

การตรวจหารูปแบบกราฟหุ่นด้วยเทคนิคการเรียนรู้เชิงลึก

อภิสิทธิ์ รุ่งมานะกุล

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมข้อมูลขนาดใหญ่

วิทยาลัยนวัตกรรมด้านเทคโนโลยีและวิศวกรรมศาสตร์

มหาวิทยาลัยธุรกิจบัณฑิตย์

พ.ศ. 2563

Stock Pattern Detection Using Deep Learning

Apisit Rungmanakul

A Thesis Submitted in Partial Fulfillment of the Requirements

for the Degree of Master of Engineering

Department of Big Data Engineering,

College of Innovative Technology and Engineering,

Dhurakij Pundit University

2020




ใบรับรองงานวิทยานิพนธ์

วิทยาลัยนวัตกรรมการด้านเทคโนโลยีและวิศวกรรมศาสตร์ มหาวิทยาลัยราชภัฏบรียรัมย์
ปริญญา วิศวกรรมศาสตรมหาบัณฑิต

หัวข้อวิทยานิพนธ์ การตรวจจ้งรูปแบบกราฟหุ่นด้วยเทคนิคการเรียนรู้เชิงลึก
เสนอโดย นายอภิสิทธิ์ รุ่งมานะกุล
สาขาวิชา วิศวกรรมข้อมูลขนาดใหญ่
อาจารย์ที่ปรึกษาวิทยานิพนธ์ ดร.ธนภัทร ชั่งคะจิตร
ได้พิจารณาเห็นชอบโดยคณะกรรมการสอบวิทยานิพนธ์แล้ว



.....ประธานกรรมการ
(รองศาสตราจารย์ ดร.กฤษณะ ไวยมัย)


.....กรรมการ
(ดร.สรรพทธี มฤคทัต)


.....กรรมการและอาจารย์ที่ปรึกษา
(ดร.ธนภัทร ชั่งคะจิตร)


.....กรรมการ
(ดร.เอกสิทธิ์ พัชรวงค์ศักดิ์ดา)

วิทยาลัยนวัตกรรมการด้านเทคโนโลยีและวิศวกรรมศาสตร์รับรองแล้ว


.....
(ผู้ช่วยศาสตราจารย์ ดร.ณรงค์เดช กิรติพรานนท์)
คณบดีวิทยาลัยนวัตกรรมการด้านเทคโนโลยีและวิศวกรรมศาสตร์
วันที่ 17 เดือน กรกฎาคม พ.ศ. 2563

หัวข้อวิทยานิพนธ์	การตรวจหารูปแบบกราฟหุ้นด้วยเทคนิคการเรียนรู้เชิงลึก
ชื่อผู้เขียน	อภิสิทธิ์ รุ่งมานะกุล
อาจารย์ที่ปรึกษา	ดร.ธนภัทร มังคะจิตร
สาขาวิชา	วิศวกรรมข้อมูลขนาดใหญ่
ปีการศึกษา	2562

บทคัดย่อ

การตรวจหารูปแบบกราฟหุ้นจากการวิเคราะห์โดยปัจจัยด้านเทคนิคอล ได้ถูกพิสูจน์แล้วว่า เป็นเครื่องมือแบบหนึ่งที่มีประสิทธิภาพ สามารถสนับสนุนนักลงทุนให้สร้างผลตอบแทนได้อย่างเหมาะสมในตลาดหุ้น แม้ว่าการเรียนรู้เชิงลึกถูกประยุกต์ใช้ในงานวิจัยจำนวนมากก่อนหน้านี้ แต่ประสิทธิภาพของการตรวจหา ยังจำเป็นต้องได้รับการปรับปรุง

งานวิจัยนี้ตรวจหารูปแบบกราฟหุ้นแยกกัน บนกราฟแท่งเทียน (Candlestick Chart) และกราฟอาร์เอสไอ (RSI Line Chart) โดยใช้เทคนิคการเรียนรู้เชิงลึกที่ต่างกัน แล้วนำรูปแบบกราฟหุ้นทั้งคู่ที่ปรากฏขึ้นในช่วงเวลาเดียวกันมาพิจารณา ด้วยรูปแบบกราฟหุ้นแบบบูลิชไดเวอร์เจนซ์ (Bullish Divergence) ซึ่งเป็นรูปแบบกราฟหุ้นที่สร้างผลตอบแทนอย่างเหมาะสมในตลาดหลักทรัพย์แห่งประเทศไทย

การทดลองบนรูปภาพกราฟหุ้นของตลาดหลักทรัพย์แห่งประเทศไทย เพื่อตรวจหารูปแบบกราฟหุ้นแบบบูลิชไดเวอร์เจนซ์ ด้วยวิธีการของงานวิจัยนี้ให้ประสิทธิภาพที่ดีกว่าเทียบกับวิธีการทดลองอื่น นอกจากนี้ประสิทธิภาพที่ดีกว่ามาจากการใช้สถาปัตยกรรมการเรียนรู้เชิงลึก (Deep Learning) และลอสฟังก์ชัน (Loss Function) อย่างเหมาะสม ซึ่งแสดงไว้อย่างชัดเจนในงานวิจัยนี้

Thesis Title	Stock Pattern Detection Using Deep Learning
Author	Apisit Rungmanakul
Thesis Advisor	Dr. Thanapat Kangkachit
Department	Big Data Engineering
Academic Year	2019

ABSTRACT

Stock pattern detection using technical analysis has been proven to be an effective tool that can assist investors to make proper return in the stock market. Although deep learning techniques were applied in many previous works but detection performance still need to be improved.

In this work, we separately performed pattern detection on Candlestick Chart and RSI Line Chart by using different deep learning techniques then the existence of both stock patterns occurred at the same period were considered as Bullish Divergence pattern which generates proper return in SET.

Experiments were made on SET stock graphs in order to detect Bullish Divergence pattern. Our methods offer better performance than others. In addition, this better performance can be obtained from using Deep Learning architecture and Loss Function properly as clearly shown in the experiments.

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วง ด้วยการให้ความช่วยเหลือชี้แนะของ ดร.ชนภัทร ชั่งคะจิตร ซึ่งเป็นอาจารย์ที่ปรึกษาวิทยานิพนธ์ ซึ่งกรุณาให้คำแนะนำข้อคิดเห็นตรวจสอบและแก้ไขร่างวิทยานิพนธ์มาโดยตลอด ผู้เขียนจึงขอกราบขอบพระคุณไว้ ณ โอกาสนี้

ผู้เขียนขอกราบขอบพระคุณ รองศาสตราจารย์ ดร.กฤษณะ ไวยมัย ที่กรุณาให้เกียรติเป็นประธาน โดยมี ดร.สรรพฤทธิ์ มฤคทัต และดร.เอกสิทธิ์ พัชรวงศ์ศักดิ์ เป็นกรรมการ ในการสอบวิทยานิพนธ์ ซึ่งกรุณาตรวจแก้ไขวิทยานิพนธ์ฉบับนี้ให้ถูกต้องสมบูรณ์ และดร.ชนภัทร ชั่งคะจิตร ที่ให้คำปรึกษาแนะนำในทุกด้าน และนางสาวกุลธิดา รอดบุญ รวมถึงเจ้าหน้าที่บัณฑิตมหาวิทยาลัยธุรกิจบัณฑิตทุกท่าน ซึ่งได้เอื้อเฟื้ออำนวยความสะดวกและสนับสนุนการประสานงานในทุกด้าน อีกทั้ง คุณบุญยง วงศ์สิริสวัสดิ์ คุณรัตน โชติ พันธุ์วิไล คุณชนพัฒน์ คำใสอินทร์ และกัลยาณมิตรทุกท่านที่ไม่ได้กล่าวไว้ ซึ่งได้ร่วมค้นคว้าหาข้อมูลในทุกด้าน ทั้งในเวลานอกเวลา กระทั่งการจัดทำวิทยานิพนธ์ของผู้เขียนครั้งนี้สำเร็จลุล่วง

ผู้เขียนหวังเป็นอย่างยิ่งว่าวิทยานิพนธ์ฉบับนี้จะเป็นพื้นฐานในการต่อยอดองค์ความรู้ของผู้ที่สนใจศึกษาในงานด้านนี้ต่อไป

อภิสิทธิ์ รุ่งมานะกุล

สารบัญ

เรื่อง	หน้า
บทคัดย่อภาษาไทย.....	ฅ
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ช
สารบัญภาพ.....	ฌ
บทที่ 1. บทนำ.....	1
1.1. ความสำคัญและความเป็นมา.....	1
1.2. วัตถุประสงค์.....	2
1.3. ขอบเขตของการวิจัย.....	2
1.4. ประโยชน์ที่คาดว่าจะได้รับ.....	2
1.5. นิยามศัพท์เฉพาะ.....	3
บทที่ 2. ทฤษฎี และผลงานวิจัยที่เกี่ยวข้อง.....	4
2.1. ข้อมูลหลักทฤษฎีและการวิเคราะห์ปัจจัยทางเทคนิค.....	5
2.1.1. การวิเคราะห์ปัจจัยทางเทคนิค (Indicators, Candlestick, RSI).....	5
2.1.2. SiamQuant (Bullish Divergence).....	11
2.2. การเรียนรู้เชิงลึก.....	13
2.2.1. โครงข่ายประสาทเทียมแบบคอนโวลูชัน.....	15
2.2.2. สถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชัน.....	15
2.2.3. การตรวจจับวัตถุในภาพ โดย Faster R-CNNs.....	17
2.2.4. Loss Function.....	18
2.3. การวัดประสิทธิภาพ (IoU, AP @ IoU \geq 0.50, Confusion Matrix).....	19
2.4. งานวิจัยที่เกี่ยวข้อง.....	22
บทที่ 3. ระเบียบวิธีวิจัย.....	25
3.1. แนวทางการวิจัย.....	26

สารบัญ (ต่อ)

เรื่อง	หน้า
3.2. การเตรียมข้อมูล.....	27
3.3. การสร้างเลเบลข้อมูล สำหรับการสอนระบบ.....	28
3.3.1.รูปแบบที่ 1.Candlestick Chart with RSI Line Chart = 1 Label.....	28
3.3.2.รูปแบบที่ 2.Candlestick Chart and RSI Line Chart = 2 Labels.....	29
3.3.3.รูปแบบที่ 3.Candlestick Chart and RSI Line Chart = 2 Labels+X-axis	30
3.4. การสอนระบบ Faster R-CNNs สำหรับการตรวจหา.....	31
3.4.1. กลยุทธ์ 1. InceptionV2 + Categorical Cross Entropy Loss.....	31
3.4.2. กลยุทธ์ 2. InceptionV2 + Focal Loss.....	31
3.4.3. กลยุทธ์ 3. ResNet50 + Categorical Cross Entropy Loss.....	31
3.4.4. กลยุทธ์ 4. ResNet50 + Focal Loss.....	31
3.5. วิเคราะห์ และสรุปผล (AP @ IoU \geq 0.50).....	31
บทที่ 4. ผลงานวิจัย.....	32
4.1. การเปรียบเทียบความแม่นยำของการสร้างเลเบล 3 รูปแบบของ 4 กลยุทธ์.....	32
4.2. การเปรียบเทียบความแม่นยำของการแยกโมเดล Candlestick Chart และ RSI Line Chart.....	34
4.3. ตัวอย่างผลลัพธ์ของการตรวจหารูปแบบกราฟหุ้น.....	36
บทที่ 5. บทสรุป อภิปราย และข้อเสนอแนะ.....	39
5.1. สรุปผลการวิจัย.....	39
5.2. อภิปรายผลการวิจัย.....	40
5.3. ข้อเสนอแนะ.....	41
บรรณานุกรม.....	42
ภาคผนวก.....	45
ประวัติผู้เขียน.....	55

สารบัญตาราง

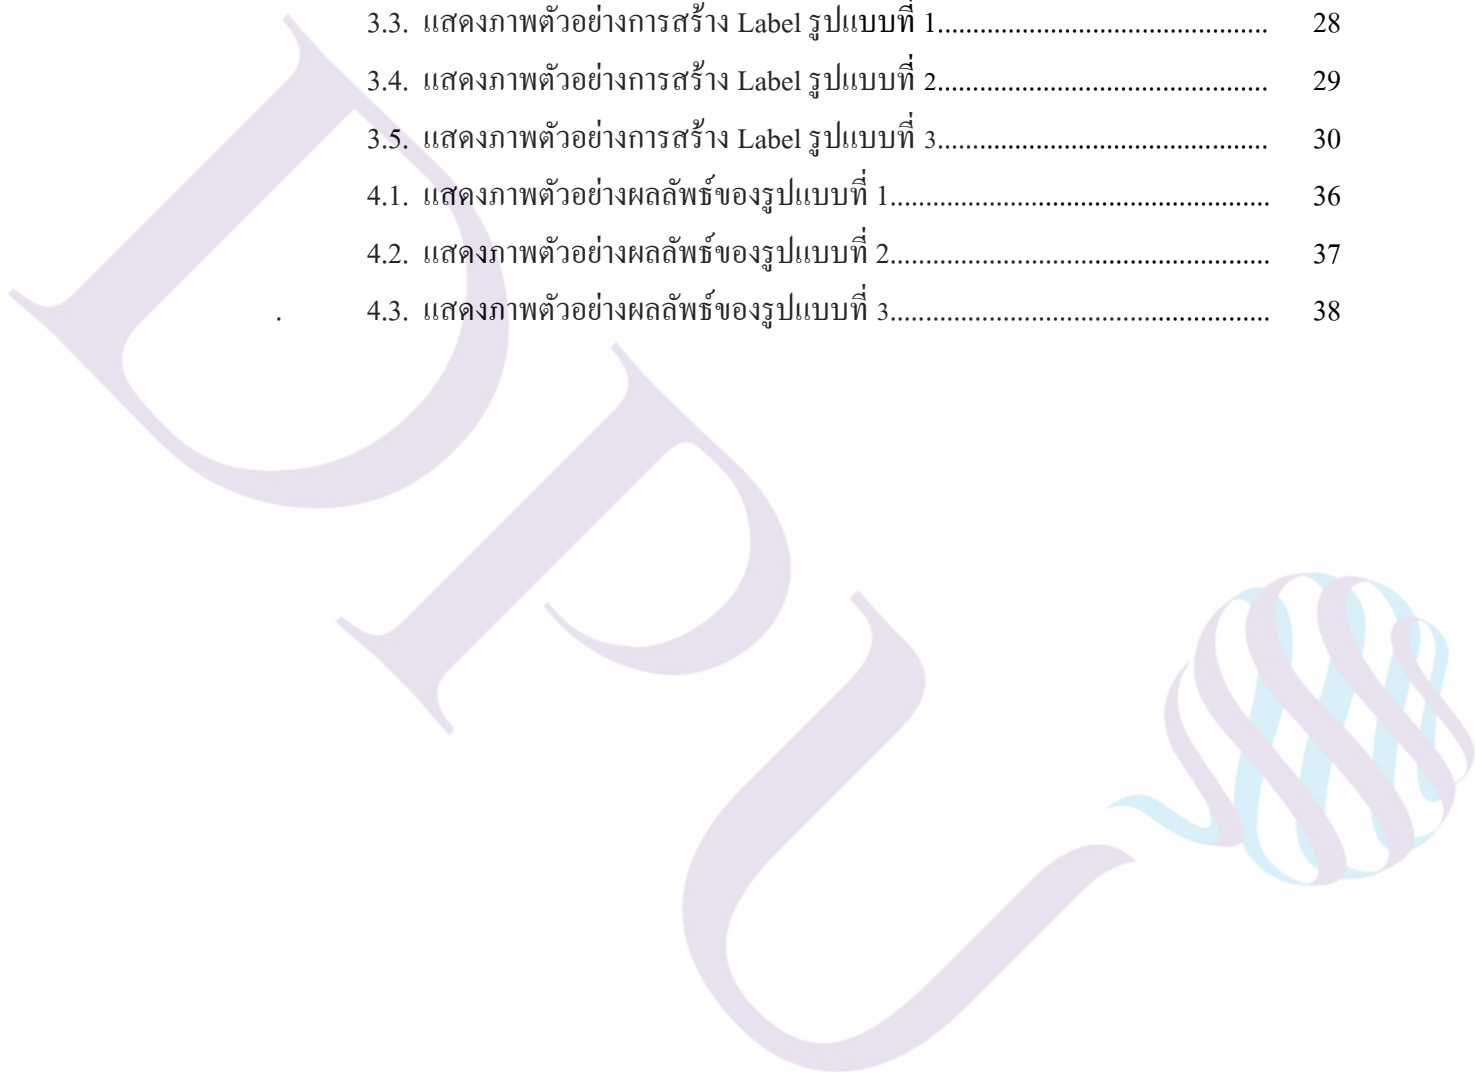
ตารางที่	หน้า
2.1 แสดงตาราง Confusion Matrix การจำแนกประเภทข้อมูล 2 กลุ่ม.....	20
2.2 แสดงตารางเปรียบเทียบค่า RMSE ของแต่ละโมเดล.....	23
2.3. แสดงตารางเปรียบเทียบค่า Recall ของแต่ละโมเดล.....	23
4.1. แสดงตารางเปรียบเทียบค่า AP @ IoU ≥ 0.50 ของการสร้างเลเบลทั้ง 3 รูปแบบ.....	33
4.2. แสดงตารางเปรียบเทียบค่า AP @ IoU ≥ 0.50 หากพิจารณาแยกโมเดลของแต่ละเลเบล.....	34
4.3. แสดงตารางเปรียบเทียบค่า AP @ IoU ≥ 0.50 หากพิจารณาเจาะจงโมเดลของแต่ละเลเบล.....	35

สารบัญภาพ

ภาพที่	หน้า
2.1. แสดงภาพตัวอย่างการใช้เครื่องมือชี้วัด หรือดัชนีบ่งชี้.....	7
2.2. แสดงภาพตัวอย่างแท่งเทียนราคา.....	9
2.3. แสดงภาพตัวอย่าง Candlestick Chart.....	10
2.4. แสดงภาพตัวอย่าง RSI Line Chart.....	11
2.5. แสดงภาพงานวิจัยอ้างอิงจาก SiamQuant.....	12
2.6. แสดงภาพตัวอย่างโครงสร้าง Convolutional Neural Networks.....	15
2.7. แสดงภาพตัวอย่างโครงสร้าง InceptionV2.....	16
2.8. แสดงภาพตัวอย่างโครงสร้าง ResNet50.....	16
2.9. แสดงภาพโครงสร้าง Faster Regional-Convolutional Neural Networks.....	17
2.10. แสดงภาพสมการ Categorical Cross Entropy Loss.....	18
2.11. แสดงภาพสมการ Focal Loss.....	18
2.12. แสดงภาพการคำนวณของค่า IoU.....	19
2.13. แสดงภาพแสดงภาพโครงสร้าง CNN-TA.....	22
2.14. แสดงภาพโครงสร้าง 2D-CNNs.....	23

สารบัญภาพ (ต่อ)

ภาพที่	หน้า
3.1. แสดงภาพรวมการทำงานของการตรวจหารูปแบบกราฟหุ่น.....	26
3.2. แสดงภาพตัวอย่างรูปภาพกราฟหุ่น.....	27
3.3. แสดงภาพตัวอย่างการสร้าง Label รูปแบบที่ 1.....	28
3.4. แสดงภาพตัวอย่างการสร้าง Label รูปแบบที่ 2.....	29
3.5. แสดงภาพตัวอย่างการสร้าง Label รูปแบบที่ 3.....	30
4.1. แสดงภาพตัวอย่างผลลัพธ์ของรูปแบบที่ 1.....	36
4.2. แสดงภาพตัวอย่างผลลัพธ์ของรูปแบบที่ 2.....	37
4.3. แสดงภาพตัวอย่างผลลัพธ์ของรูปแบบที่ 3.....	38



บทที่ 1

บทนำ

1.1. ความสำคัญและความเป็นมา

การตรวจหารูปแบบกราฟหุ้น สร้างขึ้นเพื่อสนับสนุนการวิเคราะห์หุ้นด้วยปัจจัยด้านเทคนิค คอล และแก้ปัญหาของนักลงทุน จากความไม่รู้ ขาดความเข้าใจอย่างผู้เชี่ยวชาญ ซึ่งการลงทุนหุ้นไทย ในตลาดหลักทรัพย์แห่งประเทศไทย ณ ปัจจุบันนั้น ข้อมูลมีปริมาณมหาศาลและรวดเร็ว ขณะที่เวลาที่มีจำกัด อาจนำมาซึ่งความผิดพลาดของการตัดสินใจในการลงทุน โดยงานวิจัยนี้จะทำการตรวจหารูปแบบกราฟหุ้นที่มีศักยภาพ เพื่อนำมาใช้ประกอบการลงทุนสร้างผลตอบแทนอย่างเหมาะสม

งานวิจัยก่อนหน้านี้ที่เกี่ยวกับการวิเคราะห์หุ้นด้วยปัจจัยด้านเทคนิคคอลจากรูปภาพเท่านั้น งานวิจัย¹ สร้างรูปภาพจากข้อมูล Indicators ย้อนหลัง แล้วใช้ CNN-TA เพื่อพยากรณ์ผลตอบแทนที่ดีที่สุดจากการซื้อขายหุ้น ส่วนงานวิจัย² นำรูปภาพกราฟหุ้น แล้วใช้ 1D-CNNs และ 2D-CNNs เพื่อตรวจหารูปแบบกราฟหุ้น แต่ไม่สามารถตรวจหารูปแบบกราฟหุ้นได้อย่างแม่นยำ เมื่อนำมาเปรียบเทียบกับการใช้ข้อมูล OHLC ย้อนหลัง

ข้อมูล OHLC นั้นมีบทบาทหลักสำหรับการลงทุนของตลาดการเงินทุกรูปแบบ จึงสมควรอย่างยิ่งที่จะพัฒนาการเรียนรู้ของคอมพิวเตอร์ด้าน Image Processing ให้เป็นอีกหนึ่งทางเลือก เพื่อใช้ตรวจหารูปแบบกราฟหุ้นด้วยปัจจัยด้านเทคนิคคอล จากรูปภาพกราฟหุ้น แม้จะไม่มีข้อมูล OHLC ย้อนหลังมาใช้ประกอบด้วย

ด้วยเหตุดังกล่าว งานวิจัยฉบับนี้ นำเสนอวิธีการตรวจหารูปแบบกราฟหุ้นด้วยการเรียนรู้เชิงลึก Faster R-CNNs³ ซึ่งสามารถตรวจหารูปแบบกราฟหุ้น แบบ Bullish Divergence จากรูปภาพกราฟหุ้น ที่แสดง Candlestick Chart และ RSI Line Chart บนรูปภาพกราฟหุ้นรายตัวสำหรับตลาดหลักทรัพย์แห่ง

ประเทศไทย บนจอมอนิเตอร์ที่แสดงผ่านเว็บไซต์เท่านั้น ได้อย่างมีประสิทธิภาพ โดยการออกแบบโครงข่ายการเรียนรู้เชิงลึก ร่วมกับลักษณะเด่นของรูปแบบกราฟหุ้น อีกทั้งการกำหนดพารามิเตอร์อย่างเหมาะสมเท่าที่จำเป็น เพื่อช่วยสนับสนุนนักลงทุนในการตัดสินใจประกอบการลงทุนอย่างมีประสิทธิภาพ ในระยะเวลารวดเร็ว แม่นยำ และสม่ำเสมอ

1.2. วัตถุประสงค์

1.2.1 เสนอวิธีการตรวจหารูปแบบกราฟหุ้นที่มีประสิทธิภาพโดยใช้การเรียนรู้เชิงลึก รวมทั้งวิธีการคัดเลือกการเก็บข้อมูล และการจัดเตรียมข้อมูล สำหรับสอนโมเดล การเลือกใช้โมเดล และการตั้งค่าโมเดลของการเรียนรู้เชิงลึก

1.3. ขอบเขตของงานวิจัย

1.3.1 รูปภาพกราฟหุ้นไทย ที่อยู่ในดัชนี SET จากเว็บไซต์ www.tradingview.com เท่านั้น

1.3.2 ความละเอียดของภาพไฟล์ประเภท JPEG กว้าง 1920 พิกเซล และ สูง 1080 พิกเซล

1.3.3 ข้อมูลรายปี ระหว่าง ปี ค.ศ. 2014 ถึง 2020

1.3.4 แสดงกราฟ แท่งเทียนราคา ปิดทำการของแต่ละ 1 วัน ในรูปแบบ log scale

1.3.5 แสดงกราฟ อาร์เอสไอ 14 วัน ในรูปแบบ log scale

1.3.6 รูปแบบกราฟหุ้นแบบบูลิชไดเวอร์เจนซ์

1.4. ประโยชน์ที่คาดว่าจะได้รับ

1.4.1 โมเดลที่มีความแม่นยำ สำหรับการตรวจหารูปแบบกราฟหุ้นแบบบูลิชไดเวอร์เจนซ์ โดยค่า $AP @ IoU \geq 0.50$

1.4.2 สนับสนุนนักลงทุนไทยที่มีทักษะ และแนะนำหุ้นไทยที่มีศักยภาพสำหรับนักลงทุนไทยที่ขาดทักษะ เพื่อใช้ประกอบการตัดสินใจลงทุน

1.5. นิยามศัพท์เฉพาะ

1.5.1 SET หรือ Stock Exchange of Thailand หมายถึง ตลาดหลักทรัพย์แห่งประเทศไทย

1.5.2 หุ้น หรือ หลักทรัพย์ เป็นตราสารที่กิจการออกให้แก่ผู้ร่วมลงทุน เพื่อระดมทุนไปใช้ในกิจการ โดยผู้ถือตราสารทุนจะมีฐานะเป็น “เจ้าของกิจการ” ซึ่งมีส่วนได้ส่วนเสียหรือมีสิทธิในทรัพย์สินและรายได้ของกิจการ

1.5.3 OHLC หมายถึง ค่าตัวเลขของกราฟแท่งเทียนราคาที่เกิด ณ ช่วงเวลาที่กำหนดใน 1 แท่งเทียนราคา เช่น Open (ราคาเปิดการซื้อขาย ณ ตลาดเปิดทำการ) High (ราคาซื้อขายสูงสุดระหว่างตลาดเปิดทำการ) Low (ราคาซื้อขายต่ำสุดระหว่างตลาดเปิดทำการ) และ Close (ราคาปิดการซื้อขาย ณ ตลาดปิดทำการ)

1.5.4 Indicator days หรือ จำนวนวันที่ใช้ในการคำนวณดัชนี หมายถึง ระยะเวลาย้อนหลังจากวันปัจจุบัน ที่นำไปใช้ในการดึงข้อมูลราคาซื้อขายหลักทรัพย์เพื่อใช้ในการคำนวณหาดัชนีชี้วัดทางเทคนิค โดยมีหน่วยนับเป็น วัน

บทที่ 2

ทฤษฎี และผลงานวิจัยที่เกี่ยวข้อง

การวิจัยเรื่อง วิธีการตรวจหารูปแบบกราฟหุ้นจากรูปภาพกราฟหุ้น โดยพิจารณาตัวอย่างที่สนใจในด้าน Image Processing โดยเฉพาะข้อมูลที่เกี่ยวข้องกับหุ้นและรูปแบบกราฟหุ้น รวมทั้งข้อมูลที่เกี่ยวข้องกับการเรียนรู้เชิงลึกของระบบ ซึ่งผู้วิจัยได้ทำการศึกษา ค้นคว้า จากแหล่งความรู้ทางอินเทอร์เน็ต โดยงานวิจัยที่เกี่ยวข้อง ดังนี้

2. ทฤษฎี และผลงานวิจัยที่เกี่ยวข้อง

- 2.1 ข้อมูลหลักทรัพย์และการวิเคราะห์ปัจจัยทางเทคนิค
 - 2.1.1. การวิเคราะห์ปัจจัยทางเทคนิค (Indicators, Candlestick, RSI)
 - 2.1.2. SiamQuant (Bullish Divergence)
- 2.2. การเรียนรู้เชิงลึก
 - 2.2.1. โครงข่ายประสาทเทียมแบบคอนโวลูชัน
 - 2.2.2. สถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชัน
 - 2.2.3. การตรวจจับวัตถุในภาพ โดย Faster R-CNNs
 - 2.2.4. Loss Function
- 2.3. การวัดประสิทธิภาพ (IoU, AP)
- 2.4. งานวิจัยที่เกี่ยวข้อง

2.1. ข้อมูลหลักทรัพย์ และการวิเคราะห์ปัจจัยทางเทคนิค

ข้อมูลหลักทรัพย์หรือที่นิยมเรียกว่า “หุ้น” หมายถึง หลักทรัพย์ประเภทหนึ่งที่องค์กรหรือหน่วยงานเสนอให้ผู้สนใจและประชาชนทั่วไปให้สามารถทำการซื้อขายและมีส่วนร่วมในการเป็น “เจ้าของกิจการ” ซึ่งจะมีส่วนได้เสียหรือมีสิทธิในทรัพย์สินและรายได้ของกิจการ รวมทั้งมีโอกาสได้รับผลตอบแทนเป็นเงินปันผล (Dividend) และกำไรจากการขายหุ้น องค์กรจะนำเงินที่ได้จากการซื้อขายหลักทรัพย์นั้นไปหมุนเวียนต่อยอดเพื่อคงสภาพกิจการขององค์กรให้อยู่ต่อไปได้ ซึ่งการลงทุนในหลักทรัพย์เป็นการลงทุนอย่างหนึ่ง โดยให้เงินทำหน้าที่ในการสร้างรายได้จากทิศทาง การเปลี่ยนแปลงของอุปสงค์และอุปทานในตลาด จึงทำให้มีกลุ่มบุคคลเกิดความสนใจที่จะศึกษาพฤติกรรมและธรรมชาติของการเปลี่ยนแปลงในข้อมูลตลาดหลักทรัพย์แต่ละประเภท และเนื่องจากข้อมูลหลักทรัพย์ได้รับอิทธิพลจากปัจจัยต่างๆทั้งภายในและภายนอก เช่น สภาพความมั่นคงขององค์กร ผลประกอบการ ข่าวสารประจำวัน สภาพทางเศรษฐกิจ เป็นต้น ทำให้ข้อมูลหลักทรัพย์มีการเปลี่ยนแปลงขึ้นลงอยู่ตลอดเวลา ด้วยเหตุนี้จึงจำเป็นต้องอาศัยการวิเคราะห์ปัจจัยทางเทคนิคเพื่อใช้ในการวิเคราะห์ข้อมูลหลักทรัพย์ โดยหัวข้อนี้จะอธิบายเกี่ยวกับประเภทของตัวแปรที่เป็นปัจจัยในการวิเคราะห์ข้อมูลหลักทรัพย์ และการวิเคราะห์ข้อมูลหลักทรัพย์ทางเทคนิค

2.1.1. การวิเคราะห์ปัจจัยทางเทคนิค (Technical Analysis)

เป็นการศึกษาพฤติกรรมของราคาหลักทรัพย์ หรือพฤติกรรมของตลาดในอดีต โดยใช้หลักสถิติ เพื่อนำมาใช้คาดการณ์พฤติกรรมเคลื่อนไหวของตลาดหลักทรัพย์ในอนาคต ซึ่งมีที่มาจาก การพัฒนาตามหลักการในทฤษฎีของดาว ช่วยให้ผู้ลงทุนหาจังหวะการลงทุนที่เหมาะสม ทั้งนี้ทฤษฎีที่ใช้ในการวิเคราะห์ปัจจัยทางเทคนิคมีหลากหลาย

ซึ่งแนวคิดการวิเคราะห์ปัจจัยทางเทคนิคจะอยู่บนสมมติฐาน 3 ประการ (ตลาดหลักทรัพย์แห่งประเทศไทย, 2558) คือ

1. ราคา เป็นผลรวมที่สะท้อนให้ทราบถึงข่าวสารในด้านต่างๆทั้งหมดแล้ว
2. ราคา จะเคลื่อนไหวอย่างมีแนวโน้ม และจะคงอยู่ในแนวโน้มนั้นในช่วงระยะเวลาหนึ่ง จนกว่า จะเกิดการเปลี่ยนแปลงแนวโน้มใหม่
3. พฤติกรรมการลงทุนของผู้ลงทุน จะยังคงมีลักษณะที่คล้ายคลึงกับพฤติกรรมการลงทุนในอดีต

โดยมีเครื่องมือชี้วัด หรือดัชนีบ่งชี้ (Indicators) เป็นหนึ่งในแนวคิดที่เกี่ยวกับการวิเคราะห์ปัจจัยทางเทคนิค โดยค่าของ Indicators นั้นเกิดจาก การนำข้อมูลดิบของหลักทรัพย์ ซึ่งได้แก่ ราคาเปิด (Open) ราคาปิด (Close) ราคาสูงสุด (High) ราคาต่ำสุด (Low) และปริมาณการซื้อขาย (Volume) มาคำนวณด้วยสูตรทางคณิตศาสตร์ หรือสูตรสถิติที่คิดค้นขึ้น จากนั้นเราจะนำค่าของ Indicators ที่ได้จากการคำนวณ มาแปลเป็นความหมาย เพื่อช่วยประกอบการตัดสินใจในการซื้อขายหลักทรัพย์ แต่ค่าของ Indicators เพียงค่าเดียวนั้น ไม่สามารถให้ข้อมูลเพียงพอสำหรับการตัดสินใจซื้อหรือขายหลักทรัพย์ได้ (ออมมันน์, 2015) ดังนั้นการวิเคราะห์ปัจจัยทางเทคนิคด้วย Indicators จะพิจารณา

- การคำนวณค่าของ Indicators ออกมาหลายๆตัว เป็นชุด และนำมาเรียงต่อเนื่องกัน
- การแสดงผลออกมาอยู่ในรูปของกราฟเส้นหรือกราฟแท่งควบคู่กับกราฟของราคาหลักทรัพย์ เพราะการแสดงผลในรูปของกราฟ จะทำให้มองเห็นภาพได้อย่างชัดเจน และนำไปแปลความหมายได้ง่ายขึ้น ดังภาพที่ 2.1.



ภาพที่ 2.1. แสดงภาพตัวอย่างการใช้เครื่องมือชี้วัด หรือดัชนีบ่งชี้

ที่มา : www.aomoney.com

ซึ่งนำ Indicators มาประยุกต์ใช้งาน ดังนี้

Indicators แสดงสัญญาณเตือนล่วงหน้า ช่วยให้เราสนใจ และติดตามการเคลื่อนที่ของราคาหลักทรัพย์ ในขณะนั้นให้ง่าย และรวดเร็วยิ่งขึ้น เพื่อรอจังหวะซื้อ หรือ จังหวะขายที่ดี

Indicators ส่งเสริมความมั่นใจในการลงมือซื้อหรือขายหลักทรัพย์ ถ้าข้อมูลที่ได้จากการวิเคราะห์กราฟ Indicators มีทิศทางเดียวกัน หรือสอดคล้องกับผลการวิเคราะห์กราฟราคาหลักทรัพย์ จะช่วยยืนยันความน่าเชื่อถือของผลที่ได้จากการวิเคราะห์กราฟหลักทรัพย์ว่าน่าจะมีโอกาสผิดพลาดน้อย

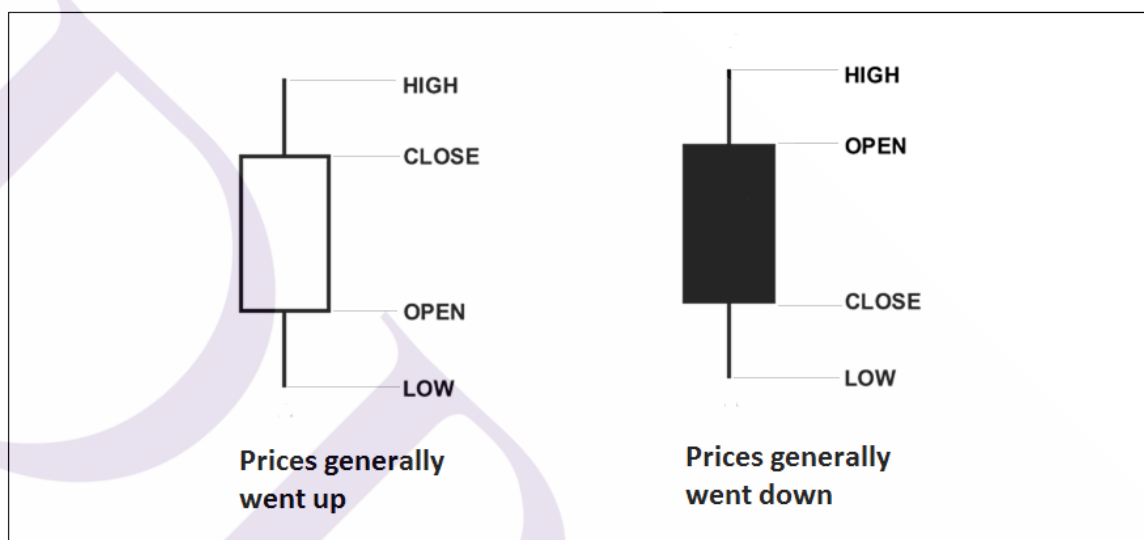
โดยแบ่งดัชนีบ่งชี้ ออกได้เป็น 4 ประเภท คือ

1. Trend Indicator คือ การวัดทิศทาง และความแรงของแนวโน้ม โดยใช้ค่าเฉลี่ยของราคาซื้อขาย ในขณะที่ราคาปัจจุบันเคลื่อนไปเหนือค่าเฉลี่ย ก็จะถือว่าเป็นแนวโน้มขึ้น เมื่อราคาปัจจุบันต่ำกว่าค่าเฉลี่ย ก็จะถือเป็นแนวโน้มลง ตัวอย่างดัชนีชี้วัดประเภทนี้ ได้แก่ Average Direction Movement Index (ADX), Moving Average (MA), และ Moving Average Convergence Divergence เป็นต้น
2. Momentum Indicator ใช้ในการประเมินการเปลี่ยนแปลงของราคาในช่วงเวลาใดๆ นอกจากนี้ยังสามารถใช้เพื่อวิเคราะห์ประมาณการซื้อขาย โดยคำนวณจากราคาปิดปัจจุบันกับราคาปิดก่อนหน้า เมื่อมีความแตกต่างระหว่างดัชนีบ่งชี้กับราคา อาจะหมายถึงการเปลี่ยนแปลงของราคาในอนาคต ตัวอย่าง เช่น Commodity Channel Index (CCI), Rate of Change (ROC), และ Relative strength Index (RSI) เป็นต้น
3. Volatility Indicator การวัดอัตราการเคลื่อนไหวของราคา โดยไม่คำนึงถึงทิศทาง โดยทั่วไปขึ้นอยู่กับ การเปลี่ยนแปลงในราคาที่สูงสุด และต่ำสุดในอดีต ซึ่งช่วยนักลงทุนในการตัดสินใจ จุดที่ตลาดจะมีการเปลี่ยนแปลง ตัวอย่าง เช่น Average True Range (ATR), Relative Volatility Index (RVI), และ Standard Deviation (SD) เป็นต้น
4. Volume Indicator ใช้ในการวัดแรงผลักดันของแนวโน้ม หรือยืนยันทิศทาง การซื้อขาย โดยพิจารณาจาก ค่าเฉลี่ย หรือ ความราบรื่นของปริมาณการซื้อขาย แนวโน้มที่มีแรงผลักดันมักจะเกิดขึ้น ในขณะที่ปริมาณการซื้อขายเพิ่มขึ้น ซึ่งการเพิ่มขึ้นของปริมาณการซื้อขายอาจนำไปสู่การเคลื่อนไหวขนาดใหญ่ของตลาดในอนาคต ตัวอย่าง เช่น On Balance Volume (OBV), Volume Rate of Change (VROC), Money Flow Index (MFI), และ Price Volume Trend (PVT) เป็นต้น

ซึ่งมีการวิเคราะห์ปัจจัยเชิงเทคนิคเป็นหลักสำคัญ 2 indicators ที่เกี่ยวข้องกับงานวิจัยฉบับนี้ คือ

Candlestick Chart: กราฟแสดงแท่งเทียนราคา มีลักษณะเบื้องต้นที่มีนัยสำคัญ 2 รูปแบบ คือ รูปแบบที่ 1. ตัวแท่งเทียนสีขาวแสดงสถานะราคาสูงขึ้น ตัวแท่งเทียนด้านล่างเป็นราคาเมื่อตลาดเปิด (Open) และตัวแท่งเทียนด้านบนเป็นราคาเมื่อตลาดปิด (Close) โดยมีไส้เทียนด้านบนสุดเป็นราคาสูงสุด (High) และไส้เทียนด้านล่างสุดเป็นราคาต่ำสุด (Low) และรูปแบบที่ 2. ตัวแท่งเทียนสีดำแสดงสถานะ

ราคาต่ำลง ตัวแท่งเทียนด้านบนเป็นราคาเมื่อตลาดเปิด (Open) และตัวแท่งเทียนด้านล่างเป็นราคาเมื่อตลาดปิด (Close) โดยมีไส้เทียนด้านบนสุดเป็นราคาสูงสุด (High) และไส้เทียนด้านล่างสุดเป็นราคาต่ำสุด (Low) ดังภาพที่ 2.2.



ภาพที่ 2.2. แสดงภาพตัวอย่างแท่งเทียนราคา

ที่มา : www.investdiva.com/investing-guide/candle-charts/danial-fig10-04/

โดย ตัวแท่งเทียน 1 แท่ง จะระบุราคาที่เกิดขึ้น ตามแต่เวลาที่กำหนด เช่น หากวิเคราะห์ปัจจัยเชิงเทคนิคระยะเวลา 6 เดือน ด้วยแท่งเทียน 1 วัน (Daily Timeframe) บนภาพกราฟหุ้นก็จะแสดงตัวแท่งเทียนรายวัน เป็นจำนวนเทียบเท่ากับ จำนวนวันที่ตลาดเปิดทำการ เรียงตัวแต่ละวันต่อเนื่องกัน เป็นรูปแบบกราฟแท่งเทียน (Candlestick Chart) ดังภาพที่ 2.3.




ภาพที่ 2.3. แสดงภาพตัวอย่าง Candlestick Chart

ที่มา : www.vsathai.wordpress.com

Relative Strength Index (RSI): ค่าความผันผวนของราคาหลักทรัพย์ โดยสังเกตการแกว่งตัวตามแต่เวลาที่กำหนด ซึ่งหากการเคลื่อนไหวของราคาอยู่ในภาวะการซื้อมากเกินไป (Overbought) คือ ค่าเหนือกว่าระดับ 70 และหากการเคลื่อนไหวของราคาอยู่ในภาวะการขายมากเกินไป (Oversold) คือ ค่าต่ำกว่าระดับ 30 เช่น RSI ของราคาที่เกิดขึ้นย้อนหลังทุก 14 วัน (RSI (14)) เกิดเป็นตำแหน่งจุดซึ่งเรียงตัวแต่ละวันต่อเนื่องกัน เป็นรูปแบบกราฟเส้น RSI (RSI Line Chart) ดังภาพที่ 2.4. ซึ่งคำนวณจากสมการดังนี้

$$RSI = 100 - \frac{100}{1 + RS}, \quad RS = \frac{\text{Average Gain}}{\text{Average Loss}}$$

โดยที่ *Average Gain* คือ ค่าเฉลี่ยของส่วนต่างของราคาปิดที่เพิ่มขึ้นในช่วงระยะเวลา n วัน
Average Loss คือ ค่าเฉลี่ยของส่วนต่างของราคาปิดที่ลดลงในช่วงระยะเวลา n วัน



ภาพที่ 2.4. แสดงภาพตัวอย่าง RSI Line Chart

ที่มา : www.forex4youonline.wordpress.com

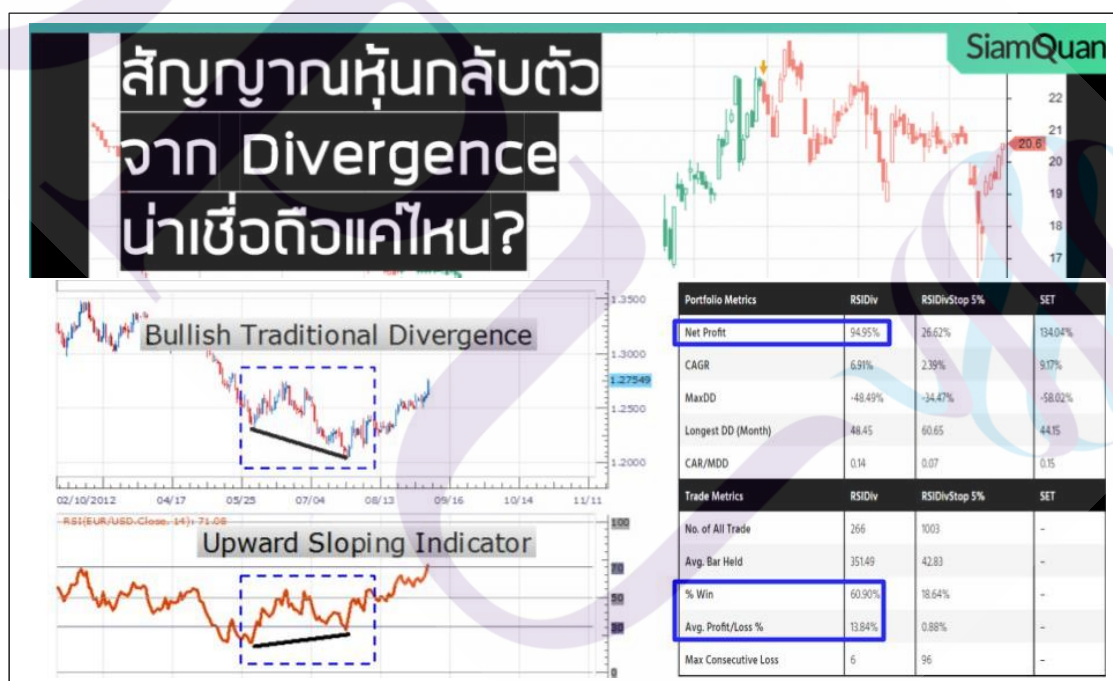
2.1.2. SiamQuant: Bullish Divergence

นิยามของคำว่า “Divergence” (www.siamquant.com) เป็นปรากฏการณ์ที่เกิดขึ้น เมื่อค่าที่วัดได้จากเครื่องมือทางเทคนิค (Technical Indicator) นั้นเกิดความไม่สอดคล้องกับการเคลื่อนไหวของราคาหุ้นอย่างชัดเจน ซึ่ง Indicator ที่เราจะใช้วัด Momentum ของราคา ซึ่งก็คือ RSI

แต่อย่างไรก็ตาม สัญญาณที่ถือว่าทรงพลังที่สุดรูปแบบหนึ่งของเครื่องมือ RSI ตามที่ Wilder ได้กล่าวไว้ คือ การเกิด “Divergence” นั้นเอง โดยเขาเชื่อว่าจุดที่เกิด Bearish Divergence ซึ่งเป็นจุดที่ราคาทำจุดสูงสุดใหม่ แต่ RSI นั้น ไม่ทำจุดสูงสุดใหม่ แปลว่า ตลาดนั้นใกล้ที่จะเกิดการเปลี่ยนแนวโน้มจากขาขึ้นเป็นขาลง และกลับกันเขาเชื่อว่าจุดที่เกิด Bullish Divergence ซึ่งเป็นจุดที่ราคาทำจุดต่ำสุดใหม่ แต่ RSI ไม่ทำจุดต่ำสุดใหม่ หมายความว่า ตลาดนั้นใกล้จะเปลี่ยนแนวโน้มจากขาลงเป็นขาขึ้นนั่นเอง โดย RSI นั้นเป็นเครื่องมือวิเคราะห์ปัจจัยเทคนิคยอดนิยมที่คิดค้นโดยคุณ J. Welles Wilder ซึ่งทำการ

ตีพิมพ์ครั้งแรกในหนังสือ New Concepts in Technical Trading Systems ในปี 1978 โดยมีหน้าที่เป็นเครื่องมือที่ใช้วัด Momentum ของราคา (Momentum Oscillator) โดยค่าของ RSI จะอยู่ระหว่าง 0 – 100 โดยมีการกำหนดให้ระดับ RSI ที่ 70 หรือ 80 เป็นจุดที่เรียกว่า “Overbought” หรือ “เขตซื้อมากเกิน” และระดับ RSI ที่ 30 หรือ 20 เป็นจุดที่เรียกว่า “Oversold” หรือ “เขตขายมากเกิน” นั่นเอง

โดยถ้าให้อธิบายโดยหลักการทางวิทยาศาสตร์ คือ การที่ราคาหุ้นมีการปรับตัวลงต่ำกว่าจุดต่ำสุด (หรือสูงสุด) ใหม่ไปด้วย ซึ่งหมายความว่า มีความเป็นไปได้ที่แนวโน้มของราคาจะไม่สามารถไปต่อในทิศทางเดิมได้อย่างยั่งยืน โดยตั้งแต่นั้นเป็นต้นมาองค์ความรู้เกี่ยวกับปรากฏการณ์ “Divergence” ของศาสตร์แห่งการวิเคราะห์หุ้นด้วยปัจจัยเทคนิคก็มีการถ่ายทอดต่อกันทั้งในประเทศและต่างประเทศ ซึ่งปัจจุบัน Trader ทั่วโลกต่างก็มองหาสัญญาณนี้ในสินทรัพย์การเงินทุกแบบ (Assets Class) เพื่อที่จะหาโอกาสทำกำไร โดยเราสามารถดูตัวอย่างของ “Divergence” ดังภาพที่ 2.5.



ภาพที่ 2.5. แสดงภาพงานวิจัยอ้างอิงจาก SiamQuant

ที่มา : www.siamquant.com

ผลงานวิจัยของ SiamQuant เรื่อง Bullish Divergence บนเว็บไซต์ www.siamquant.com ซึ่งเป็นรูปแบบกราฟหุ้น ที่มีลักษณะ คือ Candlestick Chart จะทำค่า Lower Low แต่ RSI Line chart จะทำค่า Higher Low

พบว่า ผลสถิติของผลตอบแทนจากการจำลองการลงทุนให้ผลลัพธ์ที่น่าสนใจ สามารถประยุกต์ใช้ลงทุน โดยสรุป Win Rate = 60.90%, Avg. Profit = 13.94% และ Net Profit = 94.95% จากทดสอบ Back Test ด้วยข้อมูลหุ้นในตลาดหลักทรัพย์แห่งประเทศไทย ช่วงเวลา 01/01/2007 ถึง 01/01/2017 งานวิจัยฉบับนี้ จึงได้นำรูปแบบ Bullish Divergence ดังกล่าวมาสนับสนุนการดำเนินการงานวิจัย

2.2. การเรียนรู้เชิงลึก

การเรียนรู้ของเครื่อง (Machine Learning) หมายถึง การทำให้เครื่องคำนวณสามารถเรียนรู้งาน (Task) จากตัวอย่าง (Sample) หรือประสบการณ์ (Experience) จำนวนหนึ่ง เพื่อให้สามารถทำงานนั้นมีประสิทธิภาพ (Performance) ประสบการณ์เรียนรู้ของมนุษย์ที่เกิดขึ้นกับตัวเราโดยตรง เป็นตัวอย่างที่ดีในการเข้าใจการเรียนรู้ของเครื่องได้ง่ายขึ้น เช่น ในวัยเด็ก เราเรียนรู้การเขียนตัวอักษร ก.ไก่ ด้วยวิธีการคัดลายมือด้วยสมุดคัดลายมือที่จุดไข่ปลาให้เขียนตาม เมื่อเราคัดลอกแล้วจะเริ่มคัดลายมือโดยไม่มีจุดไข่ปลาอีก จนในที่สุดเราก็สามารถจดจำและทำการเขียนตัวอักษร ก.ไก่ ได้ โดยไม่จำเป็นต้องทำการคัดลายมืออีก ซึ่งสามารถเปรียบเทียบกับการเรียนรู้ของเครื่องได้ดังนี้

- งาน (Task) คือ การเขียนตัวอักษร ก.ไก่ ได้
- ประสบการณ์ (Experience) คือ การฝึกคัดลายมือ
- ประสิทธิภาพ (Performance) คือ ความถูกต้อง และความสวยงามของลายมือที่เขียนอักษร ก.ไก่ หลังจากที่ได้คัดลายมือ

สาเหตุสำคัญว่าทำไมเครื่องจักรต้องทำการเรียนรู้ เพราะเครื่องจักรเหล่านี้ไม่สามารถตอบสนองความต้องการของเราได้อย่างเต็มที่ หากไม่มีระบบการเรียนรู้เพิ่มเติม เช่น เครื่องปรับอากาศ ควรมีการปรับอุณหภูมิให้เหมาะสมตลอดเวลา โดยไม่ให้ผู้รู้สึกร้อนหรือหนาวเกินไป หรือกล้องถ่ายรูปก็ควรมีระบบปรับจุดโฟกัสอัตโนมัติให้ภาพชัดเจนในจุดที่ต้องการ ซึ่งสิ่งเหล่านี้เราไม่สามารถ

สร้างเตรียมไว้ก่อนได้ เพราะมีปัจจัยแวดล้อมที่เปลี่ยนแปลงได้เสมอ ซึ่งหลักการเรียนรู้ของเครื่องสามารถช่วยแก้ปัญหาเหล่านี้ได้

การเรียนรู้แบบมีผู้สอน (Supervised Learning) คือ การเรียนรู้ของเครื่องที่สร้างโมเดลการวิเคราะห์จากข้อมูลผู้สอน (Training Data) ข้อมูลสอนจะประกอบไปด้วยข้อมูลต่างๆ (Input) และผลลัพธ์ (Output) โปรแกรมจะเรียนรู้รูปแบบต่างๆ จากข้อมูลสอน เพื่อนำไปวิเคราะห์หาผลลัพธ์จากข้อมูลอื่นๆ ตัวอย่าง เช่น เราต้องให้โปรแกรมเรียนรู้การแยกแยะ แอปเปิ้ล มะม่วง และส้มออกจากกัน เราต้องให้โปรแกรมเรียนรู้ถึงลักษณะของสิ่งต่างๆ ของผลไม้เหล่านั้น เช่น สี รูปทรง หรือกลิ่น เป็นต้น นี่เป็นตัวอย่างหนึ่งของการจัดหมวดหมู่ (Classification) แบบหนึ่ง


การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) คือ การเรียนรู้ของเครื่องที่สร้างโมเดลที่เหมาะสมกับข้อมูล การเรียนรู้แบบนี้แตกต่างจากการเรียนรู้แบบมีผู้สอน คือ จะไม่มีการระบุผลลัพธ์ไว้ก่อน การเรียนรู้แบบนี้จะพิจารณาหาความสัมพันธ์จากข้อมูลด้วยตัวมันเอง เช่น เรามีผลไม้อยู่ 3 ชนิด เราต้องการให้โปรแกรมเรียนรู้ผลไม้ทั้ง 3 ชนิดนี้ แล้วสามารถแยกแยะผลไม้ทั้ง 3 ชนิดนี้ได้ด้วยตัวมันเอง โดยที่เราไม่สอนมันว่าแต่ละชนิดมีลักษณะแตกต่างกันอย่างไร ในท้ายสุดโปรแกรมจะสามารถแยกผลไม้แต่ละลูกว่าควรอยู่กลุ่มใด แต่ไม่สามารถบอกได้ว่าเป็นผลไม้ชนิดใด

การเรียนรู้แบบเสริมกำลัง (Reinforcement Learning) คือ การเรียนรู้ของเครื่องที่มีปฏิสัมพันธ์กับสิ่งแวดล้อมที่เปลี่ยนไปตลอดเวลา ตัวอย่าง เช่น โปรแกรม AlphaGo (Deep Mind, 2018) ของ Google ทุกครั้งที่ผู้เล่นเดินหมาก AlphaGo ก็จะคำนวณและวิเคราะห์หาตาเดินใหม่ตามสภาพแวดล้อม ซึ่งก็คือ รูปแบบการเล่นของผู้เล่นที่เปลี่ยนไป เป็นต้น

2.2.1. โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks: CNNs)

Convolutional Neural Networks ⁴ เป็นโครงข่ายประสาทเทียมแบบคอนโวลูชัน ที่มีกระบวนการสกัดคุณลักษณะสำคัญของภาพออกมาก แปลงค่าระดับ Pixel จากข้อมูลรูปภาพ Input ทั้งหมด 3 ช่อง (Channel) คือ สีแดง สีน้ำเงิน และสีเขียว ให้เป็นค่าตัวเลขระหว่าง 0 - 255 เพื่อเป็นค่าแทนความเข้มของสีในระดับพิกเซล ทำให้ต้องใช้ประสิทธิภาพของเครื่องคอมพิวเตอร์อย่างมาก ดังนั้น CNNs จึงไม่ค่อยเป็นที่นิยม แต่ในปัจจุบันการพัฒนาหน่วยประมวลผลกราฟฟิก (GPU) สามารถรองรับการคำนวณได้อย่างมีประสิทธิภาพสูง จึงทำให้ CNNs ประสบความสำเร็จในการแก้ปัญหา

Classification ที่เกี่ยวข้องกับรูปภาพ โดยกระบวนการมีขั้นตอน Convolution, Relu, Pooling, and Fully Connected แล้วจึงคำนวณผลลัพธ์ Prediction ดังภาพที่ 2.6.



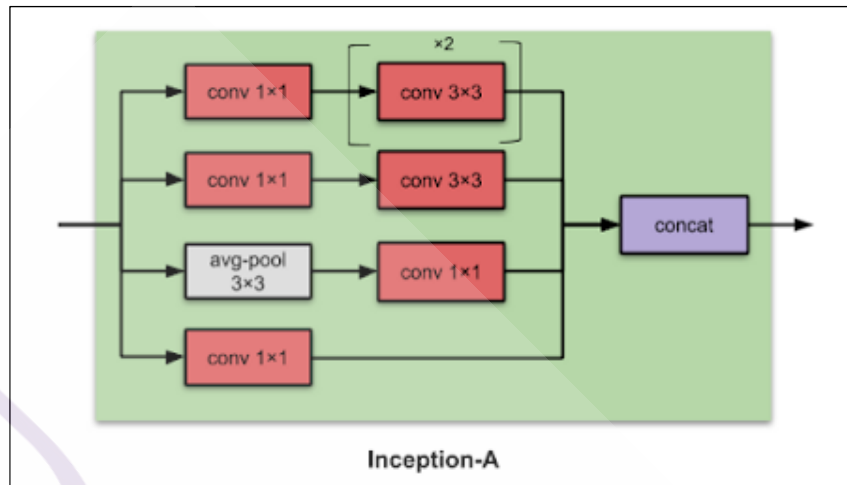
ภาพที่ 2.6. แสดงภาพตัวอย่างโครงสร้างของ Convolutional Neural Networks

ที่มา : www.en.wikipedia.org/wiki/Convolutional_neural_network

2.2.2. สถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชัน

- InceptionV2

การเรียนรู้เชิงลึก InceptionV2⁵ ภายใน Convolutional Layers มีลักษณะของการแตก Feature เพิ่มเติมจากเดิมและแตกต่างกัน โดยนำข้อมูลที่ได้ มา Concat กัน ดังภาพที่ 2.7.




ภาพที่ 2.7. แสดงภาพตัวอย่างโครงสร้างของ Inception

ที่มา : www.towardsdatascience.com

- Resnet50

การเรียนรู้เชิงลึก Resnet50⁶ ภายใน Convolutional Layers มีลักษณะของการอ้างอิง feature ก่อนหน้ามาสนับสนุน โดยนำข้อมูลที่ได้ มา Concat กัน ดังภาพที่ 2.8.



ภาพที่ 2.8. แสดงภาพตัวอย่างโครงสร้างของ ResNet

ที่มา : www.towardsdatascience.com

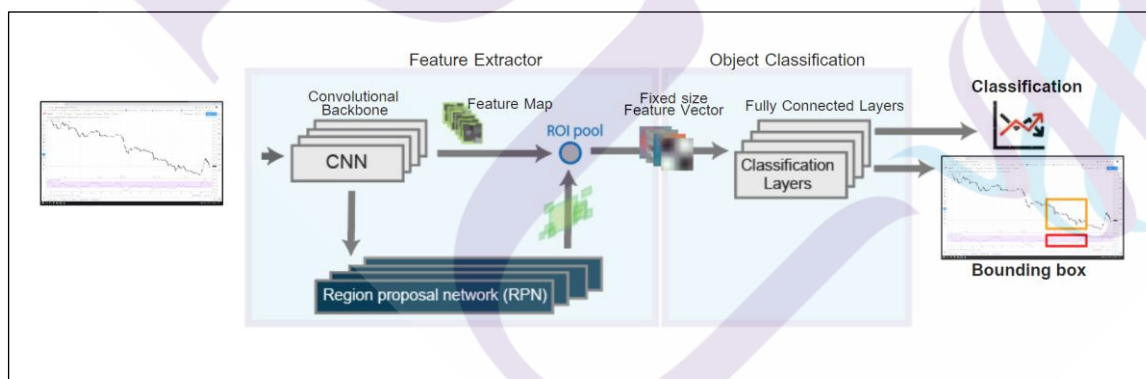
2.2.3. การตรวจหาวัตถุในภาพ โดย Faster R-CNNs (Faster Regional-Convolutional Neural Networks)

Faster Regional- Convolutional Neural Networks พัฒนาต่อจาก CNNs, R-CNNs ⁷, Fast R-CNNs ⁸ ซึ่งเป็นการทำ Object Detection ที่ปรับปรุงข้อจำกัดหลายอย่าง เพื่อเพิ่มความแม่นยำและความรวดเร็วในการตรวจหาวัตถุ ซึ่งโครงสร้างของ Faster R-CNNs ประกอบด้วย

Convolutional Layers นำข้อมูลรูปภาพ Input มา Process ส่งค่าออกมาเป็นลักษณะ Feature Map แล้วแบ่งเป็น 2 เส้นทาง โดยเส้นทางที่ 1. ส่ง Feature Map ไป Region Proposal Network (RPN) และเส้นทางที่ 2. ส่ง Feature Map ไปรอค่าจาก RPN ก่อนการ RoI Pooling (Region of Interest Pooling)

RPN ทำหน้าที่สกัดเอา บริเวณที่น่าจะเป็นวัตถุ จาก Feature Map แล้วส่งค่า Region ที่ได้สู่กระบวนการ RoI Pooling

RoI Pooling เป็นขั้นตอนการนำค่า Region จาก RPN มา Pooling กับ Feature Map ของเส้นทางที่ 2. เพื่อสร้าง Feature Vector ที่มีขนาดคงที่ ส่ง Fully Connected Layers ทำการคำนวณผลลัพธ์ แล้วแสดงผลการทำนายออกมาเป็น 2 ลักษณะ คือ Classification และ Bounding Box เพื่อตอบว่า มีวัตถุใด และอยู่บริเวณใด ของภาพ ดังภาพที่ 2.9.

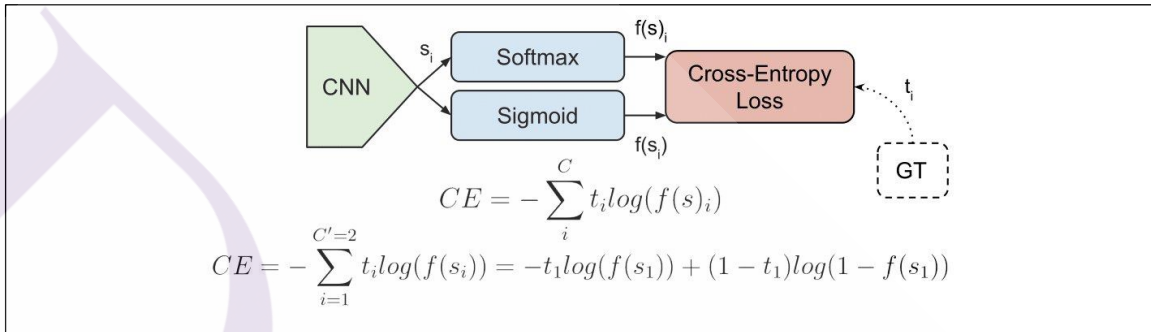


ภาพที่ 2.9. แสดงภาพโครงสร้าง Faster Regional-Convolutional Neural Networks

ที่มา : www.ch.mathworks.com

2.2.4. Loss Function


- Categorical Cross Entropy Loss⁹ ทำหน้าที่ Loss Function ใน Fully Connected Layers มุ่งเน้นการหาผลลัพธ์แบบ Multi-Class Classification (softmax) ดังภาพที่ 2.10.



ภาพที่ 2.10. แสดงภาพสมการ Categorical Cross Entropy Loss

ที่มา : www.gombru.github.io

- Focal Loss¹⁰ ทำหน้าที่ Loss Function ใน Fully Connected Layers มุ่งเน้นการหาผลลัพธ์แบบ Multi-Label Classification (sigmoid) ดังภาพที่ 2.11



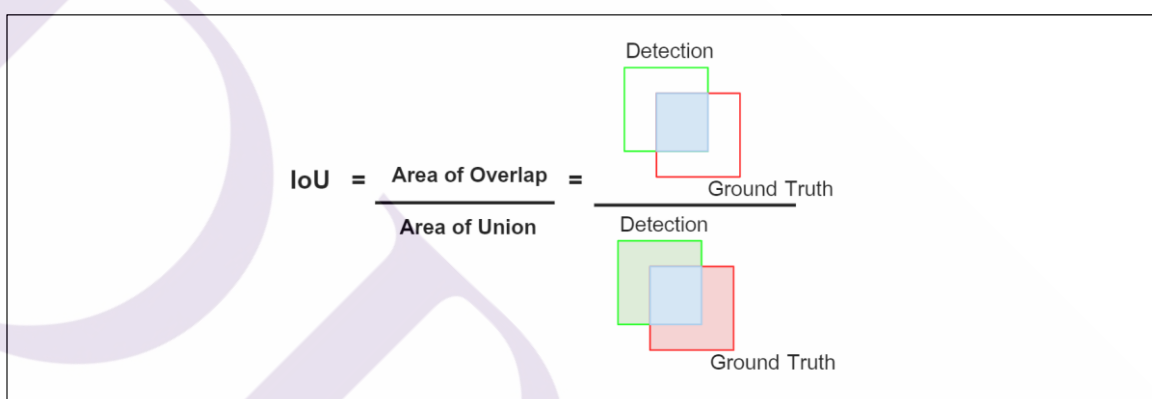
ภาพที่ 2.11. แสดงภาพสมการ Focal Loss

ที่มา : www.towardsdatascience.com

2.3. การวัดประสิทธิภาพ

- IoU (Intersection over Union)

การหาค่า IoU (Intersection over Union) ¹¹ ซึ่งใช้ค่าพื้นที่ของพิกัดตำแหน่งที่ได้จากผลการตรวจหารูปแบบกราฟหุ่น มาคำนวณหาพื้นที่ร่วมกัน เปรียบเทียบกับค่าพื้นที่ของพิกัดตำแหน่งที่ได้จาก Ground Truth ดังภาพที่ 2.12. โดยค่า IoU ที่ดีที่สุด คือ 1.00



ภาพที่ 2.12. แสดงภาพการคำนวณของค่า IoU

ที่มา : www.pyimagesearch.com

- AP (Average Precision) @ IoU ≥ 0.50

เมื่อตรวจหารูปแบบกราฟหุ่นที่ให้ค่า IoU ≥ 0.50 เท่านั้นในแต่ละครั้ง ก็จะนำการตรวจหาที่ได้มาใช้หาค่าความแม่นยำ Precision ในแต่ละครั้ง แล้วหาค่าเฉลี่ยของความแม่นยำ AP (Average Precision) ของโมเดล

- Confusion Matrix

คือ การประเมินผลลัพธ์การพยากรณ์ของโมเดลเปรียบเทียบกับผลลัพธ์จริงๆ ที่วิเคราะห์ด้วยมนุษย์ โดยแสดงเมตริกซ์การวัดประสิทธิภาพสำหรับการจำแนกประเภทข้อมูล 2 กลุ่ม

แถวของเมตริกซ์จะแสดงจำนวนของตัวอย่างจริงของแต่ละคลาส และคอลัมน์จะแสดงจำนวนที่พยากรณ์ได้ของแต่ละคลาส จากตารางที่ 2.1. โดยจะแบ่งออก 4 กรณี ดังนี้

กรณีที่ 1. ค่า “TP : True Positive”

คือ สิ่งที่ไม่เคยพยากรณ์ “ถูกต้อง” และคนบอกว่ามัน “ใช่จริง”

กรณีที่ 2. ค่า “TN : True Negative”

คือ สิ่งที่ไม่เคยพยากรณ์ “ไม่ถูกต้อง” และคนบอกว่ามัน “ไม่ใช่จริง”

กรณีที่ 3. ค่า “FP : False Positive”

คือ สิ่งที่ไม่เคยพยากรณ์ “ถูกต้อง” แต่คนบอกว่ามัน “ไม่ใช่จริง”

กรณีที่ 4. ค่า “FN : False Negative”

คือ สิ่งที่ไม่เคยพยากรณ์ “ไม่ถูกต้อง” แต่คนบอกว่ามัน “ใช่จริง”

ตารางที่ 2.1. แสดงตาราง Confusion Matrix การจำแนกประเภทข้อมูล 2 กลุ่ม

		Prediction	
		Positive	Negative
Actual	Positive	TP : True Positive ถูกต้อง และ ใช่จริง	FN : False Negative ไม่ถูกต้อง แต่ ใช่จริง
	Negative	FP : False Positive ถูกต้อง แต่ ไม่ใช่จริง	TN : True Negative ไม่ถูกต้อง และ ไม่ใช่จริง

ค่าร้อยละของจำนวนผลลัพธ์การพยากรณ์ว่าถูกต้องและใช้จริง (Precision) เมื่อเทียบกับจำนวนผลลัพธ์ของการพยากรณ์ว่าถูกต้องทั้งหมด ของกลุ่มข้อมูลที่สนใจ

กล่าวคือ เป็นค่าที่อธิบายถึง โมเดลพยากรณ์จำนวนว่าถูกต้องและใช้จริง เป็นอัตราส่วนเท่าไร ของจำนวนการพยากรณ์ว่าถูกต้องทั้งหมด ของกลุ่มข้อมูลที่สนใจ

$$precision = \frac{True\ Positive}{True\ Positive + False\ Positive}$$

ค่าร้อยละของจำนวนผลลัพธ์การพยากรณ์ว่าถูกต้องและใช้จริง (Recall) เมื่อเทียบกับจำนวนความเป็นจริงทั้งหมด ของกลุ่มข้อมูลที่สนใจ ซึ่งสามารถคำนวณได้สมการดังต่อไปนี้

กล่าวคือ เป็นค่าที่อธิบายถึง โมเดลพยากรณ์จำนวนว่าถูกต้องและใช้จริง เป็นอัตราส่วนเท่าไร ของจำนวนที่ใช้จริงทั้งหมด ของกลุ่มข้อมูลที่สนใจ

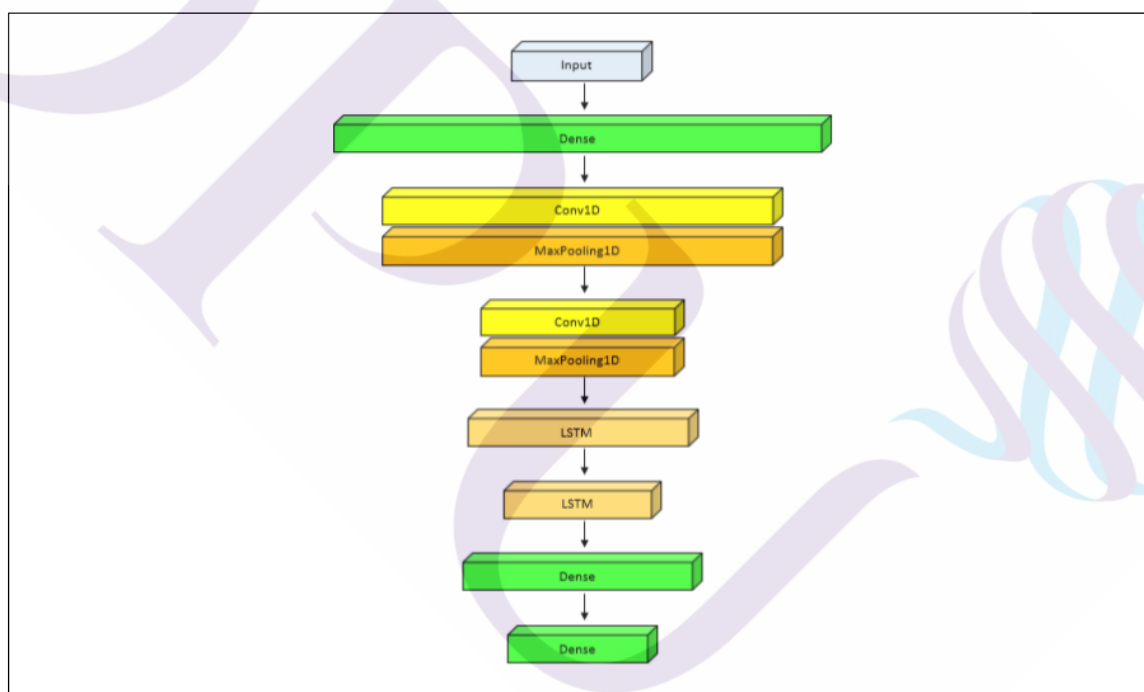
$$recall = \frac{True\ Positive}{True\ Positive + False\ Negative}$$

2.4. งานวิจัยที่เกี่ยวข้อง

งานวิจัยที่เกี่ยวกับการพยากรณ์แนวโน้มของราคาหลักทรัพย์ ด้วยวิธีการเรียนรู้ของเครื่อง (Machine Learning) มีจำนวนมาก แต่การเรียนรู้แบบ Image Processing สำหรับการตรวจหารูปแบบกราฟหุ้นนั้น มีนักวิจัยจำนวนไม่มากนักนำเสนอ ซึ่งผู้วิจัยได้ศึกษางานวิจัยที่ได้รับการตีพิมพ์เหล่านั้น และสรุปได้ดังนี้

2.4.1 Sreelekshmy Selvin, et al. (2017)

งานวิจัย¹ สร้าง Image โดยใช้ข้อมูล Indicator ย้อนหลัง แล้วเลือกใช้ CNN-TA เพื่อหาผลตอบแทนที่ดีที่สุดจากการซื้อขายหุ้น เทียบกับกลยุทธ์ LSTM, MLP, และ Buy and Hold



ภาพที่ 2.13. แสดงภาพโครงสร้าง CNN-TA

ตารางที่ 2.2. แสดงตารางเปรียบเทียบค่า RMSE ของแต่ละ โมเดล

NN Model	RMSE
LSTM	0.1364
CNN	0.0226
Conv1D - LSTM	0.0179

พบว่า การสร้าง Image โดยใช้ข้อมูล Indicator ย้อนหลัง แล้ว พบว่า จากการใช้งาน CNN-TA (Convolutional Neural Network – Technical Analysis) ให้ค่า RMSE น้อยที่สุด เมื่อเทียบกับกลยุทธ์ LSTM, MLP, และ Buy and Hold

2.4.2 Marc Velay, et al. (2018)

งานวิจัย² ได้ตรวจหา Pattern ของหุ้นจากการเลือกใช้ 2D-CNNs โดยนำภาพของ Pattern หุ้นย้อนหลัง เทียบกับการเลือกใช้ 1D-CNNs ซึ่งใช้ข้อมูล OHLCV ย้อนหลัง แต่อย่างไรก็ตามผลลัพธ์ของทั้งคู่ ยังไม่มีประสิทธิภาพที่จะนำไปใช้งาน เมื่อเทียบกับ การ Hard-coded



ภาพที่ 2.14. แสดงภาพโครงสร้าง 2D-CNNs

ตารางที่ 2.3. แสดงตารางเปรียบเทียบค่า Recall ของแต่ละ โมเดล

Algorithm	Recall	Generalization
LSTM	0.97	0.3%
2D CNN	0.73	–
1D CNN	0.64	–

พบว่า การใช้งาน CNNs เพื่อหาความถูกต้องของรูปแบบหุ้นจาก 2D-CNNs (Two-Dimensional Convolutional Neural Networks) ซึ่งใช้ข้อมูลรูปภาพของรูปแบบกราฟหุ้นย้อนหลัง และการเลือกใช้ 1D-CNNs (One-Dimensional Convolutional Neural Networks) ซึ่งใช้ข้อมูล OHLCV (Open, High, Low, Close, Volume) ย้อนหลัง นั้นยังไม่มีประสิทธิภาพที่จะนำไปใช้งาน เมื่อเทียบกับ Hard-coded ที่ใช้ข้อมูล OHLCV ย้อนหลัง

โดยสรุปจากการศึกษางานวิจัยที่เกี่ยวข้อง พบว่า CNNs (Convolutional Neural Networks) มีทั้งข้อดีและข้อเสีย แต่ยังคงขาดประสิทธิภาพที่จะนำไปใช้งาน ดังนั้นงานวิจัยฉบับนี้จะมุ่งเน้นการตรวจหารูปแบบกราฟหุ้นด้วยเทคนิคใหม่ เพื่อสร้างทางเลือก และเพิ่มความแม่นยำในการตรวจหารูปแบบกราฟหุ้นที่ปรากฏบนรูปภาพกราฟหุ้นเท่านั้น

บทที่ 3

ระเบียบวิธีวิจัย

งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาการตรวจหารูปแบบกราฟหุ้น Bullish Divergence โดยโครงข่ายประสาทเทียมคอนโวลูชันแบบฟาสเตอร์ อาร์ (Faster Regional-Convolutional Neural Networks: Faster R-CNNs) เพื่อให้สอดคล้องกับ ข้อมูลรูปภาพกราฟหุ้นที่มีลักษณะเฉพาะและสัมพันธ์กัน โดยเป็นการนำเสนอ แนวทางการสร้างเลเบลข้อมูล การเลือกใช้โมเดลการเรียนรู้เชิงลึกที่แตกต่างกัน มาประกอบกับการใช้ Loss Function ที่แตกต่างกันใน Faster R-CNNs วิธีการนี้มีเป้าหมาย คือ เพิ่มประสิทธิภาพความแม่นยำของโมเดลที่ใช้ในการตรวจหารูปแบบกราฟหุ้น

3. ระเบียบวิธีวิจัย

3.2. แนวทางการวิจัย

3.2. การเตรียมข้อมูล

3.3. การสร้างเลเบลข้อมูล สำหรับการสอนระบบ

3.3.1. รูปแบบที่ 1. Candlestick Chart with RSI Line Chart = 1 Label

3.3.2. รูปแบบที่ 2. Candlestick Chart and RSI Line Chart = 2 Labels

3.3.3. รูปแบบที่ 3. Candlestick Chart and RSI Line Chart = 2 Labels + X-axis

3.4. การสอนระบบ Faster R-CNNs สำหรับการตรวจหา

3.4.1. กลยุทธ์ที่ 1. InceptionV2 + Categorical Cross Entropy Loss

3.4.2. กลยุทธ์ที่ 2. InceptionV2 + Focal Loss

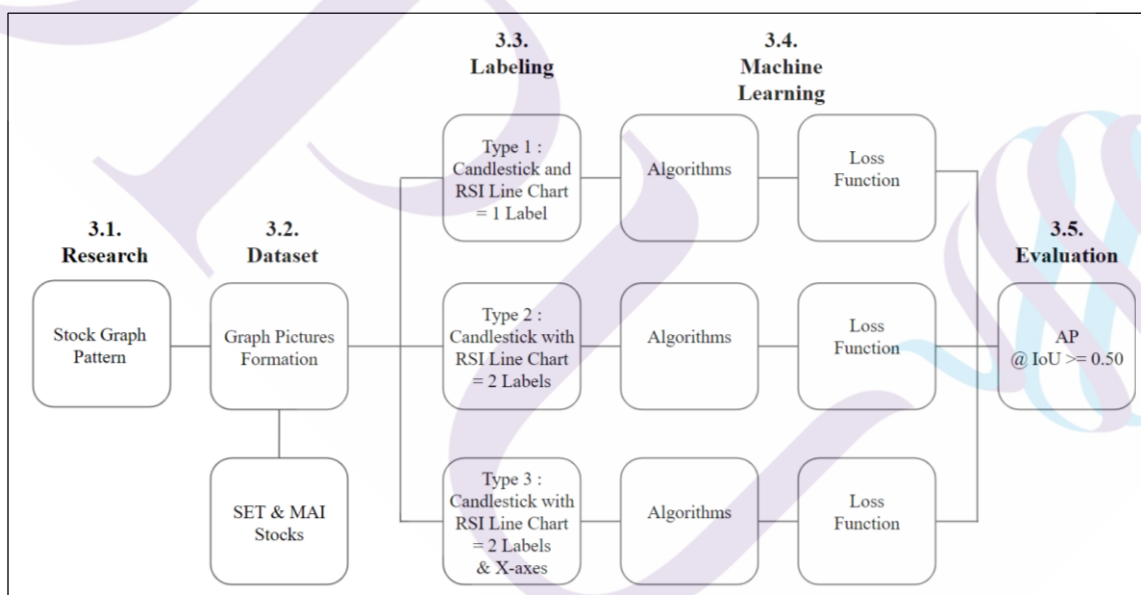
3.4.3. กลยุทธ์ที่ 3. ResNet50 + Categorical Cross Entropy Loss

3.4.4. กลยุทธ์ที่ 4. ResNet50 + Focal Loss

3.5. วิเคราะห์และสรุปผล (AP @ IoU \geq 0.50)

3.1. แนวทางการวิจัย

จากข้อมูลที่จัดเตรียมบนเว็บไซต์ โดยนำเสนอ การสร้างเลเบลข้อมูล และการสร้างโมเดลการเรียนรู้เชิงลึกที่แตกต่างกัน มาประกอบกับการใช้ Loss Function ที่แตกต่างกัน ดังภาพที่ 3.1.



ภาพที่ 3.1. แสดงภาพรวมการทำงานของ การตรวจหารูปแบบกราฟหุ้น

3.2. การเตรียมข้อมูล

นำรูปภาพกราฟหุ้นจากตลาดหลักทรัพย์แห่งประเทศไทยบนเว็บไซต์ www.tradingview.com โดยเฉพาะรูปภาพกราฟหุ้นที่ปรากฏ Bullish Divergence และกำหนดดังนี้ ดังภาพที่ 3.2.

- JPEG-type Resolution 1080 (height) x 1920 (width) pixels
- Candlestick Chart (1D) (close) 1year (log scale)
- RSI Line Chart (14) (close) 1year (log scale)
- จำนวนรูปทั้งหมด 505 รูป
 - ข้อมูลสอนระบบ Train Data จำนวน 2950 รูป (59%) และ Validation Data จำนวน 600 รูป (12%) จากหุ้นของ SET ในปี ค.ศ. 2014 ถึง 2018
 - ข้อมูลทดสอบระบบ Test Data จำนวน 1500 รูป (29%) จากหุ้นของ SET ในปี ค.ศ. 2018 ถึง 2019



ภาพที่ 3.2. แสดงภาพตัวอย่างรูปภาพกราฟหุ้น

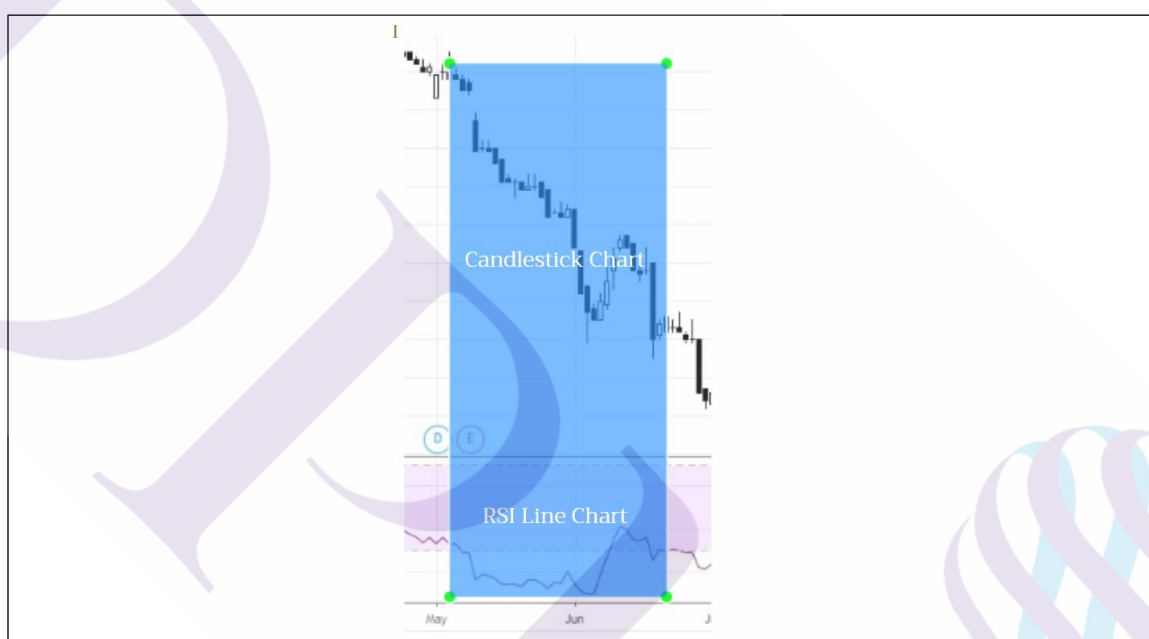
ที่มา : www.tradingview.com

3.3. การสร้างเลเบลข้อมูล สำหรับการสอนระบบ

แบ่งเป็น 3 รูปแบบ ในการระบุตำแหน่งเพื่อดำเนินการวิจัย

3.3.1. รูปแบบที่ 1. Candlestick Chart with RSI Line Chart = 1 Label

ระบุตำแหน่งเป็นทรงสี่เหลี่ยม ครอบคลุม Candlestick Chart กับ RSI Line chart พร้อมกัน เป็น 1 Label ต่อ 1 Stock Pattern สำหรับ Train และ Validation ดังภาพที่ 3.3.



ภาพที่ 3.3. แสดงภาพตัวอย่างการสร้าง Label รูปแบบที่ 1.

3.3.2. รูปแบบที่ 2. Candlestick Chart and RSI Line Chart = 2 Labels

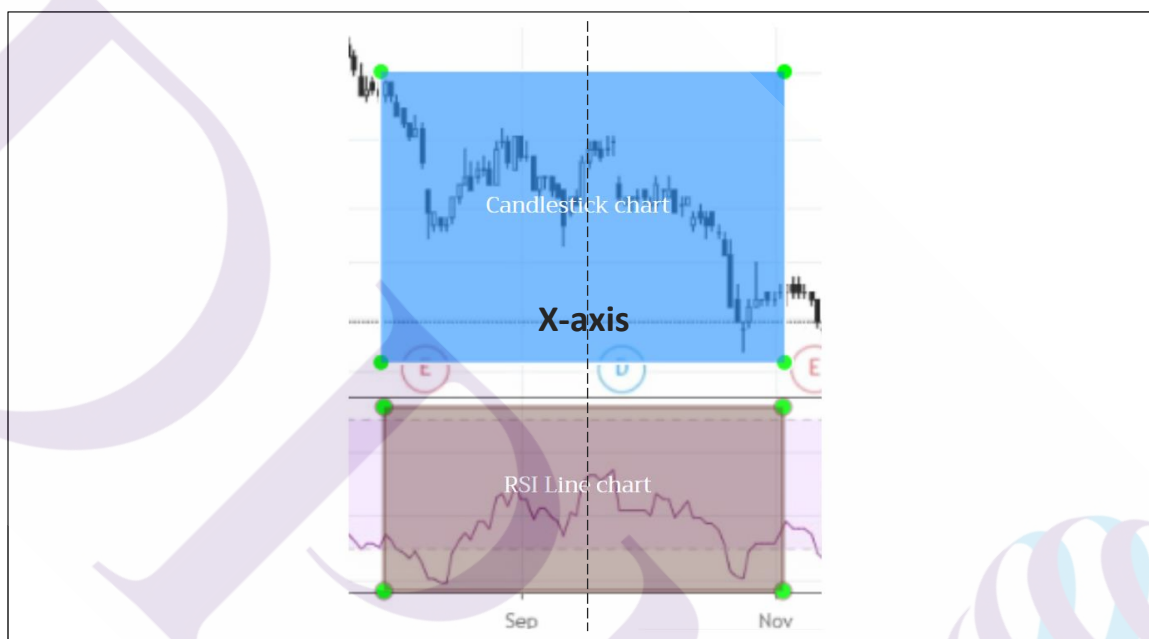
ระบุตำแหน่งเป็นทรงสี่เหลี่ยม เป็น 2 Labels โดย Candlestick Chart เป็น Label ที่ 1 และ RSI Line chart เป็น Label ที่ 2 ต่อ 1 Stock Pattern สำหรับ Train และ Validation ดังภาพที่ 3.4.



ภาพที่ 3.4. แสดงภาพตัวอย่างการสร้าง Label รูปแบบที่ 2.

3.3.3. รูปแบบที่ 3. Candlestick Chart and RSI Line Chart = 2 Labels + X-axis

ระบุตำแหน่งเป็นทรงสี่เหลี่ยม เป็น 2 Labels โดย Candlestick Chart เป็น Label ที่ 1 และ RSI Line chart เป็น Label ที่ 2 ต่อ 1 Stock Pattern สำหรับ Train และ Validation ก่อนพิจารณาแกน X ที่ปรากฏร่วมกัน ดังภาพที่ 3.5.



ภาพที่ 3.5. แสดงภาพตัวอย่างการสร้าง Label รูปแบบที่ 3.

3.4. การสอนระบบ Faster R-CNNs สำหรับการทำนาย

สอนระบบการเรียนรู้เชิงลึกด้วยอัลกอริทึม และ Loss Function ที่แตกต่างกัน เพื่อใช้ค้นหาอัลกอริทึม และ Loss Function ที่มีความสอดคล้องกับลักษณะเด่นของข้อมูลรูปแบบกราฟหุ้น และความแม่นยำที่สุด โดยแบ่งเป็น 4 กลยุทธ์ ดังนี้

3.4.1. กลยุทธ์ที่ 1. InceptionV2 + Categorical Cross Entropy Loss

3.4.2. กลยุทธ์ที่ 2. InceptionV2 + Focal Loss

3.4.3. กลยุทธ์ที่ 3. ResNet50 + Categorical Cross Entropy Loss

3.4.4. กลยุทธ์ที่ 4. ResNet50 + Focal Loss

3.5. วิเคราะห์และสรุปผล (AP @ IoU \geq 0.50)

เปรียบเทียบค่าเฉลี่ยของความแม่นยำของโมเดล โดยใช้ค่า IoU จากการตรวจหารูปแบบกราฟหุ้นแบบ Bullish Divergence เทียบกับ Ground Truth

- ใช้ค่า Precision เฉพาะที่มีค่า IoU \geq 0.50
- นำค่า AP @ IoU \geq 0.50 วัดประสิทธิภาพความแม่นยำของโมเดล

บทที่ 4

ผลการวิจัย

4. ผลการวิจัย

- 4.1. การเปรียบเทียบความแม่นยำของการสร้างเลเบล 3 รูปแบบของ 4 กลยุทธ์
- 4.2. การเปรียบเทียบความแม่นยำของการแยกโมเดล Candlestick Chart และ RSI Line Chart
- 4.3. ตัวอย่างผลลัพธ์ของการตรวจหารูปแบบกราฟหุ้น

4.1. การเปรียบเทียบความแม่นยำของการสร้างเลเบล 3 รูปแบบของ 4 กลยุทธ์

สร้างเลเบลข้อมูลสำหรับการสอนระบบ แบ่งเป็น 3 รูปแบบ ในการระบุตำแหน่งเพื่อดำเนินการวิจัย พร้อมทั้งสอนระบบการเรียนรู้เชิงลึกด้วยอัลกอริทึม และ Loss Function ที่แตกต่างกัน เพื่อใช้ค้นหาอัลกอริทึม และ Loss Function ที่มีความสอดคล้องกับลักษณะเด่นของข้อมูลรูปแบบกราฟหุ้น และให้ผลความแม่นยำดีที่สุด เป็น 4 กลยุทธ์ ให้ผลลัพธ์ ดังตารางที่ 4.1.

ตารางที่ 4.1. แสดงตารางเปรียบเทียบค่า AP @ IoU ≥ 0.50 ของการสร้างเลเบลทั้ง 3 รูปแบบ

Faster R-CNNs				
Labeling	Strategy 1.	Strategy 2.	Strategy 3.	Strategy 4.
	InceptionV2		ResNet50	
	Categorical Cross Entropy Loss	Focal Loss	Categorical Cross Entropy Loss	Focal Loss
Type 1. Candlestick with RSI Line Chart = 1 Label	0.5279	0.4565	0.3458	0.4275
Type 2. Candlestick and RSI Line Chart = 2 Labels	0.5779	0.4239	0.5225	0.4203
Type 3. Candlestick and RSI Line Chart = 2 Labels + X-axis	0.6086	0.4573	0.5545	0.4568

พบว่า การเลเบลรูปแบบที่ 3. โดยการแยกเลเบล Candlestick Chart เป็น Label ที่ 1 และ RSI Line chart เป็น Label ที่ 2 แล้วพิจารณาแกน X ที่ปรากฏร่วมกัน ของกลยุทธ์ที่ 1. InceptionV2 + Categorical Cross Entropy Loss ให้ค่าเฉลี่ยของความแม่นยำมากที่สุด AP = 0.6086 @ IoU ≥ 0.50

4.2. การเปรียบเทียบความแม่นยำของการแยกโมเดล Candlestick Chart และ RSI Line Chart

จากรูปแบบที่ 3. ของการเลเบิ้ล ซึ่งมีการหาจุดร่วมกันของแกน X ที่ปรากฏอีกภายหลัง ให้ผลการทำนายที่ดี จึงพิจารณาเปรียบเทียบความแม่นยำของการแยกโมเดล Candlestick Chart และ RSI Line Chart ในแต่ละเลเบิ้ล เพราะลักษณะเด่นของข้อมูลภาพระหว่าง Candlestick Chart และ RSI Line Chart ต่างกัน ด้วยอัลกอริทึม และ Loss Function ที่แตกต่างกัน ดังตารางที่ 4.2.

ตารางที่ 4.2. แสดงตารางเปรียบเทียบค่า AP @ IoU ≥ 0.50 หากพิจารณาแยกโมเดลของแต่ละเลเบิ้ล

Faster R-CNNs				
Modeling	InceptionV2		ResNet50	
	Categorical Cross Entropy Loss	Focal Loss	Categorical Cross Entropy Loss	Focal Loss
Candlestick	0.4565	0.3913	0.5398	0.3261
RSI	0.6992	0.4565	0.5050	0.5145

พบว่า Candlestick Chart โมเดล ResNet50 + Categorical Cross Entropy Loss ให้ค่าความแม่นยำมากที่สุด AP = 0.5398 @ IoU ≥ 0.50 และ RSI Line Chart โมเดล InceptionV2 + Categorical Cross Entropy Loss ให้ค่าเฉลี่ยของความแม่นยำมากที่สุด AP = 0.6992 @ IoU ≥ 0.50

เมื่อทราบประสิทธิภาพโมเดลที่เหมาะสม สำหรับ Candlestick Chart และ RSI Line Chart ดังนั้นจึงพิจารณาโมเดล Algorithm และ Loss Function แบบเจาะจงในแต่ละเลเบิ้ล โดยแยกโมเดล Candlestick Chart และโมเดล RSI Line Chart ก่อนพิจารณา X-axis ที่ปรากฏร่วมกัน ดังตารางที่ 4.3.

ตารางที่ 4.3. แสดงตารางเปรียบเทียบค่า AP @ IoU ≥ 0.50 หากพิจารณาเจาะจงโมเดลของแต่ละเลเบล

Faster R-CNNs (Labeling Type 3.)		RSI			
		InceptionV2		ResNet50	
Candlestick		Categorical Cross Entropy Loss	Focal Loss	Categorical Cross Entropy Loss	Focal Loss
InceptionV2	Categorical Cross Entropy Loss	0.6086	0.4565	0.4808	0.4855
	Focal Loss	0.5453	0.4573	0.4482	0.4529
ResNet50	Categorical Cross Entropy Loss	0.6195	0.4982	0.5545	0.5272
	Focal Loss	0.5127	0.3913	0.4156	0.4568

โดยสรุป สำหรับ Candlestick Chart โมเดล ResNet50 + Categorical Cross Entropy กับ RSI Line Chart โมเดล InceptionV2 + Categorical Cross Entropy ตรวจสอบรูปแบบกราฟหุ่นแบบ Bullish Divergence ด้วยการสร้างเลเบลรูปแบบที่ 3. ให้ค่าเฉลี่ยของความแม่นยำที่ดีที่สุด AP = 0.6195 @ IoU ≥ 0.50


4.3. ตัวอย่างผลลัพธ์ของการตรวจหารูปแบบกราฟหุ้น

4.3.1. รูปแบบที่ 1. ระบุตำแหน่งเป็นทรงสี่เหลี่ยม กรอบคลุม Candlestick Chart กับ RSI Line chart พร้อมกัน เป็น 1 Label ต่อ 1 Stock Pattern พบความแม่นยำน้อยจากการตรวจหารูปแบบกราฟหุ้น กล่าวคือ จำนวนภาพที่ตรวจหา มีจำนวนน้อย ตรวจพบไม่ครบถ้วน อีกทั้งตรวจหาไม่พบ ดังภาพที่ 4.1.



ภาพที่ 4.1. แสดงภาพตัวอย่างผลลัพธ์ของรูปแบบที่ 1.

4.3.2. รูปแบบที่ 2. ระบุตำแหน่งเป็นทรงสี่เหลี่ยม เป็น 2 Labels โดย Candlestick Chart เป็น Label ที่ 1 และ RSI Line chart เป็น Label ที่ 2 ต่อ 1 Stock Pattern พบความแม่นยำเพิ่มขึ้นแต่คลุมเครือจากการตรวจหารูปแบบกราฟหุ้น กล่าวคือ จำนวนภาพที่ตรวจหามีจำนวนมากขึ้น แต่มีส่วนเกินอีกทั้งส่วนที่ซ้อนทับและไม่สัมพันธ์กันระหว่าง 2 เลเบล ดังภาพที่ 4.2.



ภาพที่ 4.2. แสดงภาพตัวอย่างผลลัพธ์ของรูปแบบที่ 2.

4.3.3. รูปแบบที่ 3. ระบุตำแหน่งเป็นทรงสี่เหลี่ยม เป็น 2 Labels โดย Candlestick Chart เป็น Label ที่ 1 และ RSI Line chart เป็น Label ที่ 2 ต่อ 1 Stock Pattern แล้วพิจารณา X-axis ร่วมกัน พบความแม่นยำที่ถูกต้องจากการตรวจหารูปแบบกราฟหุ้น กล่าวคือ ตรวจพบจำนวนมาก รวมทั้งสามารถคัดกรองให้ตรวจหาเฉพาะส่วนที่ถูกต้องและมีความสัมพันธ์กัน ดังภาพที่ 4.3.



ภาพที่ 4.3. แสดงภาพตัวอย่างผลลัพธ์ของรูปแบบที่ 3.

โดยสรุป สำหรับการตรวจหารูปแบบกราฟหุ้นแบบ Bullish Divergence รูปแบบที่ 3. มีความแม่นยำดีที่สุด เทียบกับ รูปแบบที่ 1. และ รูปแบบที่ 2. อีกทั้ง Faster R-CNNs มีประสิทธิภาพยิ่งขึ้น เมื่อแยก Labels รวมทั้งการเรียนรู้เชิงลึกระหว่าง Candlestick Chart และ RSI Line Chart แล้วพิจารณา X-axis ที่ตำแหน่งร่วมกันภายหลัง

บทที่ 5

สรุป อภิปราย และข้อเสนอแนะ

งานวิจัยในวิทยานิพนธ์เล่มนี้ ได้กล่าวถึง การวิจัยการเพิ่มประสิทธิภาพความถูกต้องของการตรวจหารูปแบบกราฟหุ้นในตลาดหลักทรัพย์แห่งประเทศไทย จากข้อมูลรูปภาพของหุ้น ในปี ค.ศ. 2014 ถึง 2019 โดยใช้ปัจจัยหลัก 2 ปัจจัย คือ ข้อมูลรูปภาพ Candlestick Chart และข้อมูลรูปภาพ RSI Line Chart มาสร้างโมเดลเพื่อการตรวจหารูปแบบกราฟหุ้น ซึ่งในที่นี้ใช้รูปแบบกราฟหุ้น ที่เรียกว่า Bullish Divergence

โดยประยุกต์ใช้การเรียนรู้เชิงลึกแบบ Faster R-CNNs ซึ่งแบ่งออกเป็น 3 รูปแบบ คือ การสร้างเลเบลแบบร่วมกัน 1 Label การสร้างเลเบลแบบแยกกัน 2 Labels และการสร้างเลเบลแบบแยกกัน 2 Labels แล้วพิจารณาแกนเอ็กซ์ร่วมกันภายหลัง อีกทั้งการสร้างโมเดลจาก Algorithm และ Loss Function ที่แตกต่างกันจะจงลงไปในแต่ละเลเบล

หลังจากนั้น นำผลลัพธ์ที่ได้ไปตรวจหารูปแบบกราฟหุ้น Bullish Divergence เพื่อหาความแม่นยำของแต่ละโมเดล โดยเปรียบเทียบประสิทธิภาพความถูกต้อง ด้วยค่า AP @ IoU ≥ 0.50 ที่มีค่ามากที่สุด

5.1. สรุปผลการวิจัย

งานวิจัยนี้ นำเสนอการตรวจหารูปแบบกราฟหุ้น แบบ Bullish Divergence จากรูปภาพกราฟหุ้น ที่แสดง Candlestick Chart และ RSI Line Chart ของรูปภาพกราฟหุ้นรายตัวในตลาดหลักทรัพย์แห่งประเทศไทย ที่แสดงในเวปไซต์บนอินเทอร์เน็ตเท่านั้น

โดยประยุกต์ใช้ Faster R-CNNs และออกแบบโครงข่ายอัลกอริทึมอย่างเหมาะสมเท่าที่จำเป็น เพื่อสกัดลักษณะเด่นของรูปภาพกราฟหุ้น รวมทั้งวิธีการเลเบล ประกอบด้วยกลยุทธ์แยกโมเดลของการเรียนรู้เชิงลึกระหว่าง Candlestick Chart โดยใช้ ResNet50 กับ Categorical Cross Entropy Loss และ RSI Line Chart โดยใช้ InceptionV2 กับ Categorical Cross Entropy Loss แล้วพิจารณาแกนเอ็กซ์ร่วมกัน ภายหลัง ให้ค่าเฉลี่ยของความแม่นยำในการตรวจหารูปแบบกราฟหุ้นแบบบูลิชไดเวอร์เจนซ์ที่ดีที่สุด ด้วยการวัดค่า $AP = 0.6195 @ IoU \geq 0.50$

ในอนาคต เป็นไปได้ที่จะพัฒนาการตรวจหารูปแบบกราฟหุ้น จากการเพิ่มเติมรูปแบบกราฟหุ้น อื่น เช่น Darvas Box Theory เป็นต้น อีกทั้งการเพิ่มจำนวน Dataset ครอบคลุมไปสินทรัพย์อื่น เช่น FOREX เพื่อเพิ่มประสิทธิภาพของการตรวจหารูปแบบกราฟ และสร้างทางเลือกให้กับนักลงทุน

5.2. อภิปรายผลการวิจัย

จากการศึกษาวิจัยที่มีผลต่อประสิทธิภาพความถูกต้องของการตรวจหารูปแบบกราฟหุ้น ในตลาดหลักทรัพย์แห่งประเทศไทย ในช่วง ปี ค.ศ. 2014 ถึง 2019 ผู้ศึกษาได้ข้อสรุปที่น่าสนใจหลายประการ ดังนี้

5.2.1 จากการเปรียบเทียบผลของการตรวจรูปแบบกราฟหุ้นไทยในตลาดหลักทรัพย์แห่งประเทศไทย พบว่า การเรียนรู้จากการสร้างเลเบลแยกกันแล้วพิจารณาแกนเอ็กซ์ร่วมกันภายหลัง รวมทั้งการใช้โมเดลการเรียนรู้แบบเจาะจงของแต่ละเลเบลเป็นวิธีการที่เหมาะสม โดยพิจารณาจากค่าเฉลี่ยของความแม่นยำมีค่าประสิทธิภาพที่มากกว่า เมื่อเทียบกับวิธีการอื่น

5.2.2 จากการเปรียบเทียบผลของการตรวจรูปแบบกราฟหุ้นไทย ที่สร้างด้วยข้อมูลรูปภาพ Candlestick Chart และ RSI Line Chart เป็นกราฟที่มีลักษณะแตกต่างกัน พบว่า การเรียนรู้ด้วย Faster R-CNNs ในกระบวนการสร้าง Features ของ Convolutional Stage นั้น หากใช้โมเดลที่มีเลเบลร่วมกัน จะทำให้ข้อมูลระดับพิกเซลของรูปภาพที่ถูกสกัดไปมีลักษณะคล้ายคลึงกัน ทำให้ความแม่นยำลดลง

5.2.3 จากการเปรียบเทียบผลของการตรวจรูปแบบกราฟหุ้นไทย ด้วยวิธีการเรียนรู้ของโมเดลที่แตกต่างกัน พบว่า โมเดลอัลกอริทึม ResNet50 เหมาะกับข้อมูลภาพ Candlestick Chart เนื่องจากมีข้อมูล

ระดับฟิสิกส์จำนวนมาก และมีลักษณะ Noise ซึ่งต้องการการทบทวนข้อมูลระดับฟิสิกส์เพื่อใช้ในการเรียนรู้ของระบบ

5.2.4 จากการเปรียบเทียบผลของการตรวจรูปแบบกราฟหุ้นไทย ด้วยวิธีการเรียนรู้ของโมเดลที่ต่างกัน พบว่า โมเดลอัลกอริทึม InceptionV2 เหมาะกับข้อมูลภาพ RSI Line Chart เนื่องจากมีข้อมูลระดับฟิสิกส์จำนวนน้อย และมีลักษณะ Smooth ซึ่งต้องการการเพิ่มข้อมูลระดับฟิสิกส์เพื่อใช้ในการเรียนรู้ของระบบ

5.2.5 จากการเปรียบเทียบผลของการตรวจรูปแบบกราฟหุ้นไทย ด้วยวิธีการเรียนรู้ของโมเดลที่ต่างกัน พบว่า Loss Function แบบ Categorical Cross Entropy มีความแม่นยำมากกว่าแบบ Focal Loss เนื่องจากการตรวจหารูปแบบกราฟหุ้น Candlestick และ RSI มีลักษณะเป็น Multi-class classification

สามารถประยุกต์เป็นแนวทางสำหรับสอนระบบการเรียนรู้เชิงลึกของการตรวจหารูปแบบกราฟ 2 ลักษณะที่ต่างกัน อยู่แยกกัน แต่มีความสัมพันธ์กัน ณ ช่วงเวลาหนึ่ง บนจอคอมพิวเตอร์ที่แสดงรูปภาพกราฟ เช่น การตรวจวัดความผิดปกติบนรูปภาพกราฟคลื่นหัวใจ เป็นต้น

5.3. ข้อเสนอแนะ

1. การเพิ่มเทคนิคของการตรวจหาด้วยวิธีการอื่น อาจให้ความแม่นยำมีประสิทธิภาพยิ่งขึ้น เช่น กำหนดช่วงเวลาของรูปภาพกราฟหุ้นจาก 1 ปี เป็น 6 เดือน หรือ 3 เดือน เป็นต้น
2. การวิเคราะห์แยกตามประเภทของหลักทรัพย์ เช่น แบ่งกลุ่มหุ้นรายตัวตามหมวดอุตสาหกรรม เป็นต้น อาจให้ความแม่นยำของการตรวจหารูปแบบกราฟหุ้นมีประสิทธิภาพยิ่งขึ้น
3. การศึกษาในอนาคต อาจนำโมเดลพยากรณ์ไปประยุกต์ใช้กับตลาดแลกเปลี่ยนเงินตราระหว่างประเทศ (Foreign Exchange: FOREX) หรือ ตลาดซื้อขายสินทรัพย์ประเภทอื่น ที่มีรูปภาพกราฟของสินทรัพย์นั้นบนอินเทอร์เน็ต

DRP

บรรณานุกรม



บรรณานุกรม

- [1] Sreelekshmy Selvin, Vinayakumar R, Gopalakrishnan E.A, Vijay Krishna Menon, and Soman K.P, "Stock Price Prediction using LSTM, RNN and CNN-Sliding Window Model," *IEEE*, Sep. 2017.
- [2] Marc Velay and Fabrice Daniel, "Stock Chart Pattern recognition with Deep Learning," *arXiv:1808.00418*, June. 2018.
- [3] Shaoqing Ren, Kaiming He, Ross Girshick, and Jian Sun, "Faster R-CNN:Towards Real-Time Object Detection with Region Proposal Networks," *arXiv:1506.01497v3*, Jan. 2016.
- [4] Jake Bouvrie, "Notes on Convolutional Neural Networks," *jvb@mit.edu*, Nov. 2006.
- [5] Christian Szegedy, Vincent Vanhoucke, Sergey Ioffe, and Jonathon Shlens, "Rethink the Inception Architecture for Computer Vision," *arXiv:1512.00567v3*, Dec. 2015.
- [6] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun, "Deep Residual Learning for Image Recognition," *arXiv:1512.03385v1*, Dec. 2015.
- [7] Ross Girshick, Jeff Donahue, Trevor Darrell, and Jitendra Malik, "Rich feature hierarchies for accurate object detection and semantic segmentation," *arXiv:1311.2524v5*, Oct. 2014.
- [8] Ross Girshick, "Fast R-CNN," *arXiv:1504.08083v2*, Sep. 2015.
- [9] Zhilu Zhang and Mert R. Sabuncu, "Generalized Cross Entropy Loss for Training Deep Neural Networks with Noisy Labels," *arXiv:1805.07836v4*, Nov. 2018.
- [10] Tsung Yi Lin, Priya Goyal, Ross Girshick, KaimingHe, and Piotr Dollar, "Focal Loss for Dense Object Detection," *arXiv:1708.02002v2*, Feb. 2018.

- [11] Hamid Rezatofighi, Nathan Tsoi, Jun Young Gwak, Amir Sadeghian, Ian Reid, and Silvio Savarese, "Generalized Intersection over Union: A Metric and A Loss for Bounding Box Regression," *arXiv:1902.09630v2*, Apr. 2019.
- [12] Omer Berat Sezera and Ahmet Murat Ozbayoglu, "Algorithmic Financial Trading with Deep Convolutional Neural Networks: Time Series to Image Conversion Approach," *Applied Soft Computing*, vol. 70, pp. 525-538, Apr. 2018.
- [12] Jonatan Ward, Sergey Andreev, Francisco Heredia, Bogdan Lazar, Zlatka Manevska, "Efficient mapping of the training of Convolutional Neural Networks to a CUDA-based cluster," *www.parse.ele.tue.nl*, Apr. 2016.
- [13] Thomas Dean, Mark A. Ruzon, Mark Segal, Jonathon Shlens, Sudheendra Vijayanarasimhan, and Jay Yagnik, "Fast, Accurate Detection of 100,000 Object Classes on a Single Machine," *IEEE*, Oct. 2013.
- [14] Kevin Jarrett, Koray Kavukcuoglu, Marc'Aurelio Ranzato, and Yann LeCun, "What is the Best Multi-Stage Architecture for Object Recognition," *IEEE*, Sep. 2009.



ภาคผนวก

การตรวจหารูปแบบกราฟหุ้นด้วยการเรียนรู้เชิงลึก Stock Graph Pattern Detection Using Deep Learning

อภิสิทธิ์ รุ่งมานะกุล

Apsit Rungmanakul

สาขาวิศวกรรมข้อมูลขนาดใหญ่ / มหาวิทยาลัยบูรพาจันทบุรี

Big Data Engineering / Dhurakij Pundit University

กรุงเทพฯ / ประเทศไทย

Bangkok Thailand

605162020022@dpu.ac.th

ธนภัทร ผนังะจิตร์

Thanapat Kangkachit

สาขาวิศวกรรมข้อมูลขนาดใหญ่ / มหาวิทยาลัยบูรพาจันทบุรี

Big Data Engineering / Dhurakij Pundit University

กรุงเทพฯ / ประเทศไทย

Bangkok Thailand

605162020022@dpu.ac.th

บทคัดย่อ — การวิเคราะห์หุ้นด้วยปัจจัยด้านเทคนิคออกจากรูปแบบกราฟหุ้นได้ถูกพิสูจน์ว่าเป็นหนึ่งในเครื่องมือที่ดีที่สุดที่สามารถสร้างกำไรให้กับนักลงทุนจากตลาดหลักทรัพย์ได้ มีหลายงานวิจัยก่อนหน้านี้ได้นำเสนอวิธีการตรวจหารูปแบบกราฟหุ้นโดยใช้เทคนิคการเรียนรู้เชิงลึก แต่ยังมีขาดความแม่นยำในการตรวจจับ ในงานวิจัยนี้ได้ประยุกต์ใช้เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชันแบบสร้างหน้าฉากเพื่อรู้จำและระบุรายละเอียดระดับพิกเซล (Mask R-CNNs) ในการสร้างโมเดลสำหรับตรวจหารูปแบบกราฟหุ้นแบบกราฟแท่งเทียน (Candlestick) และโมเดลสำหรับตรวจหารูปแบบกราฟหุ้นแบบกราฟอาร์เอสไอ (RSI) นำมาพิจารณาหาช่วงเวลาที่เกิดรูปแบบกราฟหุ้นร่วมกันจากทั้งสองโมเดล โดยเลือกใช้รูปแบบกราฟหุ้นแบบบูลิชไดเวอร์เจน (Bullish Divergence) เนื่องจากมีศักยภาพสูงในการทำกำไรให้กับนักลงทุน ผลการทดลองบนกราฟหุ้นจากตลาดหลักทรัพย์แห่งประเทศไทยพบว่าวิธีการที่นำเสนอให้ผลการทำนายรูปแบบ mAP ที่แม่นยำกว่าวิธีการอื่น ซึ่งสามารถช่วยในการตัดสินใจของนักลงทุนด้วยปัจจัยด้านเทคนิคออกจากรูปแบบกราฟหุ้นได้อย่างมีประสิทธิภาพ

คำสำคัญ — การวิเคราะห์หุ้นด้วยปัจจัยด้านเทคนิคออกจากรูปแบบกราฟหุ้น, โครงข่ายประสาทเทียมแบบคอนโวลูชันแบบสร้างหน้าฉากเพื่อรู้จำและระบุรายละเอียดระดับพิกเซล, กราฟแท่งเทียน, กราฟเส้นอาร์เอสไอ, รูปแบบกราฟหุ้นแบบบูลิชไดเวอร์เจน

ABSTRACT — Technical analysis from stock chart pattern has been proven to be one of the efficient tools that assists investors to gain profits from stock market. Previously, several approaches have been proposed to detect stock chart patterns using deep learning techniques. However, the obtained accuracy needs to be improved. In this paper, we apply Mask R-CNNs technique to construct two models that separately extract patterns from Candlestick Chart (OHLCV) and RSI Line Chart. A Bullish Divergence pattern is chosen according to its high potential to gain profits. Experimental results on stock charts from Stock Exchange of Thailand (SET) data show that our approach yields better mAP among other approaches. This results in assisting investors to

make effective decisions by using technical analysis from stock chart patterns.

Keywords — Technical analysis from stock chart pattern, Mask R-CNNs, Candlestick Chart, RSI Line Chart, Bullish Divergence pattern.

1. บทนำ

การตรวจหารูปแบบกราฟหุ้น ได้ถูกออกแบบมาเพื่อสนับสนุนการวิเคราะห์หุ้นด้วยปัจจัยด้านเทคนิค และแก้ปัญหาของผู้อื่น อันเกิดจากความไม่ชัด ความเข้าใจอย่างผู้เชี่ยวชาญ ซึ่งการเข้าลงทุนหุ้นไทยในตลาดหลักทรัพย์แห่งประเทศไทย ณ ปัจจุบันนั้น ข้อมูลมีปริมาณมหาศาลและรวดเร็ว ขณะที่เวลาจำกัด อาจนำมาซึ่งความผิดพลาดของการตัดสินใจในการลงทุน โดยงานวิจัยนี้จะทำการตรวจจับรูปแบบกราฟหุ้นที่มีศักยภาพ เพื่อนำมาใช้ประกอบการลงทุนให้เกิดผลกำไรแก่นักลงทุน

จากงานวิจัยที่เกี่ยวกับการวิเคราะห์หุ้นด้วยปัจจัยด้านเทคนิคออกจากรูปภาพเท่านั้น [8] สร้างรูปภาพจากข้อมูล Indicator ย้อนหลังแล้วใช้ CNN-TA เพื่อทำนายผลตอบแทนที่ดีที่สุดจากการซื้อขายหุ้น ส่วนงานวิจัย [3] นำรูปภาพกราฟหุ้น มาใช้ 1D-CNNs, 2D-CNNs ทำนายรูปแบบกราฟหุ้น แต่ยังไม่สามารถตรวจหารูปแบบกราฟหุ้นได้อย่างแม่นยำเมื่อนำมาเปรียบเทียบกับการใช้ข้อมูล OHLCV ย้อนหลัง ซึ่งใช้สำหรับการทำนายผลตอบแทนจากการซื้อขายหุ้น


ข้อมูล OHLCV นั้นมีบทบาทสำคัญสำหรับการลงทุนของการเงินทุกรูปแบบ จึงสมควรอย่างยิ่งที่จะพัฒนาการเรียนรู้ของคอมพิวเตอร์ด้าน Image Processing ซึ่งเป็นทางเลือกที่ได้รับการพิสูจน์ยอมรับแล้ว ใช้ทำนายผลจากรูปภาพกราฟหุ้น เพื่อหารูปแบบกราฟหุ้นด้วยปัจจัยด้านเทคนิค แต่จะไม่มีข้อมูล OHLCV ย้อนหลังมาใช้ประกอบด้วยเลย

ด้วยเหตุดังกล่าว งานวิจัยฉบับนี้ จึงนำเสนอวิธีการตรวจหารูปแบบกราฟหุ้นด้วยการเรียนรู้เชิงลึก Mask R-CNNs ซึ่งสามารถตรวจหารูปแบบกราฟหุ้นจากรูปภาพกราฟหุ้นอย่างมีประสิทธิภาพ และช่วยสนับสนุนนักลงทุนในการตัดสินใจ

ประยุกต์ต่อยอดจาก [9] โดยงานวิจัยฉบับนี้จะมุ่งเน้นการตรวจจําแนกรูปแบบกราฟหุ้นด้วยเทคนิคใหม่ เพื่อเพิ่มความถูกต้องแม่นยำ

3. วิธีดำเนินการวิจัย

งานวิจัยชิ้นนี้นำเสนอเทคนิคการตรวจจําแนกรูปแบบกราฟหุ้นด้วยขั้นตอนโดยมีภาพรวมการทำงาน ดังรูปที่ 4.



รูปที่ 4. แสดงภาพรวมการทำงานของการตรวจจําแนกรูปแบบกราฟหุ้น

3.1. การเตรียมข้อมูล

รวบรวมรูปภาพกราฟหุ้นรายหุ้นจากตลาดหลักทรัพย์แห่งประเทศไทย ที่แสดง Candlestick Chart และ RSI Line Chart ปี 2017-2018 ดังรูปที่ 5.




รูปที่ 5. แสดงภาพตัวอย่างรูปภาพกราฟหุ้น Candlestick และ RSI แหล่งที่มา www.tradingview.com

3.2. การสร้าง Mask ข้อมูล สำหรับการเทรนโมเดล

แบ่งเป็น 3 กลยุทธ์ ในการระบุตำแหน่งเพื่อดำเนินการวิจัย

3.2.1. กลยุทธ์ที่ 1. ระบุตำแหน่งเป็นทรงสี่เหลี่ยม ครอบคลุมกราฟ Candlestick Chart และ RSI Line Chart เป็น 1 Label ร่วมกัน ตอน Train และ Validation ดังรูปที่ 6.




รูปที่ 6. แสดงภาพการสร้าง Mask กลยุทธ์ที่ 1.

3.2.2. กลยุทธ์ที่ 2. ระบุตำแหน่งเป็นตามลักษณะของกราฟแบบขีด โดย Candlestick Chart เป็น Label ที่ 1 และ RSI Line Chart เป็น Label ที่ 2 ร่วมกัน ตอน Train และ Validation ดังรูปที่ 7.




รูปที่ 7. แสดงภาพการสร้าง Mask กลยุทธ์ที่ 2.

3.2.3. กลยุทธ์ที่ 3. ระบุตำแหน่งเป็นตามลักษณะของกราฟแบบขีด โดย Candlestick Chart เป็น Label ที่ 1 และ RSI Line Chart เป็น Label ที่ 2 แยกกัน ตอน Train และ Validation ดังรูปที่ 8. และ รูปที่ 9



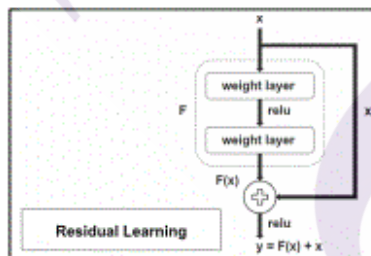
รูปที่ 8. แสดงภาพการสร้าง Mask กลยุทธ์ที่ 3.



รูปที่ 9. แสดงภาพการสร้าง Mask กลยุทธ์ที่ 3.

3.3. สร้างโมเดลด้วยเทคนิค Mask R-CNNs

ในงานวิจัยนี้ นำ ResNet มาใช้ มีลักษณะดึงค่า Features ที่สกัดมาใส่ในชั้นแรก มาคำนวณร่วมกับชั้นถัดไป ซึ่งจะเรียก Features ดังกล่าว Residues ดังรูปที่ 10.



รูปที่ 10. แสดงภาพ ResNet นำชั้นแรกมาคำนวณร่วมกับชั้นถัดไป

3.4. การวัดประสิทธิภาพในการทำนาย


โดย Weight ที่สร้างขึ้นจากรูปภาพที่ถูก Mask ทั้งรูปภาพ Train Data และรูปภาพ Validation Data ที่ประกอบด้วย Candlestick Chart และ RSI Line Chart จากการดำเนินการวิจัยทั้ง 3 รูปแบบนั้น มาทดสอบกับรูปภาพ Test Data แล้วจึงนำผลลัพธ์ที่ได้มาเทียบกับ Ground Truth จากรูปแบบของ SiamQuant Research ข้างต้น แล้ว

นำมาเปรียบเทียบกับค่า mAP (mean Average Precision) ดังรูปที่ 11. @ IoU (Intersection over Union) ดังรูปที่ 12.

$$\text{Precision} = \frac{TP}{TP + FP}$$

TP = True Positive
FP = False Positive

รูปที่ 11. แสดงภาพการคำนวณของค่า Precision



รูปที่ 12. แสดงภาพการคำนวณของค่า IoU

4. ผลการวิจัย

4.1. การตั้งค่าในการประมวลผลการวิจัย

นำรูปภาพกราฟหุ้นที่มี Bullish Divergence pattern จาก SET สุ่มจำนวนมา 43 หุ้น และ MAI สุ่มจำนวนมา 21 หุ้น เฉลี่ยจาก 8 อุตสาหกรรม ซึ่งแต่ละหุ้นจะมีค่า Free Float > 25% ขนาดของรูปภาพ jpg = Height x Width = 1080 x 1920 pixels และแสดง Candlestick Chart (1D)(close) 2yrs (log), RSI Line chart (14)(close) 2yrs (log) รวมทั้งหมด 84 รูป โดยแบ่งเป็น ข้อมูลสอนระบบ Train Data จำนวน 42 รูป (86%), ข้อมูล Validation จำนวน 7 รูป (10%), ข้อมูลทดสอบระบบ Test Data จำนวน 15 รูป (15%)

4.2. การเปรียบเทียบประสิทธิภาพ

จากการการสร้างหน้าฉากสำหรับข้อมูลในการเทรน Mask for Training Pictures ให้ผลลัพธ์ที่แตกต่างกัน

4.2.1. กลยุทธ์ที่ 1. ระบุตำแหน่งเป็นทรงสี่เหลี่ยม ครอบคลุมตัวกราฟ Candlestick Chart และ RSI Line Chart เป็น 1 Label ร่วมกัน ตอน Train และ Validation


พบการตรวจหารูปแบบกราฟหุ้นถูกต้องแบบคลุมเครือ ดังรูปที่ 13.

4.2.2. กลยุทธ์ที่ 2. ระบุตำแหน่งเป็นตามลักษณะของกราฟแบบขีด โดย Candlestick Chart เป็น Label ที่ 1 และ RSI Line Chart เป็น Label ที่ 2 ร่วมกัน ตอน Train และ Validation

พบความผิดพลาดจากการตรวจหารูปแบบกราฟหุ้น ดังรูปที่ 14.

4.2.3. กลยุทธ์ที่ 3. ระบุตำแหน่งเป็นตามลักษณะของกราฟแบบขีด โดย Candlestick Chart เป็น Label ที่ 1 และ RSI Line Chart เป็น Label ที่ 2 แยกกัน ตอน Train และ Validation


พบความแม่นยำจากการตรวจหารูปแบบกราฟหุ้นถูกต้องมากขึ้น
ดังรูปที่ 15.



รูปที่ 13. แสดงภาพผลลัพธ์จากการทดสอบกลยุทธ์ที่ 1. พบการตรวจหารูปแบบกราฟหุ้นถูกต้องแบบคลุมเครือ



รูปที่ 14. แสดงภาพผลลัพธ์จากการทดสอบกลยุทธ์ที่ 2. พบความผิดพลาดจากการตรวจหารูปแบบกราฟหุ้น



รูปที่ 15. แสดงภาพผลลัพธ์จากการทดสอบกลยุทธ์ที่ 3.

พบความแม่นยำจากการตรวจหารูปแบบกราฟหุ้นถูกต้องมากขึ้น

4.3 การทดลองของงานวิจัย

จากการทดลอง Mask ทั้ง 3 รูปแบบ ดังตารางที่ 1.

4.3.1. รูปแบบของการระบุตำแหน่งเป็นทรงสี่เหลี่ยม ครอบคลุมตัว Candlestick Chart และ RSI Line Chart เป็น 1 Label ร่วมกัน

เมื่อทดสอบกับ Test Data ปรากฏค่าการทำนาย @ IoU = 0.50 ค่า mAP = 0.85

4.3.2. รูปแบบของการระบุตำแหน่งตามลักษณะของกราฟแบบขีด Candlestick Chart เป็น Label ที่ 1 และ RSI Line Chart เป็น Label ที่ 2 ร่วมกัน

เมื่อทดสอบกับ Test Data ปรากฏค่าการทำนาย @ IoU = 0.50 ค่า mAP = 0.80

4.3.3. รูปแบบของการระบุตำแหน่งตามลักษณะของกราฟแบบขีด Candlestick Chart เป็น Label ที่ 1 และ RSI Line Chart เป็น Label ที่ 2 แยกกัน

เมื่อทดสอบกับ Test Data ปรากฏค่าการทำนาย @ IoU = 0.50 ค่า mAP = 0.90

	mAP @ IoU = 0.50
Strategy 1 : Candlestick with RSI Line Chart = 1 Label	0.85
Strategy 2 : Candlestick with RSI Line Chart = 2 Label	0.80
Strategy 3 : Candlestick and RSI Line Chart = 2 Labels	0.90

ตารางที่ 1. แสดงตารางเปรียบเทียบค่า mAP @ IoU = 0.50

4.4 ผลการทดลองของงานวิจัย

เมื่อนำข้อมูลทดสอบระบบ ตรวจหารูปแบบกราฟหุ้น Bullish Divergence พบว่า กลยุทธ์ที่ 3. มีความแม่นยำจากการตรวจหา รูปแบบกราฟหุ้นถูกต้องมากขึ้น เมื่อเปรียบเทียบกับ กลยุทธ์ที่ 1. และ กลยุทธ์ที่ 2. เนื่องจาก Mask R-CNNs สามารถทำงานได้อย่างมีประสิทธิภาพยิ่งขึ้น เมื่อทำการ Mask กราฟแบบขีด รวมทั้งแยกโมเดล การเรียนรู้ระหว่าง กราฟแท่งเทียน และ กราฟอาร์เอสไอ ออกจากกัน

5. สรุปและอภิปรายผล

งานวิจัยนี้ นำเสนอการตรวจหารูปแบบกราฟหุ้น แบบ Bullish Divergence จากรูปภาพกราฟหุ้นที่แสดง Candlestick Chart และ RSI Line Chart ในลักษณะ Daily Timeframe ของรูปภาพกราฟหุ้น รายตัว ใน SET บนจอมอนิเตอร์ที่แสดงผ่านอินเทอร์เน็ตเท่านั้น ซึ่ง งานวิจัยฉบับนี้ได้ประยุกต์ Mask R-CNNs เพื่อใช้การสกัดลักษณะเด่น

ของรูปแบบกราฟหุ้น จากรูปภาพกราฟหุ้น รวมถึงออกแบบโครงข่าย และกำหนดพารามิเตอร์อย่างเหมาะสมเท่าที่จำเป็น อีกทั้งลักษณะวิธีการ Mask ที่คิดไปกับรูปแบบกราฟหุ้น ประกอบกับกลยุทธ์แยกโมเดล Weight ระหว่าง Candlestick Chart กับ RSI Line Chart พบว่า ไลน์ทำนายที่ดีที่สุดด้วยการวัดค่า mAP = 0.90 @ IoU = 0.50

ในอนาคตเป็นไปได้ที่จะพัฒนารูปแบบกราฟหุ้นอื่นใน SET เพื่อเพิ่มประสิทธิภาพของการตรวจหารูปแบบกราฟหุ้น เช่น Bearish Divergence เป็นต้น

เอกสารอ้างอิง

- [1] Kaiming He, Georgia Gkioxari, Piotr Dollar and Ross Girshick, "Mask R-CNN," arXiv:1703.06870v3, Jan. 2018.
- [2] Omer Berat Sezera and Ahmet Murat Ozbayoglu, "Algorithmic Financial Trading with Deep Convolutional Neural Networks: Time Series to Image Conversion Approach," Applied Soft Computing, vol. 70, pp. 525-538, Apr. 2018.
- [3] Marc Velay and Fabrice Daniel, "Stock Chart Pattern recognition with Deep Learning," arXiv:1808.00418, June. 2018.
- [4] Jiagong Zhang, Jingyao Zhan and Yunhan Ma, "Mask R-CNN," https://cseweb.ucsd.edu/classes/sp18/cse252C-a/CSE252C_20180609.pdf, May, 2018.
- [5] Jonathan Hul, "mAP (mean Average Precision) for Object Detection," https://medium.com/@jonathan_hul/map-mean-average-precision-for-object-detection-45c121a31173, Mar. 2018.
- [6] Sreelekshmy Selvin, Vinayakumar R, Gopalakrishnan E.A, Vijay Krishna Menon and Soman K.P, "Stock Price Prediction using LSTM, RNN and CNN-Sliding Window Model," IEEE, Sep. 2017.
- [7] Jonatan Ward, Sergey Andreev, Francisco Heredia, Bogdan Lazar, Zlatica Manevska, "Efficient mapping of the training of Convolutional Neural Networks to a CUDA-based cluster," <http://parse.ele.tue.nl/education/cluster2>, Apr. 2016.
- [8] Adrian Rosebrock, "Intersection over Union (IoU) for object detection," <https://www.pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection/>, Nov. 2016.
- [9] Kaiming He, Xiangyu Zhang, Shaoqing Ren and Jian Sun, "Deep Residual Learning for Image Recognition," arXiv:1512.03385v1, Dec. 2015.
- [10] Thomas Dean, Mark A. Ruzon, Mark Segal, Jonathon Shlens, Sudheendra Vijayanarasimhan and Jay Yagnik, "Fast, Accurate Detection of 100,000 Object Classes on a Single Machine," IEEE, Oct. 2013.
- [11] Kevin Jarrett, Koray Kavukcuoglu, Marc'Aurelio Ranzato and Yann LeCun, "What is the Best Multi-Stage Architecture for Object Recognition?," IEEE, Sep. 2009.

ประวัติผู้เขียน

ชื่อ นามสกุล

อภิสิทธิ์ รุ่งมานะกุล

ประวัติการศึกษา

พ.ศ. 2542 - 2546 ปริญญาตรี

สถาปัตยกรรมศาสตรบัณฑิต (สถ.บ.)

สาขาสถาปัตยกรรม

คณะสถาปัตยกรรมศาสตร์

จุฬาลงกรณ์มหาวิทยาลัย

ตำแหน่งและสถานที่ทำงานปัจจุบัน

สถาปนิก

THE CIRCLE STUDIO

