ่เกิดขึ้น การมีชั้นซ่อนมากขึ้นจะทำให้โมเดลสามารถเรียนรู้ได้ซับซ้อนมากขึ้น



รูปที่ 2.2 ตัวอย่างโครงสร้างของโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า  
(อ้างอิงจาก [http://uc-r.github.io/feedforward\\_DNN](http://uc-r.github.io/feedforward_DNN))

### 2.3.2 โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า (Feed Forward Neural Networks – FFNNs)

FFNN หรือ multilayer perceptron เป็นชนิดหนึ่งของ โครงข่ายประสาทประดิษฐ์ (Artificial Neural networks – ANN) โดยทั่วไปประกอบด้วยชั้น (layer) จำนวน  $L$  ชั้น ซึ่งแต่ละชั้นมีโหนด (node) จำนวน  $M_l$  โหนด โดย  $l$  มีค่าเท่ากับ  $1$  ถึง  $L$  ถ้าสมมติให้ค่านำเข้าตั้งแต่  $x_1$  ถึง  $x_t$  ถูกป้อนเข้า FFNN เราจะสามารถเขียนสมการสำหรับชั้นแรกได้ดังนี้

$$a^1(i) = \sum_{j=1}^t w^1(i,j)x(j) + b^1(i) \quad \text{โดยที่ } i = 1, \dots, M_1$$

โดย  $w^1$  คือ ค่าน้ำหนัก และ  $b^1$  คือค่าไบแอส แต่ละผลลัพธ์  $a^1(i)$  สำหรับ  $i = 1, \dots, M_1$  จะถูกแปลงด้วยฟังก์ชันกระตุ้นแบบไม่เป็นเชิงเส้น  $h$

$$f^1(i) = h(a^1(i)) \quad \text{เมื่อ } i = 1, \dots, M_1$$


ฟังก์ชันแบบไม่เป็นเชิงเส้นนี้จะช่วยให้โมเดลสามารถเรียนรู้ความสัมพันธ์แบบไม่เป็นเชิงเส้นได้ ซึ่งในชั้นย่อย  $l$  ตั้งแต่ชั้นที่  $2$  ถึง  $L - 1$  จะทำการรับผลลัพธ์จากชั้นก่อนหน้า  $f^{l-1}$  มาทำการหาผลรวมเชิงเส้นและส่งผ่านฟังก์ชันแบบไม่เป็นเชิงเส้นอีกครั้ง

$$f^l(i) = h\left(\sum_{j=0}^{M_{L-1}} w^l(i, j)x(j) + b^l(j)\right) \text{ โดยที่ } i = 1, \dots, M_1$$

ในชั้นสุดท้ายชั้นที่  $L$  จะให้ค่าที่ต้องการทำนายออกมา โดย  $w^l$  คือ ค่าน้ำหนัก และ  $b^l$  คือค่าไบแอส

$$\bar{x}(t+1) = h\left(\sum_{j=0}^{M_{L-1}} w^L(j)f^{L-1}(j) + b^L\right)$$

FFNN ได้ถูกนำมาประยุกต์ใช้ในหลากหลายปัญหา รวมทั้งในการทำนายอนุกรมเวลาเช่นกัน โดย FFNN จะประกอบด้วยชั้นข้อมูลเข้า (input layer) ชั้นซ่อน (hidden layer) และ ชั้นข้อมูลออก (output layer) โดยชั้นข้อมูลเข้าจะอ่านค่าของข้อมูล ชั้นซ่อนจะเป็นที่ที่การเรียนรู้ส่วนใหญ่เกิดขึ้น และชั้นข้อมูลออกจะเป็นชั้นที่ส่งผลลัพธ์ออกมา โครงสร้างของโครงข่ายประสาทเทียมนี้ที่มีการใช้ชั้นหลายชั้นทำให้มันมีความสามารถในการเรียนรู้สิ่งที่ซับซ้อน และจัดการกับความไม่เป็นเส้นตรงได้ซึ่งเป็นสิ่งที่อยู่ในการทำนายอนุกรมเวลาทางการเงิน



รูปที่ 2.3 ตัวอย่างโครงสร้างของโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าเชิงลึก

(อ้างอิงจาก [http://uc-r.github.io/feedforward\\_DNN](http://uc-r.github.io/feedforward_DNN))

ในปี 2016 Matthew D. และคณะ [8] ได้นำเสนองานที่อธิบายการประยุกต์ใช้ FFNN ในการทำนายทิศทางเคลื่อนที่ของตลาดการเงิน ซึ่งค้นพบว่า FFNN เป็นตัวจำแนก (classifier) ที่มีความสามารถในการทำนายอย่างมีนัยสำคัญ นอกจากนี้ยังได้สาธิตการประยุกต์ใช้ FFNN กับการลงทุนเพื่อแสดงให้เห็น

เห็นถึงความแม่นยำในการทำนายและความสัมพันธ์ของมันกับความสามารถในการทำกำไรของกลยุทธ์การลงทุน

### 2.3.3 โครงข่ายประสาทเทียมคอนโวลูชัน (Convolutional Neural Networks – CNNs)

โครงข่ายประสาทเทียมคอนโวลูชันเป็นสถาปัตยกรรมที่ถูกนำไปประยุกต์ใช้กันเป็นอย่างมากในปัจจุบัน โดย CNN นั้นแตกต่างจากเทคนิคการเรียนรู้ของเครื่อง (machine learning techniques) อื่น ๆ ตรงที่ ประการแรกคือ CNN มีความสามารถที่จะเป็นตัวจับลักษณะสำคัญได้โดยแปลงข้อมูลดิบที่รับเข้ามาไปเป็นลักษณะสำคัญที่มีระดับสูงขึ้นไป โดยข้อมูลที่รับเข้ามาจากผ่านชั้นต่าง ๆ ทั้ง ชั้นคอนโวลูชัน (convolutional layer) ซึ่งจะช่วยจับลักษณะสำคัญจากข้อมูลที่รับเข้ามาแล้วส่งต่อไปให้ ชั้นการรวม (pooling layer) ซึ่งจะทำหน้าที่ลดขนาดข้อมูลเพื่อเอาเฉพาะข้อมูลที่มีความสำคัญเอาไว้ และอาจจะปิดท้ายด้วยชั้นการเชื่อมโยงเต็มรูปแบบ (fully connected layer) ซึ่งมักจะมียหลายชั้น เมื่อเปรียบเทียบกับ FFNN ทุกหน่วยของ FFNN นั้นจะเชื่อมกับทุกหน่วยที่อยู่ในชั้นก่อนหน้าและเชื่อมกับทุกหน่วยที่อยู่ในชั้นถัดไป ในขณะที่ CNN จะถูกจำกัดขอบเขตของส่วนที่จะรับข้อมูลเอาไว้ในชั้นคอนโวลูชันทำให้ใช้พารามิเตอร์สำหรับเรียนรู้้น้อยกว่าในแต่ละชั้นของ CNN คำนวณเข้าจะถูกผูกเข้ากับเมตริกซ์ค่าน้ำหนักที่เรียกว่าตัวกรอง (filter) เพื่อที่จะให้สร้าง feature map ขึ้นมา เมตริกซ์ค่าน้ำหนักนี้จะเลื่อนเพื่อรับค่านำเข้าไปเรื่อย ๆ ในโดยการเลื่อนแต่ละครั้งจะมีการคำนวณผลคูณเชิงสเกลาร์ระหว่างค่านำเข้าแล้วเมตริกซ์ค่าน้ำหนัก พิจารณาค่านำเข้าหนึ่งมิติ  $x = (x_t)_{t=0}^{N-1}$  เราจะได้ผลลัพธ์จากชั้นแรกของการทำคอนโวลูชันโดยมีตัวกรอง  $w_h^1$  สำหรับ  $h = 1, \dots, M_1$  ออกมาเป็น


$$a^1(i, h) = (w_h^1 * x)(i) = \sum_{j=-\infty}^{\infty} w_h^1(j)x(i-j)$$

โดยมี  $w_h^1 \in \mathbb{R}^{1 \times k \times 1}$  และ  $a^1 \in \mathbb{R}^{1 \times N-k+1 \times M_1}$  ในกรณีนี้ช่อง (channel) ของค่านำเข้าจะมีค่าเท่ากับหนึ่ง ซึ่งจะทำให้ช่องของเมตริกซ์ค่าน้ำหนักมีค่าเท่ากับหนึ่งด้วยและมีขนาดของตัวกรอง  $k$  และจะเหมือนกับ FFNN ค่าที่ได้ออกมาจะถูกส่งผ่านฟังก์ชันแบบไม่เชิงเส้น  $h(\cdot)$  ซึ่งจะได้  $f^1 = h(a^1)$

ในแต่ละชั้นย่อย ๆ ที่  $l = 2, \dots, L$  จะรับค่านำเข้าจากผลลัพธ์ของชั้นก่อนหน้า  $f^{l-1} \in \mathbb{R}^{1 \times N_{l-1} \times M_{l-1}}$  โดย  $1 \times N_{l-1} \times M_{l-1}$  คือขนาดของผลลัพธ์ที่  $N_{l-1} = N_{l-2} - k + 1$  ค่านำเข้า  $f^{l-1}$  จะถูกผูกเข้ากับตัวกรอง  $w_h^l \in \mathbb{R}^{1 \times k \times M_{l-1}}$  ที่  $h = 1, \dots, M_l$  ทำให้ได้ feature map  $a^l \in \mathbb{R}^{1 \times N_l \times M_l}$

$$a^l(i, h) = (w_h^l * f^{l-1})(i) = \sum_{j=-\infty}^{\infty} \sum_{m=1}^{M_{l-1}} w_h^l(j, m) f^{l-1}(i-j, m)$$

จากนั้นผลลัพธ์ที่ได้จะถูกส่งเข้าฟังก์ชันแบบไม่เชิงเส้นเพื่อให้ได้  $f^l = h(a^l)$  ในที่สุดผลลัพธ์ของโมเดลที่ได้จากชั้นสุดท้ายจะเป็นเมตริกซ์  $f^L$  ซึ่งขนาดจะขึ้นกับขนาดของตัวกรองและจำนวนตัวกรองที่ถูกใช้ในชั้นสุดท้าย โดยโมเดลจะเรียนรู้ด้วยการลดค่าความผิดพลาดระหว่างผลลัพธ์ของโมเดล  $f^L$  กับค่าผลลัพธ์แท้จริง



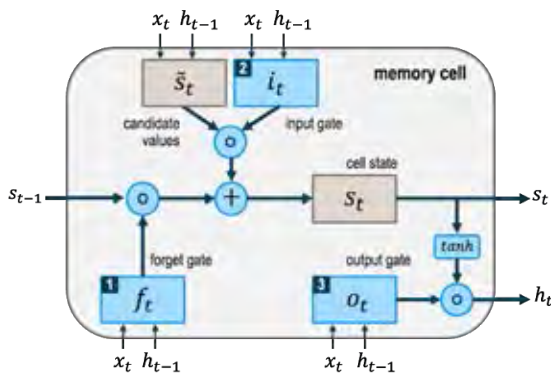
รูปที่ 2.4 ตัวอย่างโครงสร้างของโครงข่ายประสาทเทียมตื้น  
(อ้างอิงจาก [https://github.com/gwding/draw\\_convnet](https://github.com/gwding/draw_convnet))

ในปี 2018 Anastasia B. และคณะ [9] ได้นำเสนอวิธีการสำหรับการทำนายอนุกรมเวลาที่มีเงื่อนไข (conditional time serie) ซึ่งมีพื้นฐานมาจากการประยุกต์ใช้สถาปัตยกรรมโครงข่ายประสาทเทียมคอนโวลูชันเชิงลึกที่เรียกว่า WaveNet โดยได้มีการนำไปใช้กับข้อมูลอนุกรมเวลาทางการเงินอย่าง S&P500 และ อัตราแลกเปลี่ยนในหลายคู่สกุลเงิน โดยเปรียบเทียบกับวิธีการที่นิยมใช้กับอนุกรมเวลาในสมัยใหม่อย่าง LSTM ซึ่งผู้วิจัยได้แสดงให้เห็นว่า WaveNet เป็นตัวแบบที่เรียบง่าย มีประสิทธิภาพ และ ทำความเข้าใจได้ง่าย

### 2.3.4 โครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory Neural Networks – LSTMs)

โครงข่ายประสาทเทียมหน่วยความจำระยะสั้นได้ที่นำเสนอครั้งแรกโดย Hochreither และ Schmidhuber ในปี 1997 ซึ่งเป็นตัวที่จะช่วยแก้ปัญหา vanishing gradient ที่โครงข่ายประสาทเทียมแบบวนซ้ำ (Recurrent Neural Networks – RNNs) อื่น ๆ เคยเผชิญ โดย Hochreither และคณะได้ออกแบบโครงสร้างของ LSTM เพื่อแก้ปัญหานี้โดย ให้มีหน่วยประตูรับเข้า (input gated unit) และหน่วยประตูข้อมูลออก (output gated unit) โดยหน่วยประตูรับเข้าจะควบคุมข้อมูลที่รับเข้าไปในหน่วยความจำ (memory unit) ซึ่งช่วยป้องกันข้อมูลที่ไม่จำเป็นที่จะรับเข้ามา สำหรับหน่วยประตูข้อมูลออกจะช่วยควบคุมข้อมูลที่จะถูกส่งออกไปยังส่วนชั้นที่อยู่ติดกัน ต่อมาในปี 1999 โดย Gers และคณะได้เพิ่มประตูลืม (forget gate) เข้าไปในโครงสร้าง ซึ่งจะช่วยให้ตัดสินใจว่าข้อมูลอะไรที่จะเอาออกจากหน่วยความจำ โดยข้อมูลในหน่วยความจำจะเก็บไว้ในสถานะเซลล์ (cell state,  $S_t$ )





### 1 Forget gate:

Defines which information to remove from the memory (cell state)

### 2 Input gate:

Defines which information to add to the memory (cell state)

### 3 Output gate:

Defines which information from the memory (cell state) to use as output

รูปที่ 2.5 ตัวอย่างโครงสร้างของหน่วยความจำระยะสั้นแบบยาว  
(อ้างอิงจาก fig. 2 ใน [10])

ในทุก ๆ จุดเวลา  $t$  ประตูลืมจะรับค่านำเข้า  $x_t$  ค่าหนึ่งในลำดับนำเข้าและรับค่านำเข้า  $x_t$  ค่าหนึ่งในลำดับนำเข้าและรับค่าข้อมูลออกจากจุดเวลาก่อนหน้า  $h_{t-1}$  จากหน่วยความจำ ในขั้นแรกของการทำงาน ประตูลืมจะทำการระบุข้อมูลที่จะนำออกจากสถานะของเซลล์ก่อนหน้า  $s_{t-1}$  ด้วยการส่งค่านำเข้าผ่านฟังก์ชันของประตูลืมซึ่งเป็นฟังก์ชัน sigmoid ซึ่งให้ค่าระหว่าง 0 กับ 1 โดยค่า 0 จะหมายถึงข้อมูลนั้นถูกลืมโดยสมบูรณ์และค่า 1 หมายถึงข้อมูลนั้นถูกจำโดยสมบูรณ์ โดยค่านำเข้าจะมีเมตริกซ์ค่านำหนัก  $W_{f,x}$  และ  $W_{f,h}$  และมีเวกเตอร์ไบแอส  $b_f$

$$f_t = \text{sigmoid}(W_{f,x}x_t + W_{f,h}h_{t-1} + b_f)$$

ในขั้นที่สองจะทำการเลือกว่าข้อมูลใดควรจะถูกเพิ่มเข้าไปในสถานะเซลล์  $s_t$  โดยในขั้นนี้จะประกอบด้วยสองการคำนวณ อย่างแรกคือการหาค่าทำซิง (candidate values,  $\tilde{s}_t$ ) เป็นการส่งค่าผ่านฟังก์ชัน tanh ซึ่งให้ค่าตั้งแต่ 1 ถึง -1 อีกการดำเนินการคือค่ากระตุ้น  $i_t$  ของประตูลืม โดยมีเมตริกซ์ค่านำหนัก  $W_{\tilde{s},x}$   $W_{\tilde{s},h}$   $W_{i,x}$  และ  $W_{i,h}$  สำหรับแต่ละค่านำเข้า และมีเวกเตอร์ไบแอส  $b_s$  และ  $b_i$

$$\begin{aligned}\tilde{s}_t &= \text{tanh}(W_{\tilde{s},x}x_t + W_{\tilde{s},h}h_{t-1} + b_{\tilde{s}}) \\ i_t &= \text{sigmoid}(W_{i,x}x_t + W_{i,h}h_{t-1} + b_i)\end{aligned}$$

ในขั้นที่สาม ค่าของสถานะเซลล์อันใหม่จะถูกคำนวณ โดยใช้ค่าจากขั้นตอนก่อนหน้า

$$s_t = f_t \circ s_{t-1} + i_t \circ \tilde{s}_t$$

และในขั้นสุดท้ายค่าผลลัพธ์  $h_t$  ของหน่วยความจำจะถูกส่งออกมา ดังสมการด้านล่าง

$$o_t = \text{sigmoid}(W_{o,x}x_t + W_{o,h}h_{t-1} + b_o)$$

$$h_t = o_t \circ \tanh(s_t)$$

สำหรับการทำนายอนุกรมเวลาทางการเงิน ในปี 2017 Thomas Fischer และ Christopher Krauss [10] ได้นำ LSTM มาประยุกต์ใช้ในการทำนายทิศทางของการเคลื่อนที่ของหุ้นที่อยู่ในดัชนี S&P 500 ซึ่งพบว่า LSTM เป็นวิธีการที่เหมาะสมกับปัญหานี้โดยสามารถเอาชนะโครงข่ายประสาทเทียมเชิงลึกมาตรฐานที่มี 3 ชั้นซ่อน และ logistic regression ได้

### 2.3.5 โครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาวแบบคอนโวลูชัน (Convolutional Long Short-Term Memory Neural Networks – CLSTMs)

Simon Serrarens [11] ได้นำเสนอโครงข่ายประสาทเทียมคอนโวลูชันหน่วยความจำระยะสั้นยาวแบบคอนโวลูชันมาใช้ในการทำนายทิศทางของตลาดแลกเปลี่ยนเงินตราต่างประเทศ โดยเสนอว่า CLSTM จะสามารถใช้ประโยชน์จากรูปแบบการทำงานที่แตกต่างกันของทั้งสองโมเดล คือ CNN จะทำงานโดยเป็นตัวจับลักษณะที่สำคัญจากข้อมูล ในส่วนของ LSTM ซึ่งจะรับลักษณะสำคัญที่จับได้จาก CNN เพื่อมาหาความสัมพันธ์หรือความขึ้นต่อกันในระยะยาว ซึ่งทั้งหมดนี้จะช่วยให้การทำนายมีความแม่นยำมากขึ้น

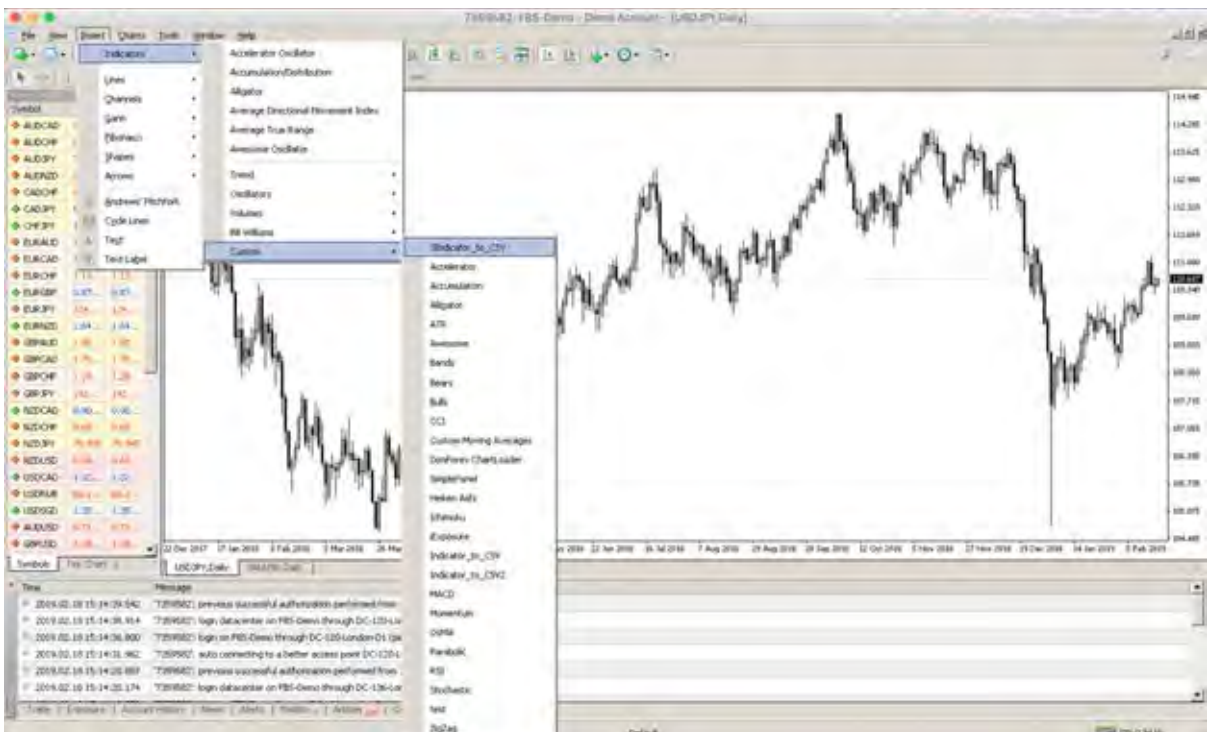
## บทที่ 3

### การรวบรวมและจัดเตรียมข้อมูล

ในบทนี้จะกล่าวถึง วิธีการที่นำข้อมูลออกมาจากโปรแกรมที่ใช้สำหรับการลงทุน (FBS Trader 4) และ การเตรียมข้อมูลก่อนนำไปใช้ โดยข้อมูลที่จะนำไปให้เครื่องเรียนรู้ จะถูกปรับให้อยู่ในรูปแบบ ลำดับของ อินดิเคเตอร์ (sequence of indicators) เพื่อให้เครื่องสามารถวิเคราะห์ทิศทางของอัตราแลกเปลี่ยนจาก ข้อมูลในอดีตได้อย่างมีประสิทธิภาพเพิ่มขึ้น

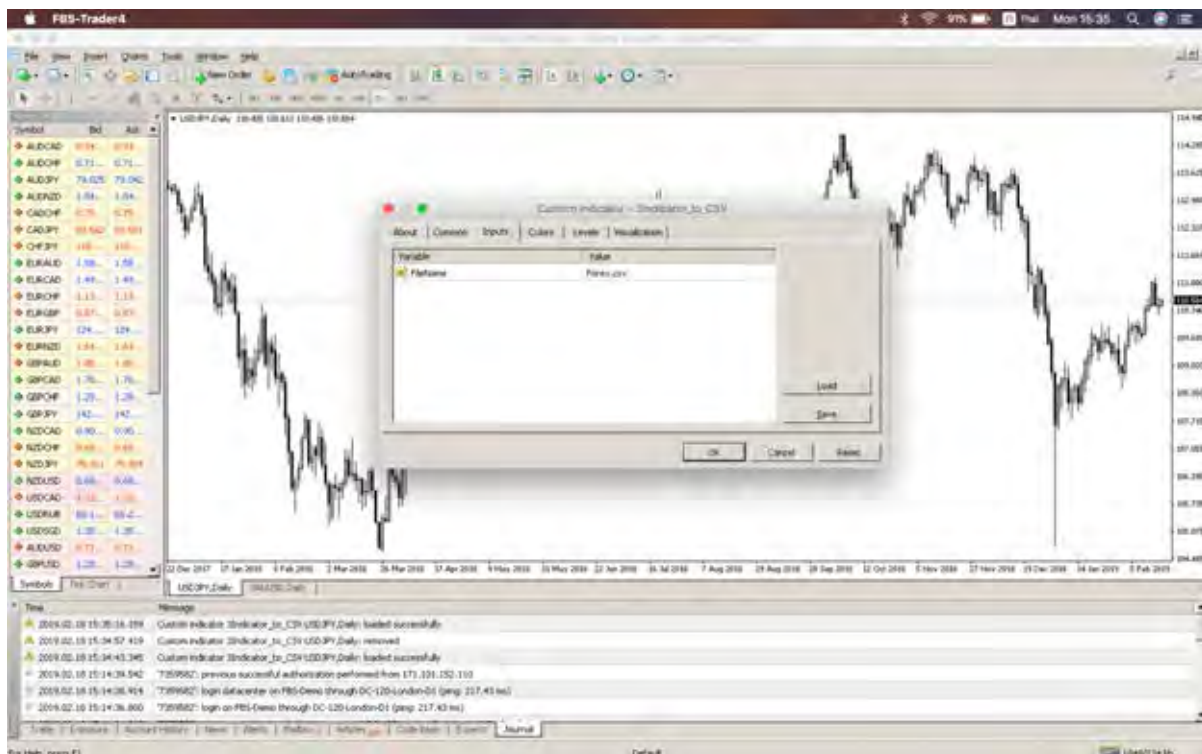
#### 3.1 ขั้นตอนการเก็บข้อมูล

1. เตรียมโค้ดสำหรับการดาวน์โหลดข้อมูลโดยนำไฟล์โค้ดใส่ไว้ที่โฟลเดอร์ Indicators ดังนี้  
Program Files > FBS Trader 4 > MQL4 > Indicators
2. เลือก Insert > Indicators > Custom > ชื่อไฟล์ที่มีคำสั่งดาวน์โหลดข้อมูล



รูปที่ 3.1 วิธีการเก็บข้อมูล

3. เลือก ok



รูปที่ 3.2 ขั้นตอนการตั้งชื่อไฟล์ที่จะดาวน์โหลด

4. ข้อมูลที่ดาวน์โหลดจะอยู่ในโฟลเดอร์ที่ชื่อว่า Files ดังนี้ Program Files > FBS Trader 4 > MQL4 > Files

### 3.2 อินดิเคเตอร์

อินดิเคเตอร์ เป็นการคำนวณทางคณิตศาสตร์โดยใช้ราคาในอดีตหรือปริมาณการซื้อขายหรือค่าทางสถิติ โดยอินดิเคเตอร์เป็นเครื่องมือที่นักลงทุนในปัจจุบันใช้วิเคราะห์แนวโน้มของตลาด แนนอนว่าการทำงานของอินดิเคเตอร์จะใช้ควบคู่กับการดูกราฟของราคาเพื่อวิเคราะห์ความสัมพันธ์ระหว่างกราฟของราคากับอินดิเคเตอร์ สำหรับงานวิจัยนี้ ผู้วิจัยได้ใช้อินดิเคเตอร์ที่เป็นที่นิยมในตลาดการลงทุน และได้เพิ่มค่าของแนวโน้มเข้าไปจากการคำนวณด้วยสูตรอย่างง่าย คือ

1. ราคาเปิดของวันปัจจุบัน - ราคาสูงสุดของวันก่อนหน้า
2. ราคาเปิดของวันปัจจุบัน - ราคาต่ำสุดของวันก่อนหน้า

ผู้วิจัยได้ทำการเก็บข้อมูลออกมาจากโปรแกรมที่ใช้สำหรับการลงทุนและได้คำนวณค่าแนวโน้ม ซึ่งเป็นข้อมูลตั้งแต่ปี 2553 ถึงปี 2561 โดยข้อมูลจะประกอบไปด้วยพีเจอร์ ดังนี้

1. วันที่
2. ราคาเปิด
3. ราคาสูงสุด
4. ราคาต่ำสุด
5. ราคาปิด
6. ปริมาณการซื้อขาย
7. Moving Average Convergence Divergence (MACD)
8. MACD Line
9. Signal Line
10. Relative Strength Index (RSI)
11. Simple Moving Average (SMA)
12. Exponential Moving Average (EMA)
13. Bollinger Band
14. Upper Band
15. Lower Band
16. Middle Band
17. Stochastic Oscillator
18. Stochastic Main Line
19. Stochastic Signal Line
20. Bear Power
21. Bull Power
22. Commodity Channel Index (CCI)
23. กำไรเมื่อทำขายลง (ProfitDown)
24. กำไรเมื่อทำขายขึ้น (ProfitUp)
25. แนวโน้ม (Target)
26. ราคาเปิดของวันปัจจุบัน - ราคาสูงสุดของวันก่อนหน้า
27. ราคาเปิดของวันปัจจุบัน - ราคาต่ำสุดของวันก่อนหน้า

Open Timestamp	Open	High	Low	Close	Volume	Target	ProfitDown	ProfitUp	MACD-signal	MACD-main	RSI_10	RSI_5
2010.01.04 00:00:00	92.98	93.21	92.18	92.5	5180	0	460	-460	0.302206635	0.345612333	76.1304336	87.2003095
2010.01.05 00:00:00	92.52	92.54	91.25	91.7	5726	0	830	-830	0.303110045	0.257625607	69.374482	71.3716328
2010.01.06 00:00:00	91.69	92.73	91.52	92.31	5557	1	-630	630	0.278263211	0.047025764	58.896135	50.6394226

SMA_5	SMA_3	SMA_10	EMA_5	EMA_3	EMA_10	Band_Lower	Band_Upper	Band_Main	Sto-main	Sto-sig	Bears5	Bulls5	CCI	CCI	Open(T) - High(T-1)	Open(T) - Low(T-1)
92.294	92.1766667	91.911	92.1180988	92.192087	91.6976727	91.4001454	93.1878546	92.294	48.0865225	58.4417113	-0.4971482	0.71285184	4.61975835	63.8264669	-0.41	0.8
92.568	92.4466667	92.125	92.5220659	92.7610435	91.9944595	91.4419165	93.6940835	92.568	58.9108911	58.6763012	-0.0180988	1.27190123	108.177172	151.572327	-0.06	1.23
92.494	92.7533333	92.203	92.5513772	92.6855217	92.106376	91.4395921	93.5484079	92.494	67.7272727	63.201787	-0.2520658	1.22793415	19.7682345	49.4231937	-1.14	0.34

รูปที่ 3.3 ตัวอย่างข้อมูล 3 แถวแรก

Features	Durations (days)	Formulas
Open price	1	$Open(i)$
Difference between current Open and previous High	1	$Open(i) - High(i - 1)$
Difference between current Open and previous Low	1	$Open(i) - Low(i - 1)$
Simple Moving Average (SMA)	3, 5, 10	$SMA = \sum_{i=0}^{n-1} \frac{Close(i)}{n}$
Exponential Moving Average (EMA)	3, 5, 10	$EMA = [Close(i) - SMA(i)] * \frac{2}{(n+1)} + SMA(i - 1)$
Moving Average Convergence Divergence (MACD) – main	fast = 12, slow = 26	$MACD = EMA(12) - EMA(26)$
Moving Average Convergence Divergence (MACD) - signal	9	$SIGNAL = SMA(MACD, 9)$
Relative Strength Index (RSI)	5, 10	$RSI = 100 - \left[ \frac{100}{\left(1 + \frac{U}{D}\right)} \right]$ where U is average number of positive price changes and D is average number of negative price changes
Bollinger Band – middle	3, 5, 10	$middle\ line = SMA(Close, n)$
Bollinger Band – upper	3, 5, 10	$upper\ line = middle\ line + 2 * \sigma(n)$
Bollinger Band – lower	3, 5, 10	$lower\ line = middle\ line - 2 * \sigma(n)$
Stochastic Oscillator – main	14	$\%K = \frac{(Close(i) - Lowest\ Low(14))}{((Highest\ high(14) - Lowest\ Low(14)))} * 100$
Stochastic Oscillator – signal	5	$\%D = SMA(\%K, 5)$
Bears	5	$Bears = Low - EMA$
Bulls	5	$Bulls = High - EMA$
Commodity Channel Index (CCI)	5, 10	$CCI = \frac{TP(i) - SMA(TP)}{0.015 * MD}$

U is the average number of positive price changes, D is the average number of negative price changes,  $\sigma$  is standard deviation,  $Typical\ price = TP = \frac{High(i) + Low(i) + Close(i)}{3}$ ,

$$Mean\ Deviation = MD = \frac{\sum_i^{n-1} |TP(i) - SMA(TP)|}{n}$$

ตารางที่ 3.1 สูตรการคำนวณและช่วงระยะเวลาของพีเจอร์ที่ใช้เป็นข้อมูลนำเข้า

(อ้างอิงจาก [12] และ [13])

Simple Moving Average (SMA) เป็นค่าเฉลี่ยของราคาในช่วงระยะเวลาที่เรากำหนด เป็นการทำให้ราคาที่มีความผันผวนของแต่ละวันมาทำให้เป็นกราฟเรียบเพื่อให้ง่ายต่อการทำความเข้าใจ ยกตัวอย่างเช่น ในกรณีที่ราคาปัจจุบันวิ่งขึ้นมาชนเส้นกราฟ SMA นั้นหมายถึงสัญญาณขาขึ้น

Exponential Moving Average (EMA) เป็นการนำราคามาหาค่าเฉลี่ยคล้ายกับ SMA แต่ว่า EMA จะให้น้ำหนักกับวันที่อยู่ใกล้ที่สุดมากกว่าวันที่อยู่ไกล ทำให้กราฟของ EMA จะตอบสนองต่อราคาเร็วกว่า SMA ซึ่งเราสามารถนำอินดิเคเตอร์สองตัวนี้มาใช้วิเคราะห์แนวโน้มได้ ยกตัวอย่างเช่น ถ้าเส้นกราฟ EMA วิ่งขึ้นมาชน SMA หมายถึงแนวโน้มขาขึ้น

Moving Average Convergence Divergence (MACD) เป็นอินดิเคเตอร์ที่เกิดจากผลต่างของ EMA 2 ตัวที่ใช้ช่วงเวลาต่างกัน ส่วนใหญ่จะนิยมใช้ EMA 26 วัน กับ EMA 12 วัน ซึ่งเมื่อเรานำไปวาดเส้นกราฟจะเรียกเส้นนี้ว่า เส้นหลัก นอกจากนั้นเพื่อทำให้แสดงสัญญาณซื้อขายได้ชัดเจนจึงมีการเพิ่ม เส้นสัญญาณ (signal line) ที่สร้างจาก EMA ที่มีใช้ระยะเวลาสั้นกว่าเส้นหลัก ที่นิยมใช้กันคือ EMA 9 วัน ซึ่งเราสามารถใช้อินดิเคเตอร์ตัวนี้พิจารณาแนวโน้มและโมเมนตัมได้

Relative Strength Index (RSI) เป็นอินดิเคเตอร์ที่วัดการเคลื่อนไหวของราคามีค่าอยู่ระหว่าง 0 ถึง 100 ใช้บ่งบอกว่ามีการซื้อหรือขายมากเกินไปและเป็นสัญญาณของการกลับตัวของราคา เช่นถ้า RSI มีค่ามากกว่า 70 จะบ่งบอกถึงภาวะที่มีการซื้อมากเกินไปซึ่งอาจส่งผลให้ราคามีโอกาสปรับตัวลง

Bolling Band เป็นอินดิเคเตอร์ที่ใช้ดูแนวโน้มและการกลับตัวเป็นหลักซึ่งประกอบด้วยเส้นกราฟ 3 เส้น โดย เส้นกราฟตรงกลางที่เกิดจาก SMA เส้นกราฟข้างบนจะเกิดจากการบวกค่าของเส้นกลางด้วยส่วนเบี่ยงเบนมาตรฐาน และ เส้นกราฟข้างล่างจะเกิดจากการลบค่าของเส้นกลางด้วยส่วนเบี่ยงเบนมาตรฐาน หมายความว่า ถ้าราคามีความผันผวนสูงกราฟจะอยู่ห่างกันมาก ถ้าราคาความผันผวนต่ำกราฟจะอยู่ใกล้ ๆ กัน

Stochastic Oscillator (STO) จะมีเส้นกราฟสองเป็นส่วนประกอบ เราเรียกเส้นกราฟหลักว่า %K ส่วนอีกเส้นกราฟเราเรียกว่า %D ซึ่งเป็น SMA ของ %K ซึ่งมีหลายวิธีการในการตีความหมายอินดิเคเตอร์ตัวนี้ ยกตัวอย่างเช่น ในกรณีที่เส้นกราฟ %K ขึ้นมาตัดเส้นกราฟ %D หมายถึงราคามีแนวโน้มกลายเป็นขาขึ้น หรือ ทั้งเส้นกราฟ %K และ %D อยู่เกินระดับ 80 หมายถึงราคามีแนวโน้มที่จะลง

Bears Power เป็นอินดิเคเตอร์ที่บ่งบอกที่กำลังในการดันราคาลงของผู้ขาย ที่คิดจากผลต่างของ EMA และราคาต่ำสุดในขณะนั้น ซึ่งเราตีความว่า MA เป็นราคาของผู้ซื้อและผู้ขายยอมรับในช่วงเวลานั้น ส่วนราคาต่ำสุดจะบ่งบอกถึงกำลังสูงสุดของผู้ขายในวันนั้น

Bulls Power เป็นอินดิเคเตอร์ที่บ่งบอกที่กำลังในการดันราคาขึ้นของผู้ซื้อ ที่คิดจากผลต่างของ EMA และราคาสูงสุดในขณะนั้น ซึ่งเราตีความว่า MA เป็นราคาของผู้ซื้อและผู้ขายยอมรับในช่วงเวลานั้น ส่วนราคาสูงสุดจะบ่งบอกถึงกำลังสูงสุดของผู้ซื้อในวันนั้น

Commodity Channel Index (CCI) เป็นอินดิเคเตอร์ที่ใช้วัดความเบี่ยงเบนของราคาจากค่าเฉลี่ยทางสถิติของมัน สามารถใช้บ่งบอกสถานะที่มีผู้ซื้อหรือผู้ขายมากเกินไปได้ ยกตัวอย่างเช่น กรณีที่ CCI มีค่ามากกว่า 100 หมายความว่าขณะนั้นมีราคาถูกซื้อมากเกินไปทำให้ราคาสูงผิดปกติ จึงมีโอกาที่ราคาจะลดลงเพื่อเข้าสู่ภาวะปกติ

### 3.3 การปรับช่วงของข้อมูล

ในงานด้านโครงข่ายประสาทเทียม การปรับช่วงของข้อมูลเพื่อหลีกเลี่ยงปัญหาข้อมูลที่มีขนาดใหญ่ เนื่องจากว่า ค่าที่โครงข่ายประสาทเทียมคำนวณจะต้องผ่านฟังก์ชันกระตุ้น (activation function) ในกรณีที่ค่าที่รับเข้ามามีขนาดใหญ่ เมื่อผ่านฟังก์ชันกระตุ้นแล้วอาจจะทำให้คุณสมบัติบางอย่างหายไป สำหรับงานวิจัยนี้จะปรับช่วงของข้อมูลโดยใช้ การปรับมาตรฐาน (Standardisation) ดังนี้

$$Z = \frac{x - \mu}{\sigma^2}$$

เมื่อ  $x$  คือ ข้อมูลแต่ละตัว  $\mu$  คือ ค่าเฉลี่ยของข้อมูล  $\sigma^2$  คือ ความแปรปรวนของข้อมูล และ  $Z$  คือ ข้อมูลที่ถูกปรับช่วง ซึ่งจะเป็นค่าที่นำไปใช้ฝึกสอนให้กับโมเดล

### 3.4 ลำดับของอินดิเคเตอร์ (sequence of indicators)

ทางผู้วิจัยได้จัดรูปของข้อมูลให้อยู่ในรูปของลำดับของอินดิเคเตอร์ เนื่องจากโมเดลหลาย ๆ ตัวที่เลือกมานั้นทำงานได้ดีกับข้อมูลที่เป็นลำดับ และทางผู้วิจัยมีความคิดว่า ข้อมูลแบบลำดับจะช่วยให้การเรียนรู้ของเครื่องมีประสิทธิภาพมากขึ้น เพราะข้อมูลแบบลำดับสามารถแสดงแนวโน้มที่ผ่านมาในอดีต

ขั้นตอนการปรับของข้อมูลให้อยู่ในรูปแบบลำดับของอินดิเคเตอร์ มีดังนี้

1. เตรียมข้อมูล โดยตอนเริ่มต้นจะเป็นเมตริกซ์ขนาด จำนวนวัน ( $N$ )  $\times$  จำนวนอินดิเคเตอร์ ( $M$ )

	$I_1$	$I_2$	$I_3$	$I_4$	$\dots$	$I_M$
$D_1$						
$D_2$						
$D_3$						
$D_4$						
$D_5$						
$D_{N-1}$						
$D_N$						

รูปที่ 3.4 ข้อมูลก่อนการปรับให้อยู่ในรูปของลำดับของอินดิเคเตอร์



2. สำหรับงานวิจัยนี้ การนำมาเรียงให้อยู่ในรูปแบบของลำดับ จะแบ่งรูปแบบของลำดับอินดิเคเตอร์เป็น 2 แบบ โดยจะแบ่งตามลักษณะของสถาปัตยกรรม ดังนี้

### 3.1. รูปแบบที่ 1 สำหรับ Feed Forward Neural Networks



รูปที่ 3.5 การเรียงข้อมูลให้อยู่ในรูปแบบของลำดับแบบที่ 1 ของวันที่ n


เนื่องจากจะต้องป้อนข้อมูลแบบ 1 มิติ เข้าไปที่ Feed Forward Neural Networks ดังนั้น ทางผู้วิจัยได้นำข้อมูลจากรูปที่ 3.4 มาจัดให้อยู่ในรูปแบบตามรูปที่ 3.5 โดยจะนำอินดิเคเตอร์ของแต่ละวันมาเรียงต่อกันเป็นเส้นตรง โดยจะเรียงจากวันที่น้อยไปวันที่มาก

### 3.2. รูปแบบที่ 2 สำหรับ

#### 3.2.1. Convolutional Neural Networks

#### 3.2.2. Long Short-Term Memory Neural Networks

#### 3.2.3. Convolutional Long Short-Term Memory Neural Networks



รูปที่ 3.6 การเรียงข้อมูลให้อยู่ในรูปแบบของลำดับแบบที่ 2 ของวันที่ n

สำหรับ 3 สถาปัตยกรรมนี้ สามารถป้อนข้อมูลแบบ 2 มิติได้ ดังนั้น ทางผู้วิจัยจึงปรับให้อยู่ในรูปแบบของเมตริกซ์ขนาด ขนาดของลำดับของอินดิเคเตอร์  $\times$  จำนวนอินดิเคเตอร์ (Window size  $\times$  Indicator size)

สำหรับงานวิจัยนี้ ทางผู้วิจัยได้แบ่งให้มีรูปแบบของลำดับอินดิเคเตอร์ทั้งหมด 10 แบบ คือ 5 10 15 20 25 30 35 40 45 และ 50 วัน (Window size) โดยในงานวิจัยนี้จะทำการทดสอบว่าขนาดของลำดับของอินดิเคเตอร์ (window size) แบบใดที่เหมาะสมกับสถาปัตยกรรมแต่ละแบบ

## บทที่ 4

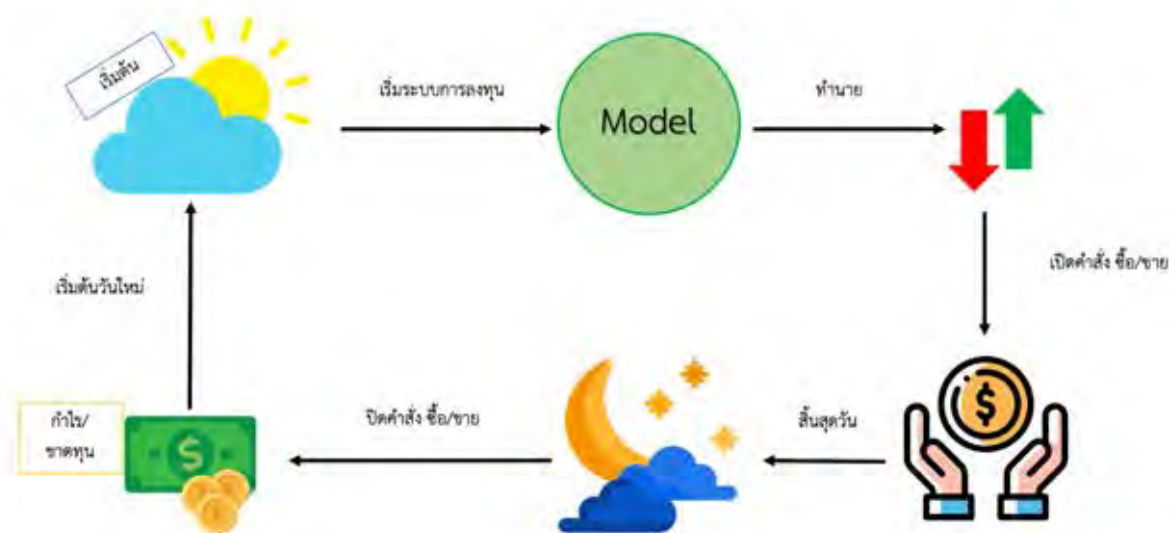
### วิธีการวิจัย

จากการศึกษาจากงานวิจัยต่าง ๆ ที่ผ่านมา ทางผู้วิจัยได้นำวิธีการของงานวิจัยในอดีตมาพัฒนาต่อโดยการนำโครงข่ายประสาทเทียมที่มีความซับซ้อนมากขึ้นมาทำการทดลอง โดยคาดหวังว่าผลลัพธ์ที่ได้จะมากขึ้นกว่างานวิจัยที่ผ่านมา

ในบทนี้จะกล่าวถึง รูปแบบการทำนายแนวโน้มรายวันของอัตราการแลกเปลี่ยนเงินตราระหว่างประเทศ การออกแบบโครงสร้างของโครงข่ายประสาทเทียม วิธีการปรับค่าพารามิเตอร์และ วิธีการทดลอง

#### 4.1 ระบบการลงทุนของงานวิจัย

สำหรับงานวิจัยนี้ ทางผู้วิจัยได้วางระบบการลงทุนไว้ คือ เปิดออเดอร์วันละหนึ่งครั้ง ณ เวลาเปิด โดยออเดอร์ที่เปิดนั้นจะมาจากการทำนายของโมเดล ซึ่งโมเดลจะทำนายว่า ณ วันนี้ อัตราแลกเปลี่ยนจะเพิ่มขึ้นหรือลดลง และ ทำการปิดออเดอร์ ณ เวลาปิด ในวันเดียวกับที่เปิดออเดอร์ ดังนั้น ในแต่ละวันจะมีออเดอร์อยู่เพียง 1 ออเดอร์



รูปที่ 4.1 ระบบการลงทุนของงานวิจัย

#### 4.2 โครงสร้างของโครงข่ายประสาทเทียม

ทางผู้วิจัยได้ออกแบบโครงสร้างของโครงข่ายประสาทเทียมแบบต่าง ๆ เพื่อหาโครงสร้างที่เหมาะสมสำหรับการทำนายแนวโน้มของอัตราการแลกเปลี่ยนเงินตราของโครงข่ายประสาทเทียมทั้งสี่สถาปัตยกรรม

1. Feed Forward Neural Networks จะแบ่งเป็น 4 แบบดังนี้
  1. Dense 128 หน่วย - Dense 64 หน่วย - Dense 32 หน่วย - Dense 32 หน่วย - Dense 1 หน่วย
  2. Dense 64 หน่วย - Dense 32 หน่วย - Dense 16 หน่วย - Dense 16 หน่วย - Dense 1 หน่วย
  3. Dense 32 หน่วย - Dense 16 หน่วย - Dense 8 หน่วย - Dense 8 หน่วย - Dense 1 หน่วย
  4. Dense 16 หน่วย - Dense 8 หน่วย - Dense 4 หน่วย - Dense 4 หน่วย - Dense 1 หน่วย
2. Convolutional Neural Networks จะแบ่งเป็น 4 แบบ ดังนี้
  1. CNN ตัวกรอง (filters) 8 แบบ - Dense 1 หน่วย
  2. CNN ตัวกรอง (filters) 16 แบบ - Dense 1 หน่วย
  3. CNN ตัวกรอง (filters) 32 แบบ - Dense 1 หน่วย
  4. CNN ตัวกรอง (filters) 64 แบบ - Dense 1 หน่วย
3. Long Short-Term Memory Neural Networks จะแบ่งเป็น 4 แบบ ดังนี้
  1. LSTM 10 หน่วย - Dense 1 หน่วย
  2. LSTM 10 หน่วย - LSTM 10 หน่วย - Dense 1 หน่วย
  3. LSTM 15 หน่วย - Dense 1 หน่วย
  4. LSTM 15 หน่วย - LSTM 15 หน่วย - Dense 1 หน่วย
4. Convolutional Long Short-Term Memory Neural Networks มี 2 แบบ ดังนี้
  1. CNN ตัวกรอง (filters) 64 แบบ - LSTM 10 หน่วย - Dense 1 หน่วย
  2. CNN ตัวกรอง (filters) 64 แบบ - LSTM 15 หน่วย - Dense 1 หน่วย

**หมายเหตุ** เครื่องหมาย – แทนการแบ่งชั้นของ ชั้นซ่อนตัว (hidden layers) แบบต่าง ๆ

Dense คือ Fully Connected Layer

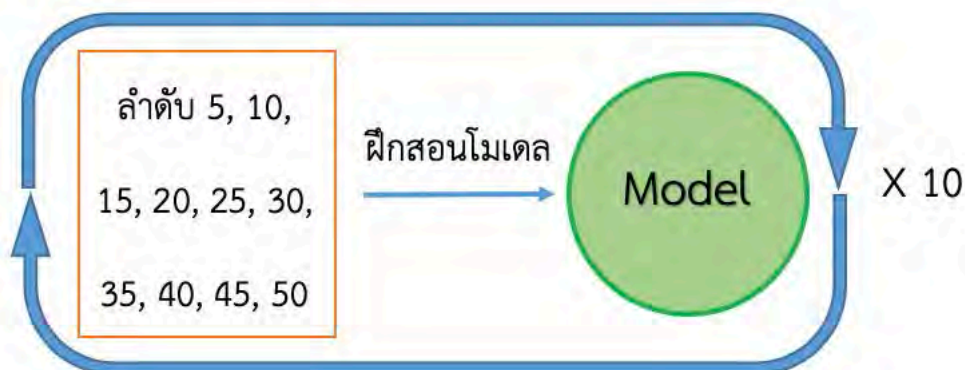
CNN คือ Convolutional Neural Network Layer

LSTM คือ Long Short-Term Memory Layer

### 4.3 การทดลอง

ในงานทดลองนี้จะแบ่งข้อมูลออกเป็น 3 ชุด คือ ชุดฝึกฝน (training set) ประกอบไปด้วยข้อมูลตั้งแต่ปีพ.ศ. 2553 ถึงปีพ.ศ. 2559 ชุดตรวจสอบ (validation set) เป็นข้อมูลในปีพ.ศ. 2560 และ ชุดทดสอบ (test set) เป็นข้อมูลในปีพ.ศ. 2561 จากนั้นนำข้อมูลไปปรับให้อยู่ในช่วงมาตรฐาน และ ปรับให้ข้อมูลอยู่ในรูปแบบของลำดับ แต่ละรูปแบบของลำดับจะนำมาฝึกสอน 10 ครั้ง ต่อ 1 โมเดล เนื่องจากว่าการประมวลผลแต่ละรอบจะได้ค่าน้ำหนักของโครงข่ายประสาทเทียมที่แตกต่างกัน ซึ่งค่าน้ำหนักที่แตกต่างกันนี้ทำให้ได้ผลการ

ทำนายที่แตกต่างกัน ดังนั้น ผู้วิจัยจึงประมวลผลหลาย ๆ ครั้ง เพื่อเพิ่มความน่าเชื่อถือของโมเดล จากนั้นนำค่าความถูกต้องและกำไรไปพล็อตลงบน Boxplot เพื่อนำมาวิเคราะห์ความสามารถของแต่ละโมเดลในการทำนายแนวโน้ม



รูปที่ 4.2 การทดลองฝึกสอนโมเดล 10 ครั้ง

#### 4.4 การวัดผลการวิจัย

งานวิจัยที่ผ่านมาใช้ความถูกต้องในการวัดผล ซึ่งการใช้ความถูกต้องในการวัดผลจะสามารถบอกได้แค่ ว่า โมเดลมีความสามารถในการทำนายดีหรือไม่ แต่สำหรับการลงทุน จะไม่พิจารณาแค่การทำนายถูกหรือทำนายผิด แต่จะพิจารณาด้วยว่า เมื่อทำนายถูกแล้วจะได้กำไรเท่าไร หรือ เมื่อทำนายผิดแล้วจะขาดทุนเท่าไร ดังนั้น งานวิจัยนี้ได้แบ่งวิธีการวัดผลออกเป็นสองแบบ คือ

1. ความถูกต้อง คือ การตรวจสอบว่าโมเดลทำนายถูกต้องกี่เปอร์เซ็นต์

$$\text{ความถูกต้อง (Accuracy)} = \frac{\text{จำนวนครั้งที่ทำนายถูก} \times 100}{\text{จำนวนทั้งหมดที่ทำนาย}}$$

2. กำไร คือ การตรวจสอบว่าโมเดลสามารถทำกำไรได้กี่เปอร์เซ็นต์เมื่อเทียบกับกำไรทั้งหมด

$$\text{กำไร (Profit)} = \frac{\text{ผลรวมของกำไรขาดทุนในแต่ละวัน} \times 100}{\text{ผลรวมของกำไรเมื่อทำนายถูกทั้งหมด}}$$

ในปี 2561 ถ้าสามารถทำนายได้ถูกต้องทุกวัน จะได้กำไรทั้งหมด 93,841 จุด โดยในงานวิจัยนี้ จะแสดงผลในรูปแบบเปอร์เซ็นต์ตามสูตรข้อที่ 2

## บทที่ 5

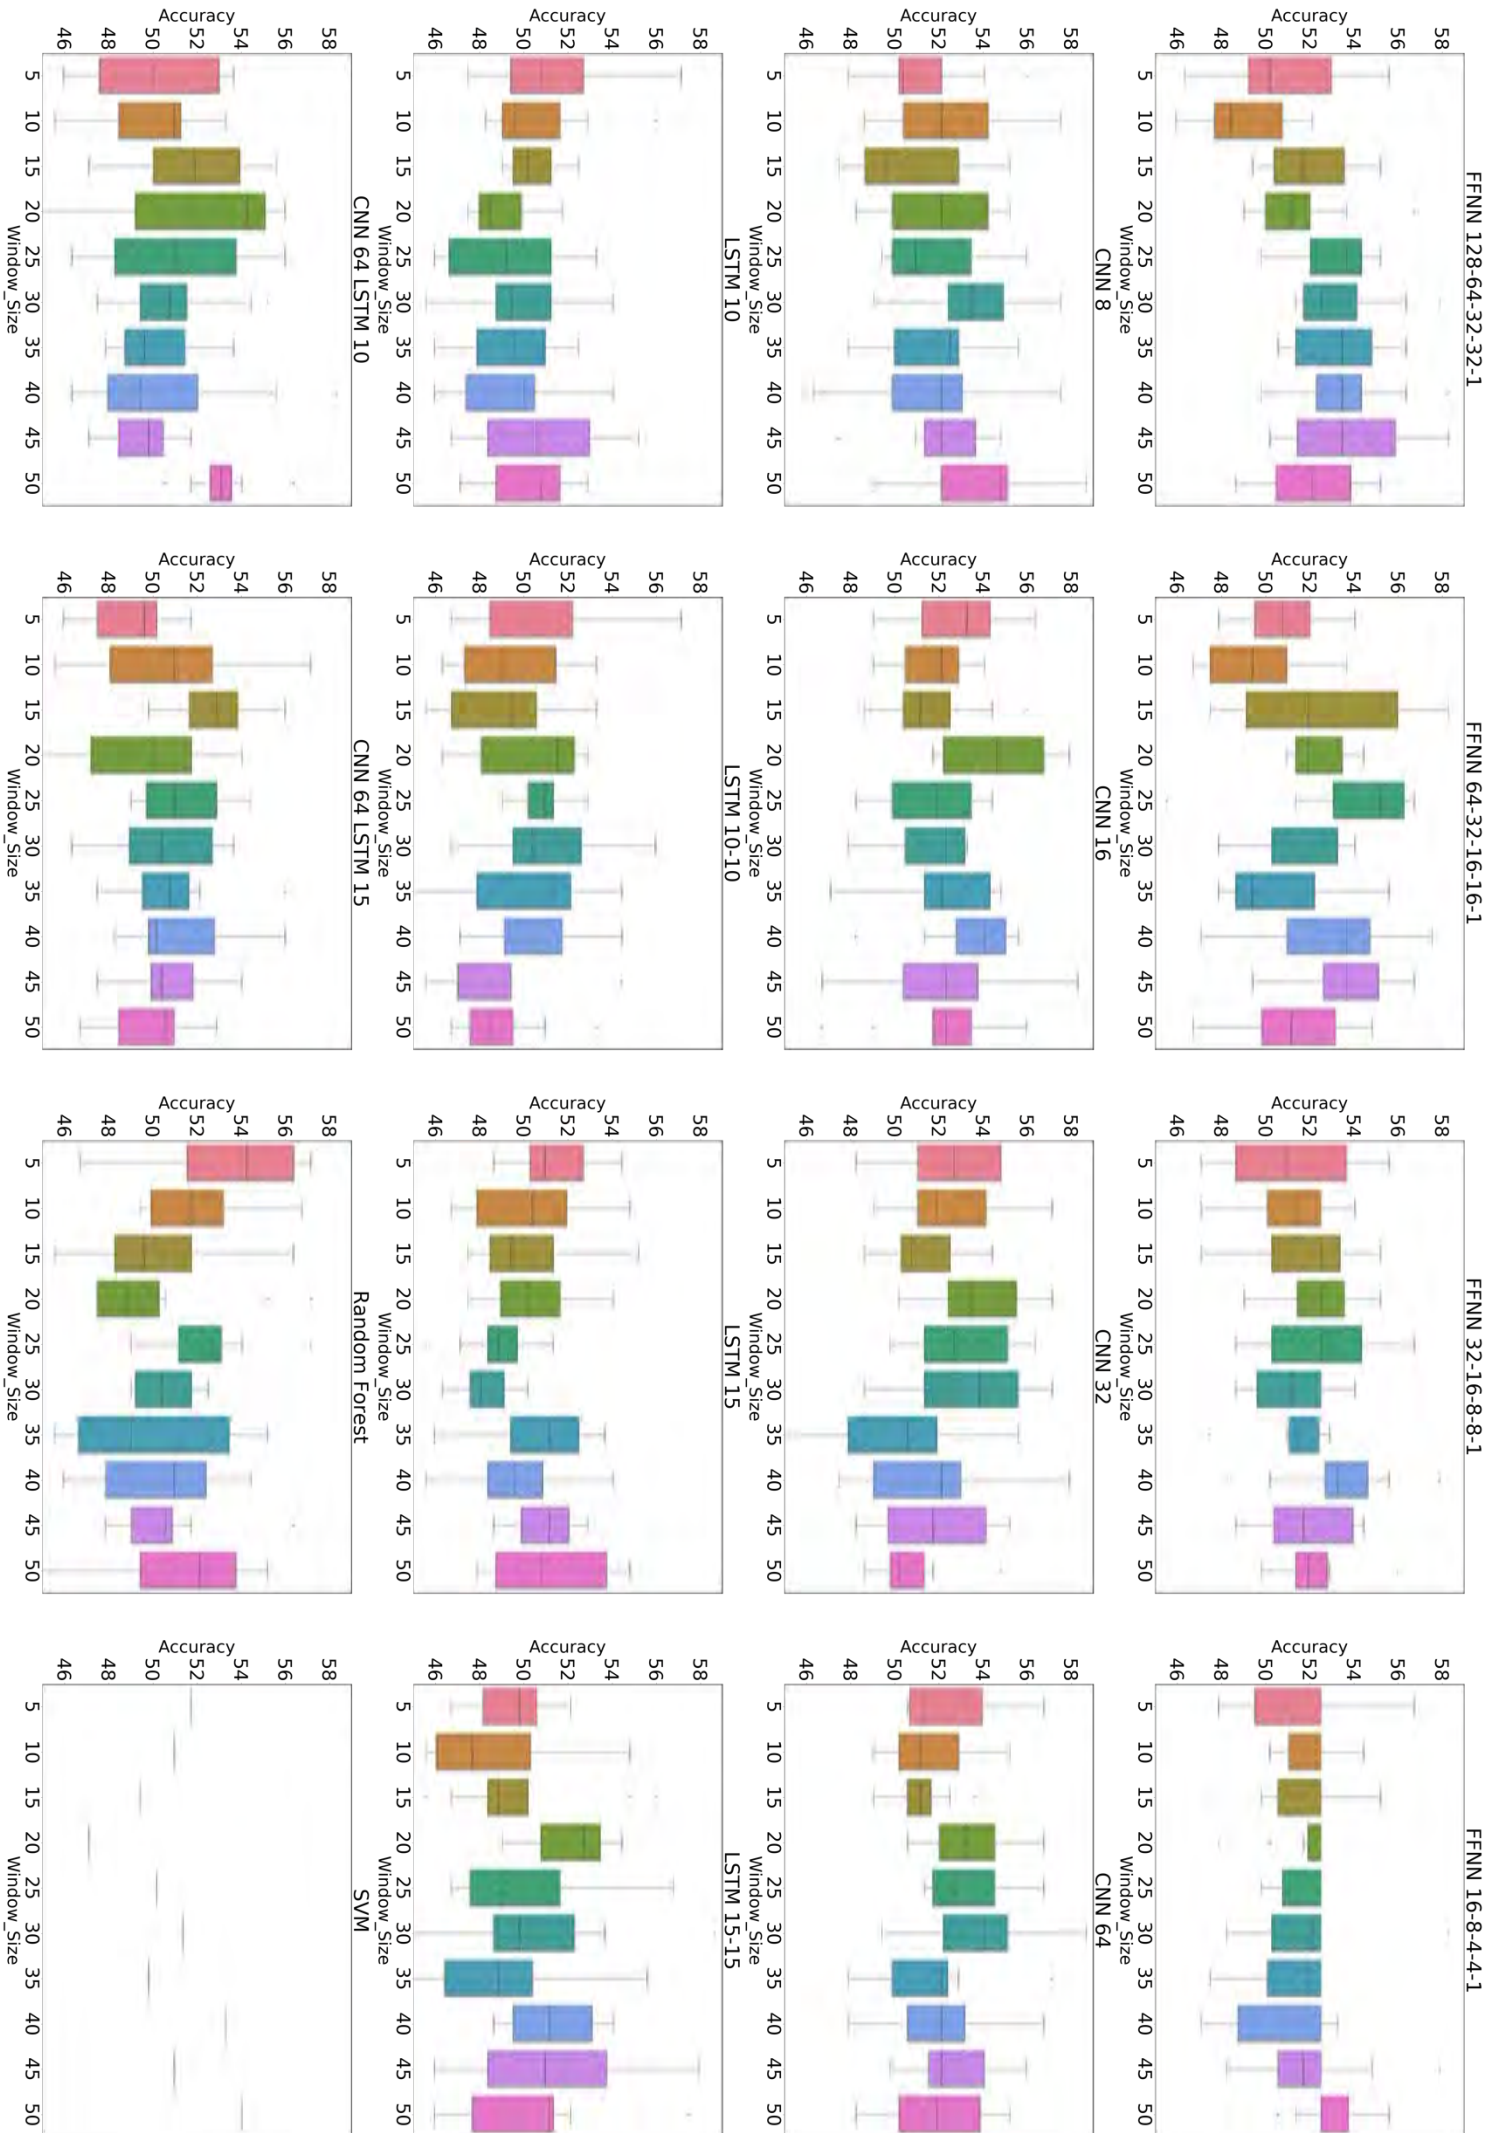
### ผลการวิจัย

ในบทนี้จะกล่าวถึง ผลของการดำเนินการวิจัยของโมเดลทั้ง 4 แบบ คือ 1. Feed Forward Neural Network 2. Convolutional Neural Network 3. Long Short-Term Memory Neural Network และ 4. Convolutional Long Short-Term Memory Neural Network และ สรุปผลการวิจัยทั้งหมด

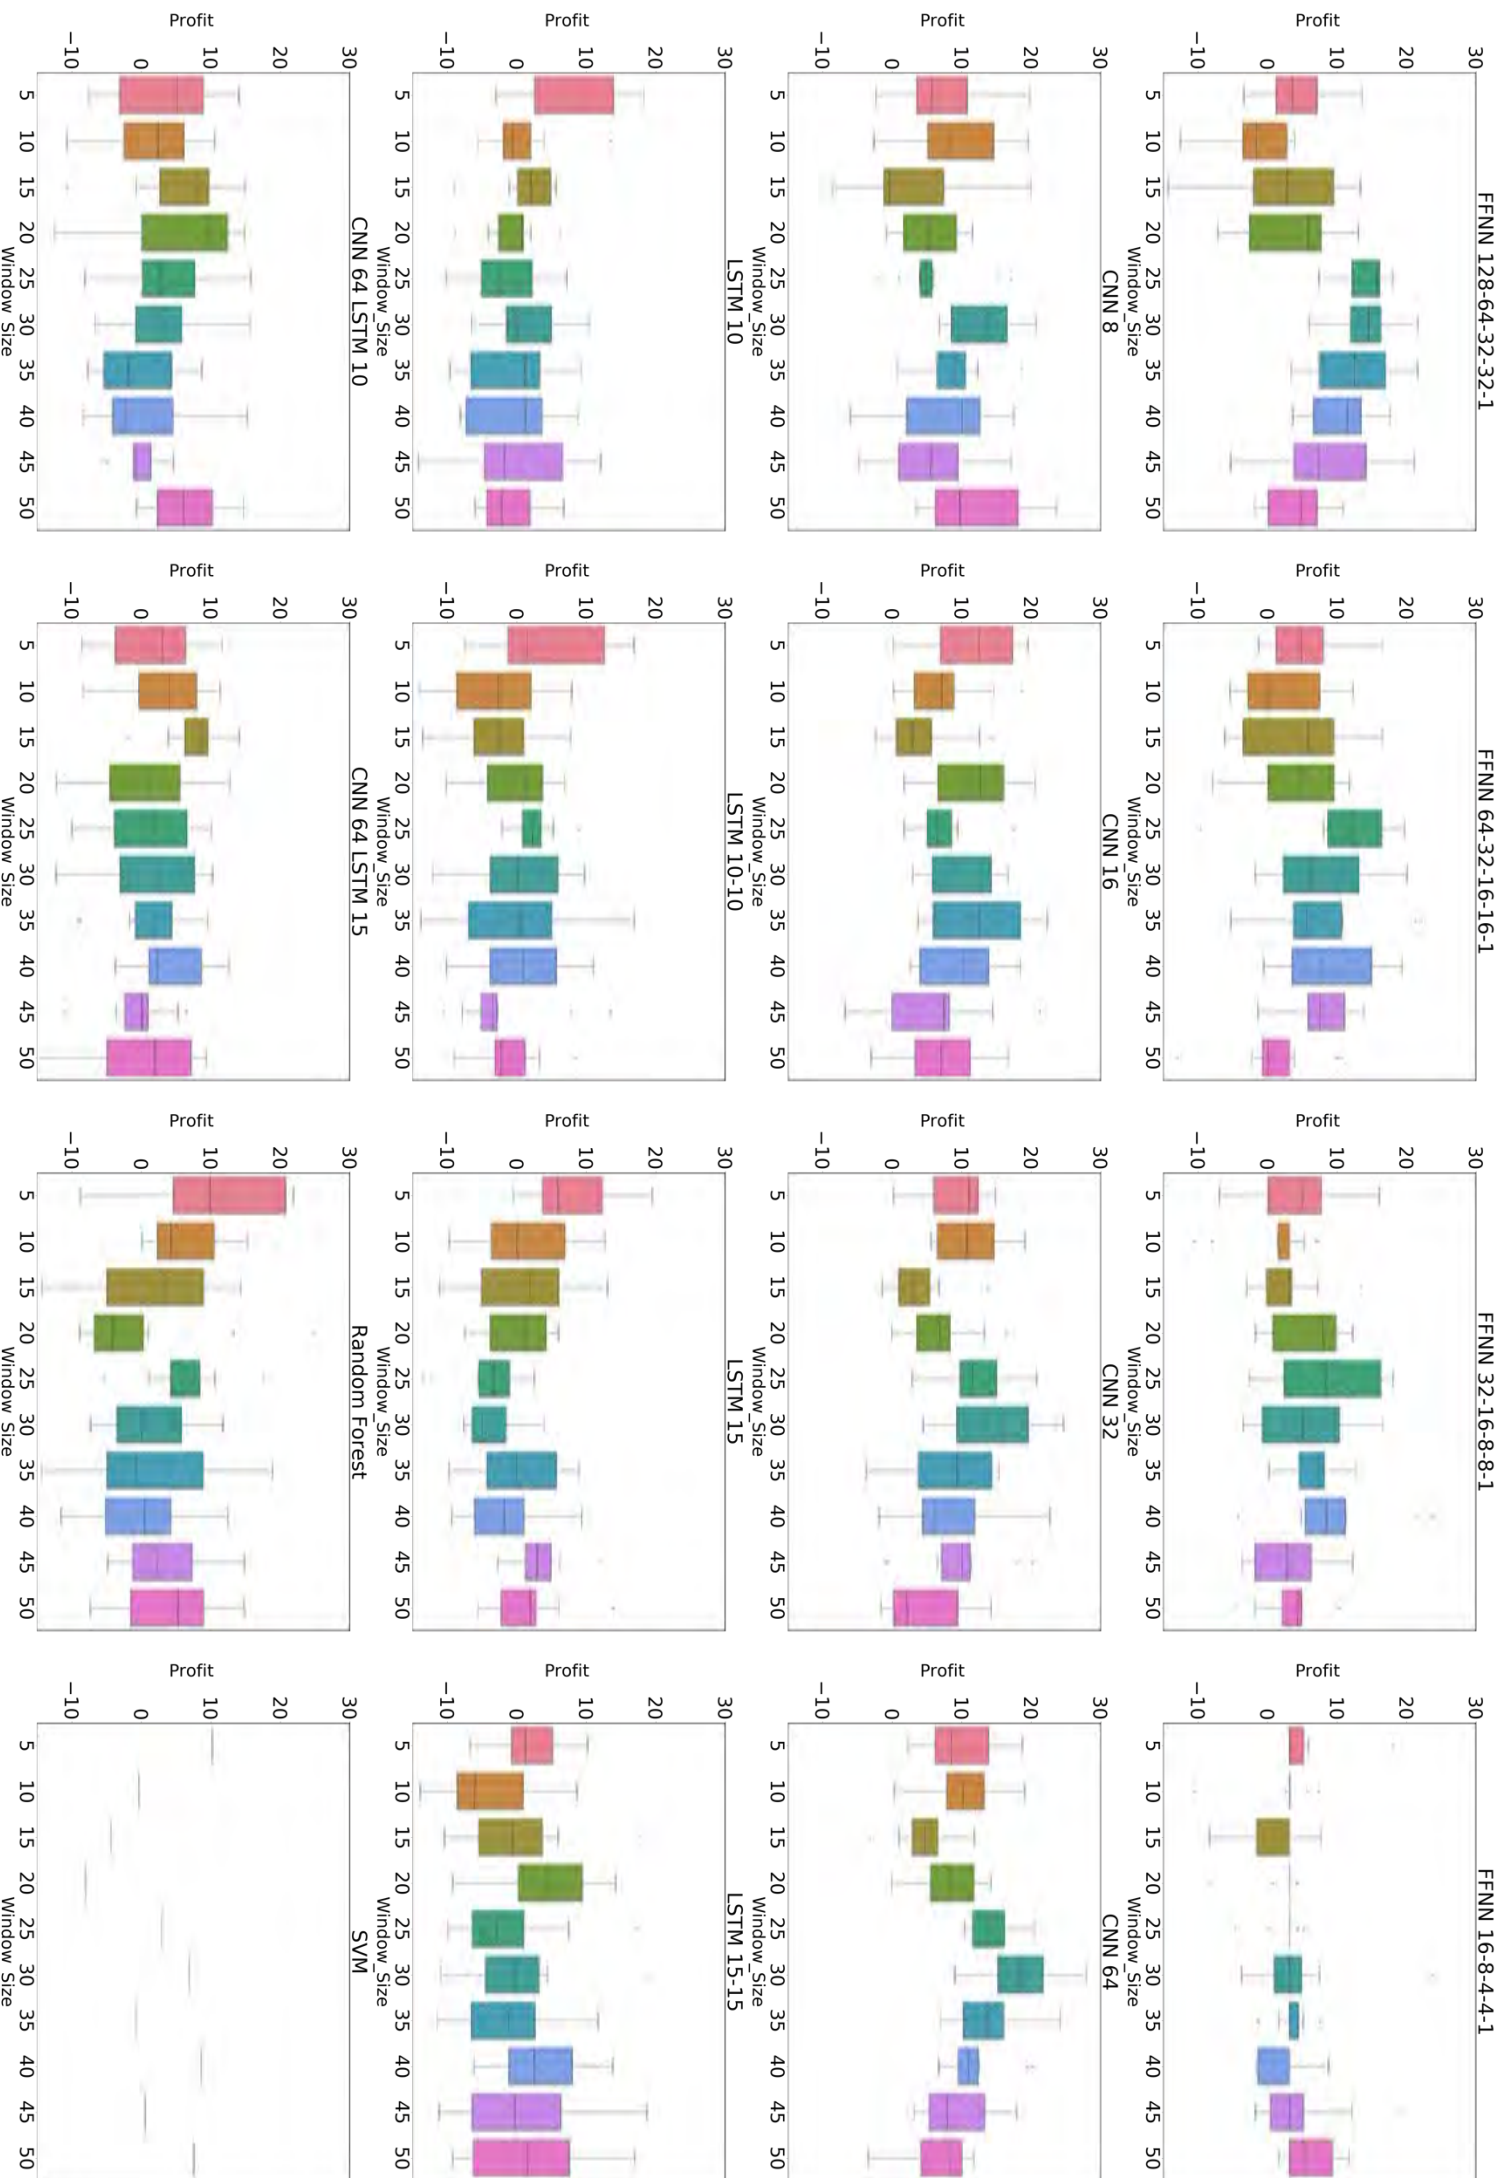
#### 5.1 ผลของการดำเนินการวิจัย

ความหมายของตัวย่อ

1. FFNN คือ Feed Forward Neural Network
2. CNN คือ Convolutional Neural Network
3. LSTM คือ Long Short-Term Memory
4. CLSTM คือ Convolutional Long Short-Term Memory
5. SVM คือ Support Vector Machine



รูปที่ 5.1 แสดงการเปรียบเทียบประสิทธิภาพการตัด



รูปที่ 5.2 แสดงผลการเปรียบเทียบกำไร

จากผลการทดลอง โดยแต่ละโมเดลทำการฝึกสอน 10 ครั้ง และวัดประสิทธิภาพในการทำนายแนวโน้ม ได้ผลดังรูปที่ 5.1 โดยพบว่าทุกโมเดลมีประสิทธิภาพในการทำนายแนวโน้มใกล้เคียงกัน แต่เมื่อพิจารณาประสิทธิภาพในการทำไจากรูปที่ 5.2 จะพบว่า CNN เป็นสถาปัตยกรรมที่สามารถทำกำไรได้ดีที่สุด และกำไรน้อยสุดก็ไม่เกิดการติดลบ และ ตามมาด้วย FFNN แต่สำหรับ LSTM และ CLSTM รวมถึง Random Forest และ SVM ที่แม้ว่าจะมีค่าความถูกต้องเฉลี่ยไม่ต่างกันมาก แต่กำไรรวมน้อยกว่า CNN ครั้งหนึ่ง และบางครั้งขาดทุนยกเว้น SVM

## 5.2 เปรียบเทียบความสามารถของแต่ละสถาปัตยกรรม

ในส่วนนี้จะทำการเปรียบเทียบความสามารถของแต่ละสถาปัตยกรรม โดยแบ่งออกเป็น 2 แบบ ดังนี้

### 1. เปรียบเทียบจากความถูกต้องเฉลี่ยสูงสุดของแต่ละสถาปัตยกรรม

สถาปัตยกรรม	โมเดล	Windows Size	ความถูกต้องสูงสุด	ความถูกต้องน้อยสุด	ความถูกต้องเฉลี่ย
FFNN	Dense 64 หน่วย - Dense 32 หน่วย - Dense 16 หน่วย - Dense 16 หน่วย - Dense 1 หน่วย	25	56.76 %	45.56 %	54.05 %
CNN	CNN ตัวกรอง 16 แบบ - Dense 1 หน่วย	20	57.92 %	51.74 %	54.56 %
LSTM	LSTM 15 หน่วย - LSTM 15 หน่วย - Dense 1 หน่วย	20	54.44 %	49.03 %	52.12 %
CNN + LSTM	CNN ตัวกรอง (filters) 64 แบบ - LSTM 10 หน่วย - Dense 1 หน่วย	50	56.37 %	50.58 %	53.13 %
Random Forest	Random Forest	5	57.14 %	46.72 %	53.55 %
SVM	SVM	50	54.05 %	54.05 %	54.05 %

ตารางที่ 5.1 สรุบบโมเดลที่ดีที่สุดจากความถูกต้องเฉลี่ย



ผลสรุปของการดำเนินการวิจัย โดยเปรียบเทียบจากสถาปัตยกรรมที่มีความถูกต้องเฉลี่ยมากที่สุดจากมากไปน้อย ดังนี้ Convolutional Neural Network มีความถูกต้องเฉลี่ย 54.56% Feed Forward Neural Network มีความถูกต้องเฉลี่ย 54.05% Convolutional Long Short-Term Memory มีความถูกต้องเฉลี่ย 53.13% และ Long Short-Term Memory มีความถูกต้องเฉลี่ย 52.12%

## 2. เปรียบเทียบจากกำไรเฉลี่ยสูงสุดของแต่ละสถาปัตยกรรม

สถาปัตยกรรม	โมเดล	Windows Size	กำไรสูงสุด	กำไรน้อยสุด	กำไรเฉลี่ย
FFNN	Dense 128 หน่วย - Dense 64 หน่วย - Dense 32 หน่วย - Dense 32 หน่วย - Dense 1 หน่วย	25	18.03 (16,917)	7.39 (6,935)	14.12 (13,249)
CNN	<b>CNN ตัวกรอง 64 แบบ - Dense 1 หน่วย</b>	<b>30</b>	<b>27.95</b> <b>(26,229)</b>	<b>9.02</b> <b>(8,467)</b>	<b>18.89</b> <b>(17,730)</b>
LSTM	LSTM 10 หน่วย - Dense 1 หน่วย	5	18.26 (17,131)	-3.02 (-2,833)	8.43 (7,906)
CNN + LSTM	CNN ตัวกรอง (filters) 64 แบบ - LSTM 15 หน่วย - Dense 1 หน่วย	15	14.11 (13,239)	-1.97 (-1,849)	7.84 (7,353)
Random Forest	Random Forest	5	21.87 (21,457)	-8.78 (-8,235)	10.36 (9,725)
SVM	SVM	40	8.58 (8,049)	8.58 (8,049)	8.58 (8,049)

ตารางที่ 5.2 สรุปโมเดลที่ดีที่สุดจากกำไรเฉลี่ย

ผลสรุปของการดำเนินการวิจัย โดยเปรียบเทียบจากสถาปัตยกรรมที่มีกำไรเฉลี่ยมากที่สุดจากมากไปน้อย ดังนี้ Convolutional Neural Network มีกำไรเฉลี่ย 18.89% หรือคิดเป็น 17,730 จุด Feed Forward Neural Network มีกำไรเฉลี่ย 14.12% หรือคิดเป็น 13,249 จุด Long Short-Term Memory มีกำไรเฉลี่ย 8.43% หรือคิดเป็น 7,906 และ Convolutional Long Short-Term Memory มีกำไรเฉลี่ย 7.84% หรือคิดเป็น 7,353

### 5.3 สรุปผลของการดำเนินการวิจัย

จากผลการทดลอง CNN มีความสามารถในการจับรูปแบบของข้อมูลที่เป็นช่วงเวลา สามารถทำนายแนวโน้มรายวันได้ดีที่สุด เมื่อเทียบกับ FFNN โดยสาเหตุน่าจะมาจาก CNN ใช้พารามิเตอร์น้อยกว่าเนื่องจาก CNN มีการใช้ค่าน้ำหนักร่วมกัน และ CNN พยายามที่จะจับรูปแบบของข้อมูลที่เป็นช่วงเวลามากกว่า FFNN ด้วยการปรับค่าพารามิเตอร์ของแต่ละตัวกรอง (filters) เมื่อตัวกรองของ CNN มีหลากหลายรูปแบบ นั้นหมายความว่า CNN พยายามที่จะหารูปแบบของอินดิเคเตอร์ที่หลากหลาย เพื่อทำนายแนวโน้มมากกว่า FFNN ซึ่งพยายามที่จะจับรูปแบบของอินดิเคเตอร์แค่แบบเดียว สำหรับ LSTM และ CNN + LSTM ทางผู้วิจัยคาดว่า โมเดลมีขั้นตอนที่ซับซ้อนในระหว่างการปรับพารามิเตอร์มากเกินไป ทำให้ทั้งสองโมเดลนี้ได้ผลลัพธ์ที่ยังไม่ดีเท่า FFNN และ CNN

โดยการทดลองทั้งหมด ทางผู้วิจัยพบว่า ทุกโมเดลนั้นเกิดปัญหา Overfitting ซึ่งเป็นปัญหาที่โมเดลปรับพารามิเตอร์เพื่อให้สามารถทำนายชุดฝึกฝนได้อย่างแม่นยำ แต่พารามิเตอร์ที่ได้มาหลังจากการฝึกฝนอาจจะไม่ใช่พารามิเตอร์ที่เป็นรูปแบบที่แท้จริงของข้อมูล ทำให้การนำโมเดลไปใช้กับข้อมูลที่นอกเหนือจากชุดฝึกฝนได้ผลลัพธ์ที่ไม่ดีเท่าที่ควร สำหรับงานวิจัยนี้ โมเดลต่าง ๆ สามารถทำนายได้ค่าความถูกต้องอยู่ในช่วงระหว่าง 45 – 58 % โดยปัญหา Overfitting นี้ ทางผู้วิจัยคาดว่าเกิดจากรูปแบบของข้อมูลที่ซับซ้อนจนโมเดลไม่สามารถปรับพารามิเตอร์ให้เข้ากับข้อมูลใด ๆ ได้ แต่โมเดลปรับพารามิเตอร์ให้เข้ากับรูปแบบของข้อมูลแค่บางรูปแบบเท่านั้น ทางผู้วิจัยจึงนำ Random Forest ซึ่งเป็นโมเดลที่ไม่ค่อยเกิดปัญหา Overfitting เนื่องจากโมเดลจะใช้ข้อมูลย่อย (sub data) มาใช้ในการเรียนรู้ ซึ่งผลลัพธ์ก็ยังคงเกิด Overfitting เหมือนกับโครงข่ายประสาทเทียมที่ทำการวิจัยในงานนี้ แต่ผลของความถูกต้องโครงข่ายประสาทเทียมสามารถได้ผลลัพธ์ที่ดีกว่า Random Forest

ในส่วนของการวัดผลด้วยกำไร จากการที่โมเดลทำนายถูกเพียงแค่ 45 - 58 % แต่ในระยะเวลาหนึ่งปีโมเดลสามารถทำกำไรได้ นั้นหมายความว่า โมเดลสามารถทำนายแนวโน้มได้ถูกต้องและแนวโน้มที่ทำนายได้นั้น มีปริมาณของกำไรมากกว่าการทำนายแนวโน้มที่ผิด ตามที่ได้รายงานไว้ข้างต้นโมเดลที่นำมาทดลอง มีทั้งโมเดลที่สามารถทำกำไรได้ดีและทำกำไรได้ไม่ดี ซึ่งขึ้นอยู่กับลักษณะของโมเดล

## บทที่ 6

### ข้อสรุปและข้อเสนอแนะ

#### 6.1 สรุปผลการดำเนินงาน

ในงานนี้ทางผู้วิจัยได้ทดลองสถาปัตยกรรมของโครงข่ายประสาทเทียม 4 แบบ ดังนี้ 1. Feed Forward Neural Networks 2. Convolutional Neural Networks 3. Long Short-Term Memory และ 4. Convolutional Long Short-Term Memory โดยใช้ Keras ในการพัฒนาโครงข่ายประสาทเทียม การทดลองจะแบ่งลำดับของอินดิเคเตอร์ออกเป็น 10 แบบ คือ 5 10 15 20 25 30 35 40 45 และ 50 วัน โดยแต่ละแบบจะทำการฝึกฝนเพื่อสร้างโมเดล 10 ครั้ง ต่อ 1 สถาปัตยกรรม

ผลการทดลองในด้านความถูกต้อง เกิดปัญหาเรื่อง Overfitting แต่เมื่อพิจารณาในด้านกำไร พบว่า มีโมเดลที่สามารถทำนายได้ถูกต้อง โดยวันที่ทายถูกนั้นมีกำไรมากกว่าขาดทุนของวันที่ทำนายผิด ทำให้กำไรโดยรวมมีค่าเป็นบวกได้

#### 6.2 ปัญหาของงานวิจัยและวิธีการแก้ไข

**ปัญหาที่ 1 :** ระหว่างการทำวิจัย ในช่วงแรกโมเดลได้ผลลัพธ์ที่ดีเป็นอย่างมาก แต่เมื่อผู้วิจัยตรวจเช็คแล้วพบว่า ข้อมูลที่เตรียมไว้นั้นผิด และเมื่อทำการแก้ไขให้ถูกต้องพบว่า โมเดลที่เคยทำไว้มีผลการทำนายลดลง

**วิธีแก้ไขปัญหา :** ผู้วิจัยได้ค้นหางานวิจัยที่ผ่านมาเพิ่มเติม จึงพบว่ามีหลายงานวิจัยได้ผลลัพธ์ใกล้เคียงกัน จากนั้นผู้วิจัยได้รับคำแนะนำจากอาจารย์ที่ปรึกษาโครงการ จึงนำไปทดลองในรูปแบบต่าง ๆ จึงได้ผลลัพธ์ที่ดีขึ้น

## รายการอ้างอิง

- [1] forexthai. รวมคำศัพท์ Forex[online]. (n.d.). Available from: <https://www.forexthai.in.th>  
[2018, November 5]
- [2] Jingtao Yao, Chew Lim Tan. A case study on using neural networks to perform technical forecasting of forex. Neurocomputing. 34 (2000): 79-98
- [3] Jigar Patel, Sahil Shah, Priyank Thakkar, K. Kotecha. Predicting stock and stock price index movement using Trend Deterministic Data Preparation and machine learning techniques. Expert Systems with Applications. 42 (2015): 259-268
- [4] Areej Abdullah Baasher, Mohamed Waleed Fakhr. FOREX Trend Classification using Machine Learning Techniques. Recent Researches in Applied Informatics and Remote Sensing. 11 (2011): 41-47
- [5] Mehdi Khashei, Mehdi Bijari. An artificial neural network (p,d,q) model for timeseries forecasting. Expert Systems with Applications. 37 (2010): 479-489
- [6] A.N. Refenes, M. Azema-Barac, L. Chen, S. A. Karoussos. Currency exchange rate prediction and neural network design strategies. Neural Computing & Applications. 1 (1993): 46-58
- [7] Malkiel, B. G. (2003). The efficient market hypothesis and its critics. Journal of economic perspectives 17 (1), 59-82.
- [8] Matthew Dixon, Diego Klabjan, and Jin Hoon Bang. 2016. Classification-based Financial Markets Prediction using Deep Neural Networks. arXiv preprint arXiv:1603.08604 (2016)

- [9] A. Borovykh, S. Bohte, and C. W. Oosterlee. Conditional time series forecasting with convolutional neural networks. preprint arXiv:1703.04691, 2017.
- [10] T. Fisher and C. Krauss, Deep learning with Long Short-Term Memory networks for financial market predictions, FAU Discussion papers in Economics, (2017).
- [11] S. Serrarens, Comparing Convolutional and LSTN Neural Networks for Intraday Forex Direction Prediction, (2017).
- [12] Technical indicators and overlays. (2018). Available from:  
[http://stockcharts.com/school/doku.php?id=chart\\_school:technical\\_indicator](http://stockcharts.com/school/doku.php?id=chart_school:technical_indicator)[2019, April 19]
- [13] metatrader5. Technical Indicators[online]. (n.d). Available from:  
[https://www.metatrader5.com/en/terminal/help/charts\\_analysis/indicatods](https://www.metatrader5.com/en/terminal/help/charts_analysis/indicatods)[2019, April 19]



ภาคผนวก

# แบบเสนอหัวข้อโครงการ รายวิชา 2301399 Project Proposal

## ปีการศึกษา 2561

ชื่อโครงการ (ภาษาไทย)	การศึกษาเชิงเปรียบเทียบของสถาปัตยกรรมโครงข่ายประสาทเทียมเชิงลึกใน การทำนายแนวโน้มรายวันของอัตราแลกเปลี่ยนเงินดอลลาร์ สหรัฐอเมริกาเทียบกับเยนญี่ปุ่น
ชื่อโครงการ (ภาษาอังกฤษ)	A comparative study of deep neural network architectures for forex daily trend prediction on USD/JPY currency pair
อาจารย์ที่ปรึกษา	อ.ดร.นฤมล ประทานวณิช
ผู้ดำเนินการ	1. นายบุญยัส ศรีสมพงษ์ 5833639723 2. นายสรวิศ เลิศอำไพสกุลวงศ์ 5833664323 สาขาวิชาคณิตศาสตร์ วิทยาการคอมพิวเตอร์ ภาควิชาคณิตศาสตร์และ วิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

### หลักการและเหตุผล

ตลาดแลกเปลี่ยนเงินตราต่างประเทศ (Foreign Exchange Market) เป็นตลาดการเงินที่ใหญ่ที่สุดในบรรดาตลาดการลงทุนทั้งหมด ด้วยการซื้อขายมากกว่าหนึ่งล้านล้านดอลลาร์สหรัฐต่อวัน [1] การทำนายอัตราแลกเปลี่ยนเงินตราต่างประเทศนั้น ทำให้เกิดการทดลองและทฤษฎีต่าง ๆ เป็นจำนวนมาก ซึ่งอัตราแลกเปลี่ยนเงินตราต่างประเทศนั้น จะขึ้นกับหลาย ๆ ปัจจัยด้วยกัน ไม่ว่าจะเป็น สภาพเศรษฐกิจ การเมืองหรือแม้แต่ปัจจัยทางด้านจิตวิทยา ปัจจัยเหล่านี้เป็นอะไรที่ค่อนข้างซับซ้อน ดังนั้นการทำนายการเปลี่ยนแปลงของอัตราแลกเปลี่ยนจึงเป็นอะไรที่ค่อนข้างทำได้ยาก มีนักวิจัยและนักลงทุนหลายคนได้พยายามอย่างต่อเนื่องเพื่อที่จะอธิบายการเคลื่อนที่ของอัตราแลกเปลี่ยน ทำให้เกิดการพัฒนาวิธีทำนายหลากหลายรูปแบบขึ้น การวิเคราะห์ทางเทคนิค (technical analysis) และ การวิเคราะห์ปัจจัยพื้นฐาน (fundamental analysis) เป็นวิธีการหลักที่นิยมในการทำนายทางการเงิน ซึ่งเหมือนกับตลาดการลงทุนอื่น ๆ อย่างเช่น ตลาดหุ้น ตลาดแลกเปลี่ยนเงินตราต่างประเทศมีรูปแบบเฉพาะตัว การหาโมเดลเพื่อให้เหมาะสมกับรูปแบบของตลาดแลกเปลี่ยนเงินตราต่างประเทศจึงมีความน่าสนใจ

การวิเคราะห์ทั้ง 2 ประเภท มีความแตกต่างกัน ดังนี้ การวิเคราะห์ปัจจัยพื้นฐาน นักลงทุนจะต้องพิจารณาถึงสถานะทางการเงินของประเทศ นั้น ๆ และศึกษาผลกระทบของอุปสงค์และอุปทานของแต่ละคู่เงิน ส่วนการวิเคราะห์ทางเทคนิคนั้นจะพิจารณาตัวแปรต่าง ๆ ตัวอย่างเช่น ทิศทางการเคลื่อนที่ของอัตรา



แลกเปลี่ยน ซึ่งสามารถระบุได้โดยใช้ตัวชี้วัดเชิงเทคนิค (technical indicators) ต่าง ๆ รูปแบบของกราฟ ปริมาณการซื้อขาย เป็นต้น สุดท้ายผลการวิเคราะห์ที่ได้จะนำมาใช้ตัดสินใจในการลงทุน

งานวิจัยที่ผ่านมาได้มีการนำตัวชี้วัดหรือราคาในอดีตมาใช้เป็นข้อมูลขาเข้า (features) ของ ตัวแบบ (models) Jingtao Yao และ Chew Lim Tan [2] ได้ประยุกต์ใช้โครงข่ายประสาทเทียม (artificial neural networks) ในการทำนายอัตราแลกเปลี่ยนระหว่างดอลลาร์สหรัฐกับอีก 5 สกุลเงินหลัก โดยได้มีการ ทำการทดลองบนโมเดลที่ใช้อัตราแลกเปลี่ยนรายสัปดาห์ในอดีตและปัจจุบันเพื่อทำนายอัตราแลกเปลี่ยนใน สัปดาห์ข้างหน้า และได้ทำการทดลองบนโมเดลที่ใช้อินดิเคเตอร์เชิงเทคนิค ซึ่งโมเดลที่ใช้อินดิเคเตอร์ได้ ผลลัพธ์ที่ดีกว่าโมเดลที่ใช้ราคาในอดีตอย่างเห็นได้ชัด Patel และคณะ [3] ได้ทำการทดลองกับหุ้น โดยใช้อินดิ เคเตอร์เป็นข้อมูลนำเข้าเช่นเดียวกันแต่มีการกำหนดเงื่อนไขเพื่อเปลี่ยนตัวเลขที่เป็นจำนวนจริงของค่าอินดิเค เตอร์ไปเป็นค่า +1 หมายถึงแนวโน้มขาขึ้น หรือ -1 หมายถึงแนวโน้มขาลง จากนั้นถึงนำไปใช้งานกับโมเดลต่าง ๆ คือ Feed forward model, SVM model, Random forest และ Naive-Bayes classifier ซึ่งได้ความ แม่นยำสูงถึง 90%

ข้อมูลขาออกที่จะทำนาย (Target) แบ่งได้หลัก ๆ 2 ประเภท คือ การทำนายแนวโน้มและการทำนาย ราคาเป้าหมาย โดยการทำนายแนวโน้มคือการทำนายทิศทางของตลาด มีงานวิจัยที่นำอินดิเคเตอร์มาใช้เพื่อ ทำนายแนวโน้มในอนาคต แต่ผลสรุปของการทดลองนี้กล่าวว่า โครงข่ายประสาทเทียมให้ผลลัพธ์แย่มากที่สุด [3] ซึ่งผู้จัดทำคิดว่าเป็นผลมาจากการออกแบบโครงข่ายประสาทเทียมที่ยังไม่ดีเท่าที่ควร ในส่วนการทำนายราคา เป้าหมาย คือการใช้ข้อมูลในอดีตมาคาดการณ์ราคาในอนาคต โดยมีงานวิจัยที่นำราคาและอินดิเคเตอร์ในอดีต มาใช้เพื่อทำนายเป้าหมายของราคาในอนาคต [2]

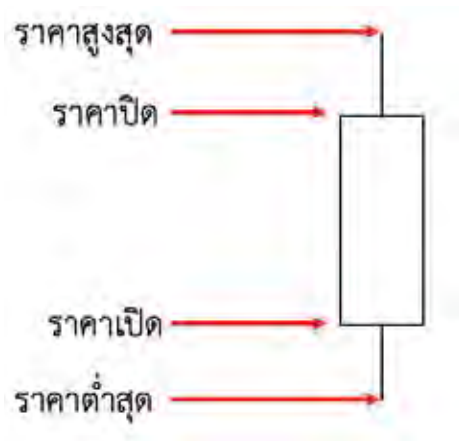
จากงานวิจัยที่ผ่านมา มีงานที่ทำทดลองในตลาดหุ้นและตลาดแลกเปลี่ยนเงินตราต่างประเทศ ซึ่งมีทั้งการทำนายแนวโน้มและการทำนายราคาเป้าหมาย โดยมีหลากหลายโมเดลถูกนำมาทดลอง หนึ่งในนั้น ก็คือ โครงข่ายประสาทเทียมเชิงลึก (deep neural networks) ในโครงการนี้ผู้ดำเนินการสนใจที่จะนำ โครงข่ายประสาทเทียมเชิงลึกมาเปรียบเทียบความสามารถในการทำนายแนวโน้มของราคาในตลาด แลกเปลี่ยนเงินตราต่างประเทศของคู่เงินดอลลาร์สหรัฐอเมริกากับเยนญี่ปุ่น โดยมีรูปแบบข้อมูลขาเข้าเป็น อินดิเคเตอร์หรือราคาในอดีต และมีรูปแบบข้อมูลขาออกเป็นแนวโน้มของอัตราแลกเปลี่ยน

### ลักษณะข้อมูล

ชุดข้อมูลที่ใช้ นำมาจากโปรแกรม Metatrader 4 โดยการใช้ภาษา MQL4 ในการเข้าถึงข้อมูล ข้อมูล ที่นำมาใช้ประกอบด้วย ราคาเปิด ราคาปิด ราคาสูงสุด ราคาต่ำสุด และ อินดิเคเตอร์


### รูปแบบกราฟแท่งเทียน

1. แท่งเทียนสีขาวแสดงถึงราคาปิดอยู่สูงกว่าราคาเปิด เรียกว่า แท่งขาขึ้น ดังรูปที่ 1



รูปที่ 1 รูปแบบแท่งขาขึ้น

2. แท่งเทียนสีดำแสดงถึงราคาปิดอยู่ต่ำกว่าราคาเปิด เรียกว่า แท่งขาลง ดังรูปที่ 2




รูปที่ 2 รูปแบบแท่งขาลง

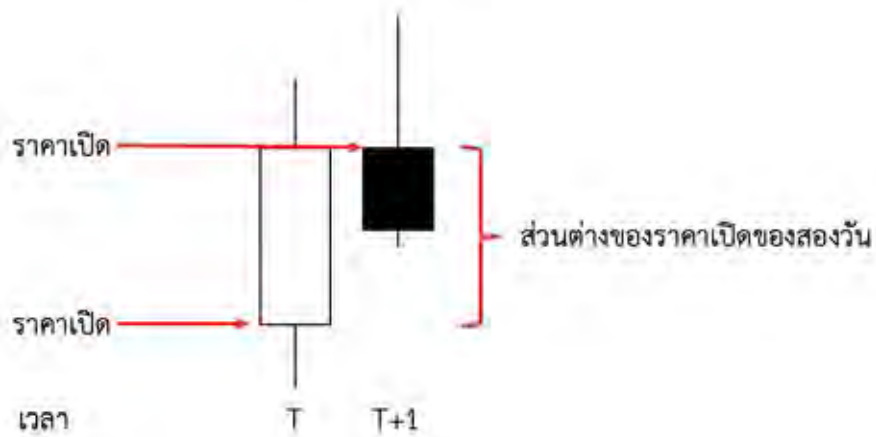
### แนวโน้มราคา

ในโครงการนี้ จะสนใจที่ราคาเปิดเป็นหลัก สามารถพิจารณาแนวโน้มจากราคาเปิดได้ 2 แบบ ดังนี้

3. พิจารณากราฟราคาเปิดวันที่ T ถ้าราคาเปิดของวันที่ T+1 อยู่สูงกว่าราคาเปิดของวันที่ T เหตุการณ์นี้ จะเรียกว่า วันที่ T มีแนวโน้มขาขึ้น ซึ่งเป็นไปได้ใน 2 ลักษณะ ดังรูปที่ 3 และ 4




รูปที่ 3 แนวโน้มขาขึ้นแบบที่ 1




รูปที่ 4 แนวโน้มขาลงแบบที่ 2

4. พิจารณากราฟราคาเปิดวันที่ T ถ้าราคาเปิดของวันที่ T+1 อยู่ต่ำกว่าราคาเปิดของวันที่ T เหตุการณ์นี้จะเรียกว่า วันที่ T มีแนวโน้มขาลง ซึ่งเป็นไปได้ใน 2 ลักษณะ ดังรูปที่ 5 และ 6



รูปที่ 5 แนวโน้มขาลงแบบที่ 1



รูปที่ 6 แนวโน้มขาลงแบบที่ 2

### วัตถุประสงค์

เพื่อเปรียบเทียบสถาปัตยกรรมของโครงข่ายประสาทเทียม 4 แบบ ได้แก่ 1. Feed Forward Neural Network 2. Convolutional Neural Network 3. Long Short-Term Memory Neural Network และ 4. Convolutional + Long Short-Term Memory Neural Network ในการทำนายแนวโน้มของอัตราแลกเปลี่ยนของคู่เงินดอลลาร์สหรัฐอเมริกากับเยนญี่ปุ่น

### ขอบเขตของโครงการ

1. ทำนายแนวโน้มในแต่ละวัน (ขึ้นหรือลง) โดยจะเปิดและปิดคำสั่งซื้อขายที่ราคาเปิดของทุกวัน
2. ใช้ชุดข้อมูลซึ่งประกอบด้วย ราคาเปิด ราคาปิด ราคาสูงสุด ราคาต่ำสุดและอินดิเคเตอร์ โดยจะใช้ข้อมูลตั้งแต่วันที่ 4 มกราคม พ.ศ. 2553 ถึงวันที่ 28 ธันวาคม พ.ศ. 2561 ไม่รวมวันเสาร์อาทิตย์และวันหยุดเทศกาล

### วิธีการดำเนินงาน

1. ศึกษางานวิจัยและบทความทางวิชาการที่เกี่ยวข้องกับงานที่จะพัฒนา
2. ระบุปัญหาและข้อเสียที่เกิดขึ้นจากงานวิจัยก่อนหน้า
3. วิเคราะห์พีเจอาร์และออกแบบสถาปัตยกรรมโครงข่ายประสาทเทียมแบบต่าง ๆ
4. พัฒนาและทดสอบความถูกต้องของโมเดล
5. ทดสอบโมเดลโดยการวัดค่าไรจากชุดข้อมูลทดสอบ
6. วิเคราะห์ผลการทดสอบและปรับปรุงโมเดลเพื่อเพิ่มประสิทธิภาพในการทำนาย
7. จัดทำเอกสารรายงาน

### แผนภูมิแกนต์(Gantt Chart)

ขั้นตอนการดำเนินงาน	เดือน / ปีการศึกษา 2561						เดือน / ปีการศึกษา 2562			
	ก.ค.	ส.ค.	ก.ย.	ต.ค.	พ.ย.	ธ.ค.	ม.ค.	ก.พ.	มี.ค.	เม.ย.
1.ศึกษางานวิจัยและบทความทางวิชาการที่เกี่ยวข้องกับงานที่จะพัฒนา										
2.ระบุปัญหาและข้อเสียที่เกิดขึ้นจากงานวิจัยก่อนหน้า										
3.วิเคราะห์ลักษณะสำคัญและออกแบบสถาปัตยกรรมโครงข่ายประสาทเทียมแบบต่าง ๆ										
4.พัฒนาและทดสอบความถูกต้องของโมเดล										
5.ทดสอบโมเดลโดยการวัดค่าไจจากชุดข้อมูลทดสอบ										
6. วิเคราะห์ผลการทดสอบและปรับปรุงโมเดลเพื่อเพิ่มประสิทธิภาพในการทำงาน										
7. จัดทำเอกสารรายงาน										

### ประโยชน์ที่คาดว่าจะได้รับ

1. ประโยชน์ต่อนิสิตที่ทำโครงการ
  - 1.1. ได้ศึกษาสถาปัตยกรรมโครงข่ายประสาทเทียมรูปแบบต่าง ๆ
  - 1.2. ได้นำความรู้จากการเรียนมาประยุกต์ใช้ในการออกแบบโมเดล
  - 1.3. ได้ศึกษางานวิจัยที่เกี่ยวข้องด้านการลงทุน
2. ประโยชน์ที่ได้จากโครงการที่พัฒนาขึ้น
  - 2.1. ได้พัฒนาองค์ความรู้ทางธุรกิจซึ่งสามารถนำไปประยุกต์ใช้กับการลงทุน

### อุปกรณ์และเครื่องมือที่ใช้

1. ฮาร์ดแวร์
  - 1.1. Macbook Pro 2017
  - 1.2. Notebook Asus N550J
  - 1.3. Google Cloud Platform

2. ซอฟต์แวร์
  - 2.1. Jupyter Notebook
  - 2.2. Microsoft Excel
  - 2.3. MetaTrader 4
3. ภาษาที่ใช้พัฒนา
  - 3.1. Python
  - 3.2. MQL 4

### งบประมาณ

1. ค่าบริการ Google Cloud Platform	ราคา 4,000 บาท
2. ค่าบริการ Amazon Elastic Compute Cloud	ราคา 1,500 บาท
3. ค่า eBook	ราคา 1,500 บาท
4. ค่าถ่ายเอกสารและทำรูปเล่ม	ราคา 2,000 บาท
5. ค่าพิมพ์โปสเตอร์และค่าเดินทางไปนำเสนอผลงาน	ราคา 1,000 บาท
	รวมทั้งหมด 10,000 บาท

## เอกสารอ้างอิง

- [1] forexthai. รวมคำศัพท์ Forex[online]. (n.d.). Available from: <https://www.forexthai.in.th>  
[2018, November 5]
- [2] Jingtao Yao, Chew Lim Tan. A case study on using neural networks to perform technical forecasting of forex. Neurocomputing. 34 (2000): 79-98
- [3] Jigar Patel, Sahil Shah, Priyank Thakkar, K. Kotecha. Predicting stock and stock price index movement using Trend Deterministic Data Preparation and machine learning techniques. Expert Systems with Applications. 42 (2015): 259-268
- [4] Areej Abdullah Baasher, Mohamed Waleed Fakhr. FOREX Trend Classification using Machine Learning Techniques. Recent Researches in Applied Informatics and Remote Sensing. 11 (2011): 41-47
- [5] Mehdi Khashei, Mehdi Bijari. An artificial neural network (p,d,q) model for timeseries forecasting. Expert Systems with Applications. 37 (2010): 479-489
- [6] A.N. Refenes, M. Azema-Barac, L. Chen, S. A. Karoussos. Currency exchange rate prediction and neural network design strategies. Neural Computing & Applications. 1 (1993): 46-58

## ประวัติผู้เขียน



Mr. Bunyawat Srisompong

นาย บุญยวัศ ศรีสมพงษ์

วันเกิด 9 พฤษภาคม พ.ศ. 2539

โรงเรียน นครนายกวิทยาคม

ชั้นปีที่ 4 คณะวิทยาศาสตร์

ภาควิชาคณิตศาสตร์และวิทยาการคอมพิวเตอร์

สาขาคอมพิวเตอร์ จุฬาลงกรณ์มหาวิทยาลัย

อีเมล: bsrisompong@gmail.com



Mr. Sorawit Lertumpaisakulwong

นาย สรวิศ เลิศอำไพสกุลวงศ์

วันเกิด 19 ธันวาคม พ.ศ. 2539

โรงเรียน สตรีวิทยา ๒

ชั้นปีที่ 4 คณะวิทยาศาสตร์

ภาควิชาคณิตศาสตร์และวิทยาการคอมพิวเตอร์

สาขาคอมพิวเตอร์ จุฬาลงกรณ์มหาวิทยาลัย

อีเมล: new-sorawit@outlook.com