

การคาดการณ์ทิศทางราคาทองคำจากความรู้สึกของข้อความบนทวิตเตอร์
โดยใช้เทคนิคการเรียนรู้ด้วยเครื่อง



สารนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต
สาขาวิชาเทคโนโลยีสารสนเทศทางธุรกิจ
คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย
ปีการศึกษา 2565
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

PREDICTABILITY OF GOLD PRICE TRENDS BASED ON TWEET SENTIMENTS
USING MACHINE LEARNING TECHNIQUES



An Independent Study Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Science in Information Technology in Business

FACULTY OF COMMERCE AND ACCOUNTANCY

Chulalongkorn University

Academic Year 2022

Copyright of Chulalongkorn University

หัวข้อสารนิพนธ์

การคาดการณ์ทิศทางราคาทองคำจากความรู้สึกรอง
ข้อความบนทวิตเตอร์ โดยใช้เทคนิคการเรียนรู้ด้วยเครื่อง

โดย

นายสกันต์ ลีศรีสกุลวงศ์

สาขาวิชา

เทคโนโลยีสารสนเทศทางธุรกิจ

อาจารย์ที่ปรึกษาหลัก

ผู้ช่วยศาสตราจารย์ ดร.นราพงศ์ ศรีวิศาล

คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้รับสารนิพนธ์ฉบับนี้เป็น
ส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

คณะกรรมการสอบสารนิพนธ์

..... ประธานกรรมการ
(รองศาสตราจารย์ ดร.จันทร์เจ้า มงคลนาวัน)

..... อาจารย์ที่ปรึกษาหลัก
(ผู้ช่วยศาสตราจารย์ ดร.นราพงศ์ ศรีวิศาล)

..... กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.ภูริพันธุ์ รุจิขจร)

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สกันต์ ลิ้มศรีสกุลวงศ์ : การคาดการณ์ทิศทางราคาทองคำจากความรู้สึกของข้อความบน
ทวิตเตอร์ โดยใช้เทคนิคการเรียนรู้ด้วยเครื่อง. (PREDICTABILITY OF GOLD PRICE
TRENDS BASED ON TWEET SENTIMENTS USING MACHINE LEARNING
TECHNIQUES) อ.ที่ปรึกษาหลัก : ผศ. ดร.นราพงศ์ ศรีวิศาล

การศึกษานี้นำเสนอการนำข้อมูลที่เป็นรูปแบบข้อความจากทวิตเตอร์ โดยเก็บรายวัน
ตั้งแต่เดือนมกราคม ปี 2017 ถึง เดือนธันวาคม ปี 2022 ซึ่งข้อความทั้งหมดมาจากการทวิตของ
ผู้เชี่ยวชาญด้านการลงทุนทองคำจำนวน 10 ท่าน ข้อความทั้งหมดหลังกระบวนการประมวลผล
ภาษาธรรมชาติจะถูกนำเข้าฝึกฝนด้วยโมเดลการเรียนรู้ด้วยเครื่องได้แก่ ต้นไม้ตัดสินใจ นาอูฟ เบย์
การถดถอยโลจิสติก เครื่องเวกเตอร์ค้ำยัน เพื่อวิเคราะห์หาโมเดลที่เหมาะสมที่สุดสำหรับการ
คาดการณ์ทิศทางราคาทองคำรายวันและรายสัปดาห์ นอกจากนี้ข้อความทั้งหมดสามารถนำมา
คำนวณค่าความรู้สึกและนำไปใช้ร่วมกับตัวแปรคาดการณ์ต่าง ๆ เช่น ดัชนีเงินดอลลาร์สหรัฐ ดัชนี
ความผันผวนทองคำ อัตราดอกเบี้ยระหว่างธนาคารของสหรัฐฯ ดัชนี SPDR® Gold Shares
(GLD) ดัชนี SPDR S&P 500 ETF Trust (SPY) และอัตราผลตอบแทนพันธบัตรรัฐบาล
สหรัฐอเมริกา 10 ปี เพื่อใช้คาดการณ์ทิศทางราคาทองคำด้วยเทคนิคการเรียนรู้ด้วยเครื่องได้อย่าง
มีประสิทธิภาพและเป็นประโยชน์ต่อนักลงทุนทองคำ

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สาขาวิชา เทคโนโลยีสารสนเทศทางธุรกิจ ลายมือชื่อนิสิต

ปีการศึกษา 2565 ลายมือชื่อ อ.ที่ปรึกษาหลัก

6382181226 : MAJOR INFORMATION TECHNOLOGY IN BUSINESS

KEYWORD: NLP, machine learning, sentiment, Twitter, gold trend

Skant Limsrisakulwong : PREDICTABILITY OF GOLD PRICE TRENDS BASED ON
TWEET SENTIMENTS USING MACHINE LEARNING TECHNIQUES. Advisor: Asst.
Prof. Dr. Narapong Srivisal

This study presents the information obtained from Twitter by scraping since January 2017 to December 2022. The data collection is from the 10 Twitter's users who are expert in gold investment. After textual data are proceeded by natural language processing (NLP), they are trained by machine learning models, including Decision Trees, Naive Bayes, Logistic Regression, Support Vector Machine to analyze the most optimal models for predicting daily and weekly gold price trends. Moreover all textual data are computed and converted into sentiment scores (positive, negative and neutral) and used with predictor variables such as dollar index, gold volatility index, effective federal fund rate, SPDR® Gold Shares (GLD), SPDR S&P 500 ETF Trust (SPY) and United States 10-Year Bond Yield (TNX) for predictability of gold price trends by machine learning techniques effectively and benefiting to gold investors.

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

Field of Study: Information Technology in Business Student's Signature

Academic Year: 2022 Advisor's Signature

กิตติกรรมประกาศ

การจัดทำโครงการการคาดการณ์ทิศทางราคาทองคำจากความรู้สึกของข้อความบนทวิตเตอร์ โดยใช้เทคนิคการเรียนรู้ด้วยเครื่อง สามารถสำเร็จจุล่งไปได้ด้วยดี ทั้งนี้ได้รับความช่วยเหลือจาก บุคคลากรต่าง ๆ หลายท่าน

ขอขอบพระคุณผู้ช่วยศาสตราจารย์ ดร.นราพงศ์ ศรีวิศาล ที่เปิดโอกาสและให้คำปรึกษาตลอด ระยะเวลาการทำโครงการพิเศษ

ขอขอบพระคุณ รองศาสตราจารย์ ดร.จันทร์เจ้า มงคลนาวิน และผู้ช่วยศาสตราจารย์ ดร.ภุรี พันธุ์ รุจิขจร ที่กรุณาสละเวลาอันมีค่ามาเป็นกรรมการสอบ และช่วยให้คำแนะนำเพื่อปรับปรุงแก้ไข การศึกษาในครั้งนี้

ขอขอบพระคุณบิดาและมารดาผู้ที่เข้าใจ สนับสนุน และให้กำลังใจมาโดยตลอด

ขอขอบคุณนายอานนท์ ศิลาพันธ์ และนายอภิชาติ ฉัตรเรืองเลิศ รวมถึงเพื่อน ๆ หลักสูตร IT EXEC รุ่นที่ 29 ที่ให้ความช่วยเหลือในทุก ๆ เรื่อง

ท้ายที่สุดนี้ขอขอบคุณสำหรับบุคคลที่ไม่ได้กล่าวถึงไว้ ณ ที่นี้ ที่มีน้ำใจต่อกันเสมอมา

สกันต์ ลีมีศรีสกุลวงศ์

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สารบัญ

| | หน้า |
|---|------|
| บทคัดย่อภาษาไทย..... | ค |
| บทคัดย่อภาษาอังกฤษ..... | ง |
| กิตติกรรมประกาศ..... | จ |
| สารบัญ..... | ฉ |
| บทที่ 1 ความสำคัญของปัญหา..... | 1 |
| 1.1 ความเป็นมาและความสำคัญของปัญหา..... | 1 |
| 1.2 วัตถุประสงค์ และคำถามงานวิจัย..... | 6 |
| 1.3 แนวทางเบื้องต้นในการตอบวัตถุประสงค์หรือคำถามงานวิจัย..... | 7 |
| 1.4 นิยามของคำศัพท์..... | 8 |
| 1.5 ขอบเขตของงานวิจัย..... | 9 |
| 1.6 ข้อจำกัดของงานวิจัย..... | 10 |
| 1.7 ระยะเวลาในการดำเนินโครงการ..... | 11 |
| 1.8 ประโยชน์ที่คาดว่าจะได้รับ..... | 11 |
| บทที่ 2 วรรณกรรมที่เกี่ยวข้อง..... | 12 |
| 2.1 บทนำ..... | 12 |
| 2.2 การลงทุนทองคำและปัจจัยที่มีผลกระทบต่อราคาทองคำ..... | 12 |
| 2.3 เทคนิคการวิเคราะห์ข้อมูล (Data Analysis Techniques)..... | 21 |
| 2.4 การประมวลผลภาษาธรรมชาติ (Natural Language Processing, NLP)..... | 31 |
| 2.5 การวัดประสิทธิภาพโมเดล (Model Evaluation)..... | 36 |
| 2.6 ความรู้สึกของการแพร่กระจายของข้อมูลในสื่อสังคมออนไลน์..... | 38 |
| 2.7 บทบาทของสื่อสังคมออนไลน์ในตลาดการเงินและการลงทุน..... | 39 |

| | |
|--|----|
| 2.8 เทคนิคการคำนวณค่าความรู้สึก (Sentiment Scoring Techniques) | 43 |
| 2.9 สรุปบททวนวรรณกรรม | 45 |
| บทที่ 3 ระเบียบการวิจัย | 46 |
| 3.1 การเก็บข้อมูล | 46 |
| 3.2 ขั้นตอนกระบวนการดำเนินงานในงานวิจัย..... | 47 |
| 3.3 เครื่องมือและเทคนิคที่ใช้สร้างโมเดลและวิเคราะห์ข้อมูล..... | 56 |
| 3.4 ตัววัดประสิทธิภาพของโมเดล | 57 |
| บทที่ 4 ผลการวิเคราะห์..... | 59 |
| 4.1 ผลการวิเคราะห์ภาพรวม..... | 59 |
| 4.2 ผลการวิเคราะห์ส่วนที่ 1 | 71 |
| 4.3 ผลการวิเคราะห์ส่วนที่ 2 กรณีที่ 1 | 73 |
| 4.4 ผลการวิเคราะห์ส่วนที่ 2 กรณีที่ 2 | 75 |
| 4.5 ผลการวิเคราะห์ส่วนที่ 2 กรณีที่ 3 | 77 |
| 4.6 วิจารณ์ผลการวิเคราะห์..... | 83 |
| บทที่ 5 สรุป อภิปรายผล และข้อเสนอแนะ | 89 |
| 5.1 ข้อสรุป..... | 89 |
| 5.2 ปัญหา และอุปสรรค..... | 90 |
| 5.3 ข้อเสนอแนะ..... | 91 |
| บรรณานุกรม..... | 92 |
| ประวัติผู้เขียน | 97 |

สารบัญตาราง

| | |
|---|----|
| ตารางที่ 1: ชื่อย่อ ชื่อเต็ม ประเภทหลักศัพท์ ที่ถูกเลือกนำมาเปรียบเทียบผลตอบแทน..... | 3 |
| ตารางที่ 2: ระยะเวลาที่ใช้ในการทำวิจัย..... | 11 |
| ตารางที่ 3: เปรียบเทียบผลกระทบต่อทองคำด้านบวกและด้านลบ..... | 21 |
| ตารางที่ 4: ตัวอย่างประโยคหลังทำ Tokenization | 32 |
| ตารางที่ 5: ตัวอย่างคำเปรียบเทียบข้อแตกต่างระหว่าง Stemming และ Lemmatization..... | 33 |
| ตารางที่ 6: ตาราง Confusion Matrix..... | 37 |
| ตารางที่ 7: รายชื่อผู้เชี่ยวชาญด้านการลงทุนทองคำในทวิตเตอร์ 10 ท่าน..... | 46 |
| ตารางที่ 8: พีเจอร์ของข้อมูลนำเข้าที่พร้อมนำไปใช้ (ส่วนที่ 1)..... | 52 |
| ตารางที่ 9: พีเจอร์ของข้อมูลนำเข้าที่พร้อมนำไปใช้ (ส่วนที่ 2)..... | 55 |
| ตารางที่ 10: ค่าวัดสถิติของเปอร์เซ็นต์การเปลี่ยนแปลงราคาทองคำรายวันและรายสัปดาห์..... | 61 |
| ตารางที่ 11: ค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างเปอร์เซ็นต์การเปลี่ยนแปลงราคาทองคำรายวันกับตัวแปรคาดการณ์ราคาทองคำ | 61 |
| ตารางที่ 12: อธิบายค่าความรู้สึกด้วยค่าวัดสถิติ จากข้อความทวิตทั้งหมด 47,317 ข้อความ..... | 66 |
| ตารางที่ 13: อธิบายค่าความรู้สึกที่คำนวณเฉลี่ยตามรายวันและรายสัปดาห์ | 68 |
| ตารางที่ 14: เปรียบเทียบค่าความถูกต้องของแต่ละโมเดลของการวิเคราะห์ส่วนที่ 1 | 71 |
| ตารางที่ 15: Confusion matrix ของผลการวิเคราะห์ส่วนที่ 1 โดยพิจารณารายวัน | 72 |
| ตารางที่ 16: Confusion matrix ของผลการวิเคราะห์ส่วนที่ 1 โดยพิจารณารายสัปดาห์ | 72 |
| ตารางที่ 17: เปรียบเทียบค่าความถูกต้องของแต่ละโมเดลของการวิเคราะห์ส่วนที่ 2 กรณีที่ 1 | 73 |
| ตารางที่ 18: Confusion matrix ของผลการวิเคราะห์ส่วนที่ 2 กรณีที่ 1 โดยพิจารณารายวัน | 74 |
| ตารางที่ 19: Confusion matrix ของผลการวิเคราะห์ส่วนที่ 2 กรณีที่ 1 โดยพิจารณารายสัปดาห์ | 74 |
| ตารางที่ 20: เปรียบเทียบค่าความถูกต้องของแต่ละโมเดลของการวิเคราะห์ส่วนที่ 2 กรณีที่ 2 | 75 |
| ตารางที่ 21: Confusion matrix ของผลการวิเคราะห์ส่วนที่ 2 กรณีที่ 2 โดยพิจารณารายวัน | 76 |

ตารางที่ 22: Confusion matrix ของผลการวิเคราะห์ส่วนที่ 2 กรณีที่ 2 โดยพิจารณารายสัปดาห์ 76

ตารางที่ 23: เปรียบเทียบค่าความถูกต้องของแต่ละโมเดลของการวิเคราะห์ส่วนที่ 2 กรณีที่ 3 77

ตารางที่ 24: Confusion matrix ของผลการวิเคราะห์ส่วนที่ 2 กรณีที่ 3 โดยพิจารณารายวัน 78

ตารางที่ 25: Confusion matrix ของผลการวิเคราะห์ส่วนที่ 2 กรณีที่ 3 โดยพิจารณารายสัปดาห์ 78

ตารางที่ 26: เปรียบเทียบค่า Precision Recall และ F1-Score ของการวิเคราะห์ส่วนที่ 1 80

ตารางที่ 27: เปรียบเทียบค่า Precision Recall และ F1-Score ของการวิเคราะห์ส่วนที่ 2 กรณีที่ 1
..... 81

ตารางที่ 28: เปรียบเทียบค่า Precision Recall และ F1-Score ของการวิเคราะห์ส่วนที่ 2 กรณีที่ 2
และ กรณีที่ 3 82

ตารางที่ 29: ค่าความสำคัญของพีเจอรืในข้อมูลการวิเคราะห์ส่วนที่ 2 กรณีที่ 1 ด้วยโมเดลการ
ถดถอยโลจิสติก 83

ตารางที่ 30: ค่าความสำคัญของพีเจอรืในข้อมูลการวิเคราะห์ส่วนที่ 2 กรณีที่ 1 ด้วยโมเดลต้นไม้
ตัดสินใจ 85

ตารางที่ 31: ค่าความสำคัญของพีเจอรืในข้อมูลการวิเคราะห์ส่วนที่ 2 กรณีที่ 3 ด้วยโมเดลต้นไม้
ตัดสินใจ 87

สารบัญรูปภาพ

| | |
|--|----|
| รูปที่ 1: ผังแสดงตำแหน่งความเสี่ยงและผลตอบแทนของผลิตภัณฑ์การลงทุนแต่ละประเภท | 2 |
| รูปที่ 2: เปรียบเทียบความสามารถการให้ผลตอบแทนสินทรัพย์ทางการเงินประเภทต่าง ๆ ตั้งแต่ปี 2002 ถึง 2022 | 3 |
| รูปที่ 3: เปรียบเทียบความผันผวนของทองคำกับสินทรัพย์อื่นๆ ในระยะเวลา 1 ปี ตั้งแต่ปี 2003 ถึง 2022..... | 4 |
| รูปที่ 4: เปรียบเทียบความผันผวนของทองคำกับสินทรัพย์อื่นๆ ในระยะเวลา 5 ปี ตั้งแต่ปี 2007 ถึง 2022..... | 4 |
| รูปที่ 5: ความสัมพันธ์ระหว่างสกุลเงิน Lira (TRY) กับกระแข่าวและสื่อสังคมออนไลน์ ตั้งแต่ ตุลาคม 2013 ถึง เมษายน 2014..... | 6 |
| รูปที่ 6: ความสัมพันธ์ระหว่างราคาทองคำกับค่าเงินดอลลาร์ ตั้งแต่ปี 2008 ถึง 2022..... | 15 |
| รูปที่ 7: ความสัมพันธ์ระหว่างอัตราดอกเบี้ยระหว่างธนาคารสหรัฐฯ และราคาทองคำตั้งแต่ปี 1971 ถึง 2021 | 15 |
| รูปที่ 8: เปรียบเทียบราคาทองคำและอัตราผลตอบแทนจากตัวเงินคลังของสหรัฐฯประเภท 3 เดือน | 16 |
| รูปที่ 9: ความสัมพันธ์ระหว่างราคาทองคำกับความผันผวนของทองคำรายวัน ตั้งแต่ กันยายน 2018 ถึง สิงหาคม 2019..... | 17 |
| รูปที่ 10: Treemap แสดงการถือครองทองคำของธนาคารกลางของแต่ละประเทศ | 18 |
| รูปที่ 11: ปริมาณอุปสงค์ของทองคำในแต่ละอุตสาหกรรมตั้งแต่ปี 2010 ถึง 2022 | 19 |
| รูปที่ 12: ความสัมพันธ์ระหว่างราคาทองคำและจำนวนหุ้นที่กองทุน SPDR Gold Share ถือครอง ช่วงเวลาตั้งแต่ ธันวาคม 2019 ถึง พฤศจิกายน 2020 | 20 |
| รูปที่ 13: ขอบเขตศาสตร์ความรู้ของ Machine Learning | 22 |
| รูปที่ 14: ข้อแตกต่างของแนวคิดและกระบวนการระหว่างโปรแกรมกับการเรียนรู้ของเครื่อง ... | 23 |
| รูปที่ 15: ตัวอย่างโครงสร้างต้นไม้ตัดสินใจ | 25 |

| | |
|--|----|
| รูปที่ 16: ตัวอย่าง Decision Trees ทำการแบ่ง Internal Node เพื่อให้ได้ Leaf Node..... | 25 |
| รูปที่ 17: ตัวอย่าง Logistic Sigmoid Function | 29 |
| รูปที่ 18: SVM Classification ของข้อมูลใดๆ 2 Class..... | 30 |
| รูปที่ 19: ตัวอย่างการทำ CountVectorizer และ Text encoding คำศัพท์ในเอกสารจากข้อความ ตัวอย่าง..... | 35 |
| รูปที่ 20: ตัวอย่างการทำ TF-IDF คำศัพท์ในเอกสารจากข้อความตัวอย่าง | 36 |
| รูปที่ 21: ภาพรวมเทคนิคการคำนวณค่าความรู้สึก..... | 43 |
| รูปที่ 22: ขั้นตอนกระบวนการดำเนินงานในการวิจัยส่วนที่ 1 | 47 |
| รูปที่ 23: ตัวอย่างขั้นตอนการดึงข้อมูลจากทวิตเตอร์..... | 48 |
| รูปที่ 24: ตัวอย่างขั้นตอนการเตรียมข้อมูลรูปแบบข้อความ (Text preprocessing)..... | 48 |
| รูปที่ 25: คำ Stop word ทั้งหมดที่มาจาก ENGLISH_STOP_WORDS ของ Scikit Learn..... | 49 |
| รูปที่ 26: ตัวอย่างการทำ Tokenize ข้อความ (1)..... | 50 |
| รูปที่ 27: ตัวอย่างการทำ Tokenize ข้อความ (2)..... | 50 |
| รูปที่ 28: ตัวอย่างการทำ Stemming ชุดข้อความตัวอย่าง | 51 |
| รูปที่ 29: ตัวอย่างการทำ Lemmatization ชุดข้อความตัวอย่าง | 51 |
| รูปที่ 30: ตัวอย่างการเลื่อน Target value ขึ้น 1 แถว..... | 52 |
| รูปที่ 31: ตัวอย่างชุดข้อมูลที่พร้อมนำไปใช้..... | 53 |
| รูปที่ 32: ตัวอย่างผลการทำ Tokenize ชุดข้อมูลที่พร้อมนำไปใช้ | 53 |
| รูปที่ 33: ภาพรวมขั้นตอนกระบวนการดำเนินงานในงานวิจัยส่วนที่ 2 | 54 |
| รูปที่ 34: ตัวอย่างข้อความภาษาอังกฤษจากทวิตเตอร์ที่นำมาทำ Sentiment | 54 |
| รูปที่ 35: จำนวนข้อความจากทวิตเตอร์ของผู้เชี่ยวชาญด้านการลงทุนทองคำ 10 ท่านระหว่าง มกราคม 2560 ถึง ธันวาคม 2565 | 59 |
| รูปที่ 36: การแจกแจงของเปอร์เซ็นต์การเปลี่ยนแปลงราคาทองคำรายวันระหว่าง มกราคม 2560 ถึง ธันวาคม 2565 | 60 |

| | |
|---|----|
| รูปที่ 37: เปรียบเทียบการแจกแจงระหว่างเปอร์เซ็นต์การเปลี่ยนแปลงราคาทองคำรายวันและรายสัปดาห์..... | 60 |
| รูปที่ 38: เปรียบเทียบจำนวน Target value ระหว่างการเปลี่ยนแปลงราคาทองคำรายวันและรายสัปดาห์..... | 61 |
| รูปที่ 39: เมทริกซ์สหสัมพันธ์ของเปอร์เซ็นต์การเปลี่ยนแปลงราคาทองคำรายวันกับตัวแปรคาดการณ์..... | 62 |
| รูปที่ 40: ความสัมพันธ์ระหว่างเปอร์เซ็นต์การเปลี่ยนแปลงราคาทองคำกับดัชนีเงินดอลลาร์สหรัฐฯ | 63 |
| รูปที่ 41: ความสัมพันธ์ระหว่างเปอร์เซ็นต์การเปลี่ยนแปลงราคาทองคำกับดัชนีความผันผวนทองคำ..... | 63 |
| รูปที่ 42: ความสัมพันธ์ระหว่างเปอร์เซ็นต์การเปลี่ยนแปลงราคาทองคำกับอัตราดอกเบี้ยระหว่างธนาคารของสหรัฐฯ..... | 64 |
| รูปที่ 43: ความสัมพันธ์ระหว่างเปอร์เซ็นต์การเปลี่ยนแปลงราคาทองคำกับดัชนี SPDR® Gold Shares (GLD)..... | 64 |
| รูปที่ 44: ความสัมพันธ์ระหว่างเปอร์เซ็นต์การเปลี่ยนแปลงราคาทองคำกับดัชนี SPDR S&P 500 ETF Trust (SPY)..... | 65 |
| รูปที่ 45: ความสัมพันธ์ระหว่างเปอร์เซ็นต์การเปลี่ยนแปลงราคาทองคำกับอัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐอเมริกา 10 ปี..... | 65 |
| รูปที่ 46: เปรียบเทียบการแจกแจงของค่าความรู้สึกจากข้อความทวีตทั้งหมด 47,317 ข้อความ..... | 66 |
| รูปที่ 47: แบ่งประเภทของค่าความรู้สึกจากข้อความทวีตทั้งหมด 47,317 ข้อความ..... | 67 |
| รูปที่ 48: เปรียบเทียบการแจกแจงของค่าความรู้สึกเฉลี่ยตามวันทั้งหมด 1,562 วัน..... | 67 |
| รูปที่ 49: เปรียบเทียบการแจกแจงของค่าความรู้สึกเฉลี่ยตามสัปดาห์ ทั้งหมด 313 สัปดาห์..... | 68 |
| รูปที่ 50: ตัวอย่างข้อมูลนำเข้าของการวิเคราะห์ส่วนที่ 2 กรณีที่ 1 (1.1)..... | 69 |
| รูปที่ 51: ตัวอย่างข้อมูลนำเข้าของการวิเคราะห์ส่วนที่ 2 กรณีที่ 1 (1.2)..... | 70 |
| รูปที่ 52: เปรียบเทียบค่าความถูกต้องของแต่ละโมเดลของการวิเคราะห์ส่วนที่ 1..... | 71 |
| รูปที่ 53: เปรียบเทียบค่าความถูกต้องของแต่ละโมเดลของการวิเคราะห์ส่วนที่ 2 กรณีที่ 1..... | 73 |
| รูปที่ 54: เปรียบเทียบค่าความถูกต้องของแต่ละโมเดลของการวิเคราะห์ส่วนที่ 2 กรณีที่ 2..... | 75 |

| | |
|---|-----|
| รูปที่ 55: เปรียบเทียบค่าความถูกต้องของแต่ละโมเดลของการวิเคราะห์ส่วนที่ 2 กรณีที่ 3..... | 77 |
| รูปที่ 56: เปรียบเทียบค่าความถูกต้องของแต่ละโมเดลของการวิเคราะห์ส่วนที่ 2 กรณีที่ 2 และ 3. | 79 |
| รูปที่ 57: เปรียบเทียบค่าความสำคัญของพีเจอรินในข้อมูลการวิเคราะห์ส่วนที่ 2 กรณีที่ 1 ด้วยโมเดลการถดถอยโลจิสติก..... | 84 |
| รูปที่ 58: เปรียบเทียบค่าความสำคัญของพีเจอรินในข้อมูลการวิเคราะห์ส่วนที่ 2 กรณีที่ 1 ด้วยโมเดลต้นไม้ตัดสินใจ..... | 85 |
| รูปที่ 59: ตัวอย่างบางส่วนของโมเดลต้นไม้ตัดสินใจสำหรับในข้อมูลการวิเคราะห์ส่วนที่ 2 กรณีที่ 1 | 186 |
| รูปที่ 60: เปรียบเทียบค่าความสำคัญของพีเจอรินในข้อมูลการวิเคราะห์ส่วนที่ 2 กรณีที่ 3 ด้วยโมเดลต้นไม้ตัดสินใจ..... | 88 |




บทที่ 1

ความสำคัญของปัญหา

1.1 ความเป็นมาและความสำคัญของปัญหา

ในอดีตมนุษย์เราใช้ทองคำเป็นสื่อกลางในการแลกเปลี่ยน ก่อนการพัฒนาเปลี่ยนแปลงอย่างต่อเนื่องมาถึงปี 1900 ที่ทั่วโลกยอมรับการใช้ระบบอัตราแลกเปลี่ยนอ้างอิงค่าเงินกับน้ำหนักทองคำ และมีทองคำเป็นทุนสำรองทั้งหมด เรียกว่าระบบมาตรฐานทองคำ (Gold Standard) ก่อนจะมีการยกเลิกไปหลังสงครามโลกครั้งที่ 2 และพัฒนาสู่ยุค Bretton Wood ที่ประเทศต่าง ๆ มีเงินทุนสำรองเป็นดอลลาร์สหรัฐ ที่ผูกกับมูลค่าทองคำไว้ที่ 35 ดอลลาร์สหรัฐ ต่อทองคำ 1 ออนซ์ (Ounce) หลังจากนั้นเข้าสู่ยุคที่หลายประเทศทั่วโลกมีทองคำเป็นทุนสำรองระหว่างประเทศ จึงเป็นสิ่งพิสูจน์ว่าทองคำเป็นสินทรัพย์ปลอดภัยที่หลายประเทศให้การยอมรับมาจนถึงปัจจุบัน (มนัสวี เต็ดอนันต์กุล, 2565)


ปัจจุบันการซื้อขายและการลงทุนทองคำเป็นที่นิยมอย่างมาก รายงานวิจัยของ World Gold Council แสดงให้เห็นว่าตั้งแต่ปี 2001 ความต้องการลงทุนทองคำทั่วโลกเพิ่มขึ้นประมาณร้อยละ 15 ในแต่ละปี (World Gold Council, 2019a) และตามรายงานการสำรวจตลาดค้าปลีกทองคำล่าสุดในปี 2019 พบว่าในบรรดาผลิตภัณฑ์การลงทุนทั้งหมด นักลงทุนรายย่อยเลือกลงทุนทองคำในสัดส่วนร้อยละ 46 ซึ่งรองมาจากบัญชีเงินฝากออมทรัพย์ในสัดส่วนร้อยละ 78 และประกันชีวิตในสัดส่วนร้อยละ 54 เป็นสาเหตุให้ทองคำกลายเป็นเครื่องมือการลงทุนหลักในตลาดโลกมากขึ้นเรื่อย ๆ (World Gold Council, 2019b) เนื่องจากทองคำเป็นสินทรัพย์ปลอดภัย (Safe haven asset) หากสังเกตการเปลี่ยนแปลงราคาทองคำจะพบว่ามีความผันผวนเคลื่อนไหวในทิศทางตรงกันข้ามกับค่าเงินดอลลาร์สหรัฐ บ่งชี้ได้ว่าทองคำนอกจากสามารถใช้ป้องกันความเสี่ยงจากการด้อยค่าของสกุลเงินสำรองของโลก (Reserve currency) ทองคำสามารถทำหน้าที่เป็นตัวป้องกันอัตราเงินเฟ้อ และเป็นหนึ่งในสินทรัพย์สำคัญในพอร์ตการลงทุนของนักลงทุน รวมถึงธนาคารกลางและสถาบันการเงินต่างประเทศต่างเก็บทองคำไว้จำนวนมากเพื่อการกระจายความเสี่ยงและความมั่นคงทางเศรษฐกิจ (Kaufmann & Winters, 1989 อ้างถึง Gokmenoglu & Fazlollahi, 2015)



รูปที่ 1: ฝั่งแสดงตำแหน่งความเสี่ยงและผลตอบแทนของผลิตภัณฑ์การลงทุนแต่ละประเภท
(ที่มา: <https://www.joyfuli.co.jp/hubfs/web/images/32.png>)

จากรูปที่ 1 พบว่า ทองคำถูกจัดอยู่ในตำแหน่งของกลุ่มสินค้าโภคภัณฑ์ที่ค่อนข้างไปด้านความเสี่ยงต่ำ และมีผลตอบแทนที่สูงเมื่อเทียบกับการลงทุนประเภทอื่น

World Gold Council ได้เปิดเผยสถิติผลตอบแทนจากทองคำและสินทรัพย์ที่มีความใกล้เคียงกัน พบว่าที่ผ่านมาทองคำเป็นสินทรัพย์ที่ให้ประโยชน์และสร้างผลตอบแทนเชิงบวกต่อนักลงทุนในระยะยาวในช่วงเวลาที่มีความไม่แน่นอน ทั้งในช่วงเวลาที่ดีและช่วงเวลาเกิดวิกฤตการณ์ต่างๆ จากมุมมองทั่วโลก



Data based on USD. Data as of 31 Dec, 2022

Sources: Bloomberg, ICE Benchmark Administration, World Gold Council; Disclaimer: <https://www.gold.org/terms-and-conditions#proprietary-rights>

รูปที่ 2: เปรียบเทียบความสามารถการให้ผลตอบแทนสินทรัพย์ทางการเงินประเภทต่าง ๆ ตั้งแต่ปี 2002 ถึง 2022

(ที่มา: <https://www.gold.org/goldhub/data/gold-returns>)

ตารางที่ 1: ชื่อย่อ ชื่อเต็ม ประเภทหลักทรัพย์ ที่ถูกเลือกนำมาเปรียบเทียบผลตอบแทน

| ชื่อย่อ | ชื่อเต็ม | ประเภทหลักทรัพย์ |
|-------------|--------------------------------------|------------------------------------|
| GOLD | Gold Spot US | ทองคำ (Gold) |
| MSCI US | MSCI US Total Return Index | ตราสารทุน (Equities) |
| US CASH | ICE BofA US 3-Month Treasury Bills | ตราสารหนี้ (Fixed income) |
| BBG US Bond | Bloomberg Barclays US Bond Aggregate | ตราสารหนี้ (Fixed income) |
| Hedge Funds | Hedge Fund Research Weighted Index | กองทุนทางเลือก (Alternative funds) |

นักลงทุนทองคำมีแนวโน้มที่จะได้รับมูลค่าผลตอบแทนจากการลงทุนในช่วงเงินเฟ้อและช่วงที่มีความผันผวนทางเศรษฐกิจ ซึ่งมักมาจากความไม่แน่นอนทางการเมืองหรือวิกฤตการณ์ระดับโลกที่ไม่สามารถควบคุมได้ เช่น เหตุการณ์ความขัดแย้งระหว่างประเทศ เหตุการณ์การระบาดโรคติดเชื้อไวรัสโคโรนา 2019 ฯลฯ แต่ทองคำจะได้รับความน่าสนใจน้อยลงเมื่ออัตราดอกเบี้ยสูงขึ้น เนื่องจากนักลงทุนไม่ได้รับดอกเบี้ยหรือเงินปันผลจากการถือครองทองคำ นอกจากนี้ ตลาดทองคำมีข้อได้เปรียบในด้านสภาพคล่องสูง สามารถแลกเปลี่ยนทองคำเป็นเงินสดได้อย่างรวดเร็วเมื่อใดก็ได้ โดยภาพรวมราคาทองคำขึ้นอยู่กับตัวบ่งชี้ทางเศรษฐกิจหลายปัจจัยและความซับซ้อนในการทำความเข้าใจการเปลี่ยนแปลงของราคา ราคาทองคำยังสามารถบ่งชี้ถึงเสถียรภาพทางการเงินโดยรวมของสภาพแวดล้อมทางธุรกิจทั่วโลก ปัจจัยต่าง ๆ ที่เป็นตัวขับเคลื่อนและแรงหนุนราคาทองคำ ได้แก่ มูลค่าของเงินดอลลาร์สหรัฐ อัตราเงินเฟ้อ อัตราดอกเบี้ย สภาพเศรษฐกิจทั่วโลก ความไม่มั่นคงทางภูมิรัฐศาสตร์ อุปสงค์และอุปทานของทองคำ

Rolling volatility

US




1y rolling period, monthly return frequency. Data as of 31 Jan, 2023

Sources: Bloomberg, CBOE, COMEX, World Gold Council; Disclaimer: <https://www.gold.org/terms-and-conditions#proprietary-rights>

รูปที่ 3: เปรียบเทียบความผันผวนของทองคำกับสินทรัพย์อื่นๆ ในระยะเวลา 1 ปี ตั้งแต่ปี 2003 ถึง 2022 (ที่มา: <https://www.gold.org/goldhub/data/gold-price-volatility>)

Rolling volatility

US



5y rolling period, monthly return frequency. Data as of 31 Jan, 2023

Sources: Bloomberg, CBOE, COMEX, World Gold Council; Disclaimer: <https://www.gold.org/terms-and-conditions#proprietary-rights>


รูปที่ 4: เปรียบเทียบความผันผวนของทองคำกับสินทรัพย์อื่นๆ ในระยะเวลา 5 ปี ตั้งแต่ปี 2007 ถึง 2022 (ที่มา: <https://www.gold.org/goldhub/data/gold-price-volatility>)

เมื่อพิจารณาว่าทองคำเป็นตัวเลือกในการลงทุนที่ดี ในขณะที่ตลาดการเงินยังคงมีความผันผวนอย่างมาก ทำให้ยากต่อการคาดการณ์ราคาทองอย่างแม่นยำ และยากยิ่งขึ้นในการลงทุนระยะยาว ด้วยเหตุนี้นักลงทุนควรศึกษา สังเกตแนวโน้มตลาด ข่าวสาร การวิเคราะห์ทางเทคนิคและปัจจัยพื้นฐาน และความเห็นจากผู้เชี่ยวชาญก่อนตัดสินใจซื้อขาย ดังนั้นการคาดการณ์ราคาทองคำสำคัญต่อนักลงทุน ธุรกิจ และอุตสาหกรรมที่เกี่ยวข้อง เช่น อุตสาหกรรมเครื่องประดับ อุปกรณ์ทางการแพทย์ อุตสาหกรรมอิเล็กทรอนิกส์

การศึกษาการลงทุนทุกประเภทรวมถึงการลงทุนทองคำในยุคปัจจุบัน ซึ่งเป็นยุคที่มีแหล่งข้อมูลข่าวสาร บทวิเคราะห์ บอร์ดส่วนกลาง (Discussion forum) สำหรับปรึกษา แนะนำ ประเด็นต่าง ๆ ผ่านโลกออนไลน์ รวมถึงข้อคิดเห็นการลงทุนทั้งทองคำหรือผลิตภัณฑ์ด้านการลงทุนต่าง ๆ สามารถค้นหาได้จากอินเทอร์เน็ตและสื่อสังคมออนไลน์ตลอดเวลา ทำให้เห็นว่าข่าวสารบนโลกเชื่อมโยงกันอย่างแน่นและสามารถแพร่กระจายข้อมูลได้อย่างรวดเร็ว ตลอดจนเทคโนโลยี AI Chatbot ล่าสุดชื่อว่า Chat GPT แหล่งข้อมูลที่หลากหลายเหล่านี้โดยเฉพาะบทวิเคราะห์และการแสดงความคิดเห็นจึงเป็นประโยชน์อย่างมากสำหรับนักลงทุนในการประกอบการตัดสินใจอย่างมีประสิทธิภาพ ทำให้เพิ่มความมั่นใจในการลงทุนมากยิ่งขึ้น หรืออาจกล่าวได้ว่านักลงทุนจะเข้าใจเหตุผลได้ว่าทำไมจึงต้องตัดสินใจซื้อขาย และยังสามารถคอยติดตามประเด็นต่าง ๆ ที่เกี่ยวข้องกับทองคำได้ตลอดเวลา ดังนั้นเครื่องมือจากสื่อสังคมออนไลน์สามารถเป็นตรวจวัดความเชื่อมั่นของตลาดการลงทุน คลี่คลายความเสี่ยงจากการคาดเดาในช่วงมีความผันผวนของตลาด โดยใช้ตัวชี้วัดที่เรียกว่า ความเชื่อมั่น ความรู้สึก อารมณ์ หรือความคิดเห็น (Sentiment index)

จากการศึกษาของ (Bollen, 2011) ใช้เทคนิคการวิเคราะห์ความรู้สึก (Sentiment analysis) ตรวจสอบความรู้สึก อารมณ์ ของผู้คนบนสังคมทวิตเตอร์ โดยแบ่งประเภทอารมณ์ในวันเหตุการณ์สำคัญต่าง ๆ เช่น พบว่าในปี 2008 วันที่มีการเลือกตั้งท้องถิ่น (Local presidential election) และ วันขอบคุณพระเจ้า (Thanksgiving day) หากเพิ่มตัวแปรทางอารมณ์ในโมเดลเพื่อคาดการณ์ราคาปิดของดัชนีอุตสาหกรรมดาวโจนส์ (The Dow Jones Industrial Average, DJIA) นั้นมีความแม่นยำเพิ่มขึ้นจาก 73.3% เป็น 86.7%

งานตีพิมพ์ของ (Peterson, 2016) ให้ตัวอย่างที่มองเห็นชัดเจน ในปี 2013 เงิน Lira ของตุรกีด้อยค่าลงในเดือนมกราคม ปี 2014 หลังจากการประท้วงต่อต้านรัฐบาลที่ไร้ความสามารถที่รุนแรงมากในปีก่อนหน้า เนื่องจากรัฐบาลตอบสนองอย่างไม่เหมาะสมต่อการประท้วงควบคู่ไปกับการเปิดเผยการทุจริตที่สร้างความไร้เสถียรภาพทางเศรษฐกิจและการเมืองในตุรกี สกุลเงิน Lira จึงตกลงและสื่อธุรกิจระหว่างประเทศเพิ่มการรายงานข่าวของสกุลเงินมากกว่า 20 เท่า ทำให้ตลาดที่เคยสงบโดนความกลัวเข้าครอบงำ เป็นปรากฏการณ์ในตลาดการเงินที่เกิดขึ้นอย่างรวดเร็ว มูลค่าของ Lira พ้นตัวขึ้นอย่างมาก ในปีถัดมาหลังจากการตื่นตระหนก



รูปที่ 5: ความสัมพันธ์ระหว่างสกุลเงิน Lira (TRY) กับกระแสข่าวและสื่อสังคมออนไลน์ ตั้งแต่ ตุลาคม 2013 ถึง เมษายน 2014 (ที่มา: Trading on Sentiment: The Power of Minds Over Markets (p. 124), by Richard L. Peterson, 2016, John Wiley & Sons.)

จะเห็นว่าจากข้อมูลความเชื่อมั่นในกระแสข่าว สื่อสังคมออนไลน์ การกลับตัวของมูลค่าเงิน Lira สามารถคาดการณ์ได้มากขึ้น และการกลับตัวเฉื่อยมีแนวโน้มมากขึ้นเมื่อมีความกลัวสูง

เพื่อให้เกิดประโยชน์ต่อนักลงทุนทองคำ การวิเคราะห์ความรู้สึกจากข้อคิดเห็นในสื่อสังคมออนไลน์ (Social media) จึงถูกนำมาใช้ในการศึกษา งานวิจัยนี้มุ่งเน้นศึกษาข้อความที่ผู้เชี่ยวชาญด้านการลงทุนทองคำเผยแพร่ในทวิตเตอร์ (Twitter) มาใช้วิเคราะห์ร่วมกับราคาทองคำที่มีการเคลื่อนไหวอยู่ตลอดเวลา เพื่อคาดการณ์ทิศทางของราคาทองคำในอนาคต และเป็นแนวทางสนับสนุนการตัดสินใจในการลงทุนซื้อขายทองคำ

1.2 วัตถุประสงค์ และคำถามงานวิจัย

วัตถุประสงค์

- 1) เพื่อหาความสัมพันธ์ระหว่างข้อความทวีตของผู้เชี่ยวชาญด้านการลงทุนทองคำในสื่อสังคมออนไลน์ ทวิตเตอร์กับการเปลี่ยนแปลงราคาทองคำที่เกิดขึ้นจริง

2) เพื่อศึกษาข้อความทวีตของผู้เชี่ยวชาญด้านการลงทุนทองคำ โดยใช้หลักการทำเหมืองข้อความ (Text mining) ร่วมกับการประมวลภาษาธรรมชาติ (Natural Language Processing, NLP)

3) เพื่อเปรียบเทียบประสิทธิภาพของอัลกอริทึมในการจำแนกข้อความทวีตของผู้เชี่ยวชาญด้านการลงทุนทองคำ ได้แก่

อัลกอริทึมต้นไม้ตัดสินใจ (Decision Trees) นาอิวเบย์ (Naive Bayes) เครื่องเวกเตอร์ค้ำยัน (Support Vector Machines) และการถดถอยโลจิสติก (Logistic Regression) ด้วยวิธีการเปรียบเทียบค่าความถูกต้อง (Accuracy) ค่าความแม่นยำ (Precision) ค่าระลึก (Recall) และประสิทธิภาพโดยรวมของระบบ (F-measure) ของผลลัพธ์ที่ได้จากแต่ละอัลกอริทึม

คำถามงานวิจัย

- 1) ทิศทางราคาทองคำได้รับอิทธิพลจากข้อความทวีตของผู้เชี่ยวชาญด้านการลงทุนทองคำอย่างไร
- 2) ค่าความรู้สึก (Sentiment score) เป็นตัวแปรควบคุมส่งผลต่อทิศทางราคาทองคำอย่างไร
- 3) ประสิทธิภาพของอัลกอริทึมในการจำแนกข้อความทวีตของผู้เชี่ยวชาญด้านการลงทุนทองคำเป็นอย่างไร

1.3 แนวทางเบื้องต้นในการตอบวัตถุประสงค์หรือคำถามงานวิจัย

- 1) ศึกษา Library ของภาษา Python ที่เกี่ยวข้องกับการทำโมเดลด้วยวิธีการเรียนรู้ของเครื่องแบบมีผู้สอน (Supervised Machine Learning) และเทคนิคการประมวลภาษาธรรมชาติ
- 2) ศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้องด้านการลงทุนทองคำ ปัจจัยที่มีผลกระทบต่อราคาทองคำ การวิเคราะห์ความรู้สึก ความเชื่อมั่นด้านการลงทุน
- 3) ทำการรวบรวมข้อความทวีตของผู้เชี่ยวชาญด้านการลงทุนทองคำจากทวีตเตอร์ และข้อมูลดัชนีในตลาดหลักทรัพย์ที่มีผลกระทบต่อราคาทองคำตั้งแต่ มกราคม ปี 2017 ถึง ธันวาคม ปี 2022
- 4) ทำการเตรียมข้อมูลให้พร้อม (Data preprocessing) สำหรับการวิเคราะห์ สำหรับข้อมูลที่เป็นรูปแบบข้อความ จะถูกเตรียมด้วยเทคนิคการประมวลภาษาธรรมชาติ เพื่อจัดการกับความหมายและโครงสร้างของภาษา สำหรับข้อมูลราคาหลักทรัพย์ รวมถึงราคาสินค้าโภคภัณฑ์ ดัชนีอัตราแลกเปลี่ยน และดัชนีความผันผวนของราคาทองคำ จะถูกนำมารวม ปรับแต่งจุดผิดพลาด เรียกกระบวนการรวมในขั้นตอนนี้ว่า Data wrangling จากนั้นสร้าง Feature เพื่อใช้เป็น Target เรียกกระบวนการนี้ว่า Feature extraction
- 5) แบ่งการวิเคราะห์ออกเป็น 2 ส่วน:

ส่วนที่ 1: มีวัตถุประสงค์เพื่อการตรวจจับคำ ประโยคที่มาจากข้อความทวีตของผู้เชี่ยวชาญด้านการลงทุนทองคำ เนื่องจากการทวีตข้อความด้านการลงทุนทองคำที่ผู้คนทั่วโลกสามารถเข้าไปอ่าน มีความน่าจะเป็นที่กำลังให้สัญญาณว่าราคาทองคำในวันถัดไปหรือสัปดาห์ถัดไปมีทิศทางอย่างไร

ส่วนที่ 2: มีวัตถุประสงค์เพื่อทดสอบว่าค่าความรู้สึกร่วมกับตัวแปรคาดการณ์อื่นๆเพื่อใช้ในการคาดการณ์ทิศทางราคาทองคำเป็นตัวแปรตาม ที่ให้ความแม่นยำด้วยเทคนิคการเรียนรู้ของเครื่อง

- 6) ค้นหาและคำนวณคำศัพท์สำคัญในข้อความ สำหรับส่งผ่านข้อมูลเข้าโมเดลเพื่อรับการฝึกฝน และจะถูกฝึกฝนเฉพาะในคำศัพท์ของชุดข้อมูลที่ใช้ฝึกฝนเท่านั้น
- 7) แบ่งชุดข้อมูลเพื่อเข้าฝึกฝน นำข้อมูลส่งผ่านเข้าโมเดลสำหรับคาดการณ์ที่เลือกไว้เพื่อเรียนรู้
- 8) ศึกษาและเลือกโมเดลสำหรับคำนวณค่าความรู้สึก
- 9) ประเมินและเปรียบเทียบประสิทธิภาพการคาดการณ์ทิศทางราคาทองคำของแต่ละโมเดล

1.4 นิยามของคำศัพท์

- 1) สื่อสังคมออนไลน์ (Social media) คือ แพลตฟอร์มดิจิทัลที่มีการตอบสนองที่ถูกนำมาใช้เป็นเครื่องมือในการสื่อสาร แสดง แลกเปลี่ยนความคิดเห็นต่างๆ และแบ่งปันเรื่องราวกับสาธารณชนในรูปแบบ ข้อความ รูปภาพ คลิปวิดีโอ ผ่านเครือข่ายอินเทอร์เน็ต
- 2) Tweet มาจากเสียงกริ่ง หมายถึงการโพสต์ข้อความใน Twitter แพลตฟอร์มสื่อสังคมออนไลน์ที่นิยมในปัจจุบัน มีโลโก้เป็นรูปนกสีฟ้า เปรียบกับการเผยแพร่ข้อความเป็นเสียงกริ่งแจ้งเตือนข่าวสาร
- 3) Sentiment หมายถึง อารมณ์ ความรู้สึก ข้อคิดเห็น หรือความเชื่อมั่นหากเป็นมุมมองด้านธุรกิจ sentiment analysis คือ “การวิเคราะห์ความรู้สึก” แบ่งเป็นเชิงบวก (Positive) เชิงลบ (Negative) และเป็นกลาง (Neutral)
- 4) การเรียนรู้ด้วยเครื่อง (Machine Learning) คือการศึกษาที่มีจุดมุ่งหมายเพื่อสอนคอมพิวเตอร์ถึงวิธีการเรียนรู้และดำเนินการโดยไม่ต้องตั้งโปรแกรมไว้ วิธีการเรียนรู้ด้วยเครื่องเป็นแนวทางการวิเคราะห์ข้อมูลที่เกี่ยวข้องกับการสร้างและการปรับโมเดล ซึ่งทำให้โปรแกรมสามารถ "เรียนรู้" ผ่านประสบการณ์ได้ การเรียนรู้ด้วยเครื่องเกี่ยวข้องกับการคิดค้นอัลกอริทึมที่ปรับโมเดลเพื่อพัฒนาความสามารถในการคาดการณ์

5) การเรียนรู้แบบมีผู้สอน (Supervised Learning) เป็นรูปแบบการเรียนรู้ของเครื่องที่ซึ่งการสร้างฟังก์ชันทางคณิตศาสตร์ที่เกี่ยวข้องกับตัวแปร input กับตัวแปร output ที่ต้องการ มีชุดข้อมูลสำหรับการฝึกฝนที่มีการแบ่งประเภทแล้วจำนวนมาก ซึ่งเป็นตัวอย่างข้อมูลที่คอมพิวเตอร์จะนำไปเรียนรู้ และประมวลผล

6) การประมวลผลภาษาธรรมชาติ (Natural Language Processing, NLP) คือการศึกษาที่เกี่ยวข้องกับปฏิสัมพันธ์ระหว่างคอมพิวเตอร์กับภาษาธรรมชาติ (ภาษามนุษย์) เป็นหลัก โดยที่ความสำคัญของการประมวลผลภาษาธรรมชาติรวมถึง การรู้จำเสียง (speech recognition) การเข้าใจภาษาธรรมชาติ และการสร้างภาษาธรรมชาติ (natural language generation) วิธีการเรียนรู้ด้วยเครื่องสามารถนำไปใช้กับการศึกษาด้านนี้ได้

7) การลงทุน (Investment) คือ การใช้เงินเพื่อให้ได้มาซึ่งทรัพย์สินที่จะนำไปใช้ในการผลิตสินค้าหรือบริการให้เกิดรายได้ ทำให้เกิดกิจกรรมทางเศรษฐกิจ เช่น การซื้อ-ขายสินค้าและบริการ มีการจ้างงาน มีการรับเงิน เก็บออม การใช้จ่าย จนมีความเติบโตสามารถนำกำไรไปลงทุนใหม่ต่อเนื่อง การลงทุนทองคำ (Gold investment) หมายถึงการใช้เงินเพื่อให้ได้มาซึ่งสินทรัพย์โภคภัณฑ์ทองคำ ซึ่งถูกจัดว่าเป็นหนึ่งในการลงทุนที่ปลอดภัย ประเภทของการลงทุนทองคำได้แก่ การลงทุนซื้อ-ขายทองคำแท่ง การลงทุนในกองทุนรวมทองคำ (ETF) การลงทุนในหุ้นเหมืองทองคำ และการลงทุนในตราสารอนุพันธ์ทองคำ

1.5 ขอบเขตของงานวิจัย

1) ขอบเขตด้านข้อมูล

ข้อมูลจากข้อความทวีตของผู้เชี่ยวชาญด้านการลงทุนทองคำ เป็นข้อมูลรายวัน ตั้งแต่เดือนมกราคม 2017 ถึง เดือนธันวาคม 2022 โดยที่มาของข้อมูลมาจากข้อคิดเห็นของผู้เชี่ยวชาญด้านการลงทุนทองคำจาก Twitter ที่มีจำนวนยอดผู้ติดตามมากที่สุด 10 อันดับ

ข้อมูลเกี่ยวกับราคาทองคำ (Gold Spot, XAU/USD), ดัชนีค่าเงินดอลลาร์สหรัฐ (Dollar Index) ดัชนีความผันผวนของราคาทอง (Gold Volatility Index, GVZ) อัตราดอกเบี้ยระหว่างธนาคารของสหรัฐฯ (Effective Federal Funds Rate, EFFR) มูลค่า SPDR Gold Shares (GLD, \$/ozt) ดัชนีกองทุน SPDR S&P 500 ETF Trust (SPY) และ อัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐอเมริกา 10 ปี (TNX) ตั้งแต่เดือนมกราคม 2017 ถึง เดือนธันวาคม 2022

2) ขอบเขตด้านเครื่องมือ

เครื่องมือที่ใช้ในการเก็บข้อมูล คือ อัลกอริทึม “TWINT – Twitter Intelligence Tool” ที่ถูกพัฒนาด้วยภาษา Python ที่ไม่ใช่ API ของ Twitter สำหรับเก็บข้อมูลรูปแบบข้อความทวีตของผู้เชี่ยวชาญด้านการลงทุนทองคำในทวีตเตอร์

เครื่องมือที่ใช้ในการศึกษา สร้างแบบจำลอง และการวิเคราะห์ข้อมูลสำหรับใช้คาดการณ์ทิศทางราคาทองคำ คือ Library ต่างๆที่ถูกเรียกใช้ถูกพัฒนาด้วยภาษา Python ได้แก่ Scikit-Learn module เป็น Open-source ที่ได้รับการพัฒนาอย่างต่อเนื่อง และเป็นเครื่องมือที่ได้รับความนิยมอย่างมากในการสร้างโมเดล เพื่อทำนาย พยากรณ์ต่าง ๆ และ Natural Language Toolkit (NLTK) เป็นเครื่องมือที่ใช้ในการจัดการข้อมูลรูปแบบข้อความ NLTK รวบรวมหลาย Module เช่น สร้างคลังคำศัพท์ สกัดแบ่งคำออกจากกลุ่มเอกสาร แปลงคำให้อยู่ในรูปแบบพร้อมใช้งาน ฯลฯ

เครื่องมือที่ใช้ในการวิเคราะห์ความรู้สึก คือ FinBERT ซึ่งเป็นโมเดลที่ออกแบบมาเป็นพิเศษเพื่อทำงานกับข่าวและข้อความทางการเงิน FinBERT จะส่งกลับค่าความรู้สึกในรูปแบบตัวเลข (Polarity score) ซึ่งมีค่าระหว่าง -1 ถึง 1 ค่าเป็นลบหมายถึง ความรู้สึกในทิศทางที่ไม่ดี, ค่าเป็นบวกหมายถึง ความรู้สึกในทิศทางที่ดี และ 0 หมายถึง ความรู้สึกเป็นกลาง

1.6 ข้อยกจำกัดของงานวิจัย

- 1) การเก็บข้อมูลข้อความทวีตของผู้เชี่ยวชาญด้านการลงทุนทองคำนั้นถูกรวบรวมมา 8 ท่านโดยคัดเลือกจากจำนวนผู้ติดตาม 20,000 ผู้ใช้งานขึ้นไป และเป็นทั้งหมดข้อความภาษาอังกฤษเพียงเท่านั้น
- 2) วิธีการเก็บข้อมูลโดยใช้ความสามารถจากอัลกอริทึม Twint ซึ่งเป็น Open-source
- 3) ตัวเลขทางเศรษฐกิจที่นำมาใช้เป็น Feature เพื่อการฝึกฝนข้อมูลรวมเป็นข้อมูลตัวเลขราคาปิดรายวัน โดยมี อัตราแลกเปลี่ยนดอลลาร์สหรัฐ, ดัชนีความผันผวนของทองคำ (GVZ), อัตราดอกเบี้ยระหว่างธนาคารของสหรัฐฯ, มูลค่ากองทุน ETF อ้างอิงราคากองทุนรวมทองคำในต่างประเทศ มีชื่อว่า SPDR Gold Shares (GLD), ดัชนีกองทุน SPDR S&P 500 ETF Trust (SPY) และ อัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐอเมริกา 10 ปี (TNX)
- 4) การวิเคราะห์ความรู้สึกใช้อัลกอริทึมสำเร็จรูป FinBERT ในการคำนวณหาค่าคะแนน Sentiment

1.7 ระยะเวลาในการดำเนินโครงการ

โครงการ “การคาดการณ์ทิศทางการค้าจากความรู้สึกของข้อความบนทวิตเตอร์โดยใช้เทคนิคการเรียนรู้ด้วยเครื่อง” มีระยะเวลาในการดำเนินงานโครงการ ดังตารางที่ 2

ตารางที่ 2: ระยะเวลาที่ใช้ในการทำวิจัย

| ขั้นตอนการดำเนินงาน | ระยะเวลาในการดำเนินงาน | | | | | | |
|--|------------------------|------|------|---------|------|-------|-------|
| | ปี 2565 | | | ปี 2566 | | | |
| | ต.ค. | พ.ย. | ธ.ค. | ม.ค. | ก.พ. | มี.ค. | เม.ย. |
| 1. ศึกษาวรรณกรรมที่เกี่ยวข้องกับงานวิจัย | | | | | | | |
| 2. สร้างเครื่องมือที่จะใช้เก็บข้อมูล | | | | | | | |
| 3. เก็บข้อมูลสำหรับการวิจัย | | | | | | | |
| 4. จัดการข้อมูล | | | | | | | |
| 5. วิเคราะห์ข้อมูลการวิจัย | | | | | | | |
| 6. สรุปผลข้อมูลการวิจัย | | | | | | | |
| 7. เรียบเรียงรายงานการวิจัย | | | | | | | |
| 8. จัดพิมพ์งานวิจัย | | | | | | | |

1.8 ประโยชน์ที่คาดว่าจะได้รับ

1. ได้ทราบถึงอิทธิพลของข่าวที่เกี่ยวกับการลงทุนทองคำในเครือข่ายสังคมออนไลน์ทวิตเตอร์ที่ส่งผลต่อการคาดการณ์ทิศทางการค้าทองคำ
2. ได้ผลลัพธ์จากการเรียนรู้ของโมเดลที่มาจากสัญญาณของข่าวที่เกี่ยวกับการลงทุนทองคำในเครือข่ายสังคมออนไลน์ทวิตเตอร์
3. ได้อัลกอริทึมที่เหมาะสมสำหรับการวิเคราะห์ความรู้สึกของข้อมูลที่มาจากข้อคิดเห็นของผู้เชี่ยวชาญด้านการลงทุนทองคำ

บทที่ 2

วรรณกรรมที่เกี่ยวข้อง

2.1 บทนำ

ในการศึกษา “การคาดการณ์การเปลี่ยนแปลงราคาทองคำจากความรู้สึกของข้อความบนทวิตเตอร์โดยใช้เทคนิคการเรียนรู้ด้วยเครื่อง” มีหลักการ ทฤษฎีต่าง ๆ ที่เกี่ยวข้องกับการลงทุนทองคำ ปัจจัยที่มีผลกระทบต่อราคาทองคำ ลักษณะ และอิทธิพลของข้อมูลที่มาจากสื่อสังคมออนไลน์ที่ใช้เผยแพร่บทวิเคราะห์ทิศทางราคาทองคำ การเรียนรู้ด้วยเครื่อง (Machine learning) ตลอดจนงานวิจัยที่เกี่ยวข้อง ดังรายละเอียดต่อไปนี้

2.2 การลงทุนทองคำและปัจจัยที่มีผลกระทบต่อราคาทองคำ

ทองคำไม่ใช่สินทรัพย์ที่สร้างรายได้ ผลตอบแทนจากทองคำขึ้นอยู่กับการแข่งขันค่าของราคา (Price appreciation) นอกจากนี้ทองคำเป็นทรัพย์สินที่จับต้องได้ ดังนั้นการลงทุนในทองคำจำเป็นต้องมีต้นทุนค่าใช้จ่ายในการจัดเก็บและค่าประกัน และในขณะที่ทองคำถูกมองว่าเป็นสินทรัพย์ที่ปลอดภัย แต่ก็มีความผันผวนสูง ราคาทองคำลดลงได้ นักลงทุนส่วนมากจึงมองว่าทองคำเป็นตัวช่วยที่ดีที่สุดเมื่อมีบทบาทเป็นส่วนหนึ่งของพอร์ตการลงทุน (กลุ่มรายการหลักทรัพย์สินตั้งแต่ 2 หลักทรัพย์สินขึ้นไป) โดยเฉพาะทำหน้าที่เป็นตัวป้องกันความเสี่ยงเมื่อความเคลื่อนไหวของราคาหุ้นในตลาดหลักทรัพย์ฯ ทั้งหมดเป็นแนวโน้มขาลง

การเปลี่ยนแปลงราคาทองคำเกิดขึ้นได้ตลอดเวลา มีทั้งขาขึ้นและขาลง ตามปัจจัยต่าง ๆ ที่เข้ามากระทบโดยปัจจัยหลักที่นักลงทุนใช้วิเคราะห์คาดการณ์แนวโน้มการขึ้นลงของราคาทองคำในตลาดโลก เช่น ราคาน้ำมันดิบ ค่าเงินดอลลาร์สหรัฐ อัตราดอกเบี้ย ราคาหุ้น วิกฤตการณ์ต่างๆ ซึ่งเป็นเพียงตัวชี้วัดคร่าว ๆ เท่านั้น ราคาทองคำยังมีปัจจัยแวดล้อมอื่นๆ เข้ามาเกี่ยวข้อง เช่น การประกาศนโยบายทางเศรษฐกิจโดยเฉพาะของสหรัฐอเมริกา ที่แม้เป็นผลบวกกับราคาทองคำ แต่ผู้บริโภค และนักลงทุน ไม่เชื่อมั่นว่าจะเป็นจริงได้ ก็จะทำให้ราคาทองคำไม่เป็นไปตามคาดการณ์ได้เช่นกัน การลงทุนทองคำจึงต้องติดตามข้อมูลข่าวสารรอบด้านอย่างสม่ำเสมอ

ปัจจัยที่มีผลกระทบต่อราคาทองคำ (Factors Affecting Gold Prices)

1) ราคาน้ำมันดิบ (Crude Oil Price)

งานวิจัยของ (Coronado & Rojas, 2016) ใช้ตัวอย่างข้อมูลโดยแบ่งเป็นชุดข้อมูลย่อย เริ่มตั้งแต่วันที่ 1 ของปีใดๆ ระหว่างกลางปี ค.ศ. 1990 - 2001 จนถึงวันที่ 5 กุมภาพันธ์ ค.ศ. 2015

พบว่าความสัมพันธ์ที่เป็นเหตุเป็นผลระหว่างการเคลื่อนไหวของราคาในตลาดน้ำมันดิบและตลาดทองคำ สอดคล้องกับงานวิจัยของ A. Kaur & K. Gupta (2019) ค้นหาความสัมพันธ์ระหว่างราคาทองคำในประเทศอินเดียกับราคาน้ำมันดิบ ผลกระทบของการเปลี่ยนแปลงของราคาน้ำมันดิบต่อการเปลี่ยนแปลงของราคาทองคำ ได้ผลลัพธ์อย่างชัดเจนว่ามีความสัมพันธ์ในเชิงบวกปานกลางระหว่างตัวแปรทั้งสอง ตลาดน้ำมันดิบและทองคำยังเป็นตัวชี้วัดหลักของตลาดสินค้าโภคภัณฑ์ขนาดใหญ่ แต่ในช่วงวิกฤตการณ์การระบาดโรคติดเชื้อไวรัสโคโรนา 2019 ชาวจากศูนย์ข่าวพลังงานเมื่อวันที่ 21 เมษายน พ.ศ. 2563 รายงานว่า

หน่วยวิเคราะห์สถานการณ์ราคาน้ำมัน ไทยออยล์ เผยน้ำมันดิบ WTI ปรับลดลง 55.90 เหรียญสหรัฐ ปิด ดิตลบ 37.63 เหรียญสหรัฐต่อบาร์เรล นับเป็นครั้งแรกในประวัติศาสตร์ หลังนักลงทุนเทขายก่อนสิ้นสุดสัญญาส่งมอบน้ำมันเดือนพฤษภาคม 2563 ในวันที่ 21 เม.ย. 2563 รวมทั้งปัญหา COVID-19 ส่งผลความต้องการใช้น้ำมันในสหรัฐขาดด้า เกิดปัญหา น้ำมันล้นคลังต้องเร่งระบาย ด้านนักวิชาการพลังงานชี้ราคาน้ำมันดิบร่วงหนักเป็นความผันผวนแค่ช่วงสิ้นสุดสัญญาส่งมอบน้ำมัน

จากวิกฤตดังกล่าวเป็นช่วงที่ราคาน้ำมันดิบร่วงลง ขณะเดียวกันราคาทองคำกลับขึ้นสูงอย่างมาก พร้อมด้วยงานวิจัยของ K. Mitravinda & R. Pavithra (2020) อ้างอิงข้อมูลราคาทองคำและราคาน้ำมันดิบของปี 2010 ถึง 2019 เพื่อพยากรณ์ราคาทองคำในปี 2020 ถึง 2025 ปรากฏว่าแนวโน้มที่เพิ่มขึ้นของราคาทองคำและแนวโน้มราคาน้ำมันดิบที่ลดลงจะส่งผลดีต่อภาวะเศรษฐกิจ การขัดแย้งกันอย่างชัดเจนของราคาสินค้าโภคภัณฑ์ทั้งสองนี้ เป็นการทำลายตำนานทิศทางของราคาทองคำได้รับอิทธิพลจากราคาน้ำมันดิบ นักวิจัยทั้งสองจึงสรุปว่าแนวโน้มที่คาดการณ์นั้นเป็นเพียงภาวะเศรษฐกิจปกติเท่านั้น และเมื่อพิจารณาจากสถานการณ์การระบาดโรคติดเชื้อไวรัสโคโรนา 2019 ในขณะนั้น ทองคำกลายเป็นสินทรัพย์ที่ปลอดภัยในช่วงเศรษฐกิจถดถอยอย่างชัดเจน

เนื่องจากชุดข้อมูลของงานวิจัยนี้ครอบคลุมช่วงวิกฤตการณ์การระบาดโรคติดเชื้อไวรัสโคโรนา 2019 ซึ่งเป็นช่วงที่ราคาทองคำและราคาน้ำมันดิบมีความผันผวนอย่างมาก เพื่อป้องกันความคลาดเคลื่อนที่ผิดปกติ งานวิจัยนี้จึงไม่ใช้ราคาน้ำมันดิบเป็นตัวแปรในการคาดการณ์ราคาทองคำ

2) ดัชนีมูลค่าดอลลาร์สหรัฐ (Dollar Index, DXY)

Dollar Index เป็นดัชนีชี้วัดมูลค่าของสกุลเงินดอลลาร์สหรัฐ เทียบกับสกุลเงินสำคัญทั่วโลก 6 สกุล คือ EUR (ยูโร) JPY (เยน) GBP (ปอนด์) CAD (ดอลลาร์แคนาดา) SEK (โครนาสวีเดน) และ CHF (สวิสฟรังก์) ช่วงที่ตลาดกังวล (fear sentiment) หรือมีวิกฤติเงินดอลลาร์มักแข็งค่าเนื่องจากนักลงทุนต้องการเก็บไว้ในรูปสกุลเงินดอลลาร์

บทบาทสำคัญของเงินดอลลาร์สหรัฐ เนื่องจากสหรัฐอเมริกาเป็นประเทศที่มีขนาดเศรษฐกิจเป็นอันดับ 1 ของโลก สภาพเศรษฐกิจมีความแข็งแกร่งเมื่อเทียบกับประเทศอื่นทั่วโลก ทำให้เงินดอลลาร์มีบทบาทต่อระบบการเงินระดับโลก ไม่ว่าจะเป็นทุนสำรองระหว่างประเทศทั่วโลก บทบาทสำคัญนี้ส่งผลให้การค้าระหว่างประเทศและการซื้อขายสินทรัพย์ด้านการลงทุนส่วนใหญ่อยู่ในสกุลเงินดอลลาร์ เช่น น้ำมัน ทองคำ สินค้าโภคภัณฑ์ ตราสารหนี้ และหุ้น


เมื่อเงินดอลลาร์แข็งค่า ราคาทองคำ น้ำมัน และสินค้าโภคภัณฑ์จะปรับตัวลง เพราะสินทรัพย์เหล่านี้ถูกซื้อขายในสกุลเงินดอลลาร์ การแข็งค่าของเงินดอลลาร์ส่งผลให้ต้นทุนการซื้อเพิ่มขึ้น ความต้องการลดลง ราคาสินทรัพย์จึงมีแนวโน้มลดลง งานวิจัยของ A. Seemuang และ S. Romprasert (2556) ยืนยันได้ว่า “การเปลี่ยนแปลงของดัชนีดอลลาร์สหรัฐเป็นปัจจัยที่แม่นยำในการอธิบายการเคลื่อนไหวของราคาทองคำ เมื่อดอลลาร์สหรัฐอ่อนค่าลง 1% จากไตรมาสก่อน ราคาทองคำในไตรมาสปัจจุบันเพิ่มขึ้น 1.3%” จึงสรุปจากมุมมองดังกล่าวได้ว่า มูลค่าของทองคำมีทิศทางบวกแม้มูลค่าของค่าเงินดอลลาร์สหรัฐลดลง



รูปที่ 6: ความสัมพันธ์ระหว่างราคาทองคำกับค่าเงินดอลลาร์ ตั้งแต่ปี 2008 ถึง 2022 (ที่มา: <https://www.macrotrends.net/1335/dollar-vs-gold-comparison-last-ten-years>)

3) อัตราดอกเบี้ย และอัตราผลตอบแทน

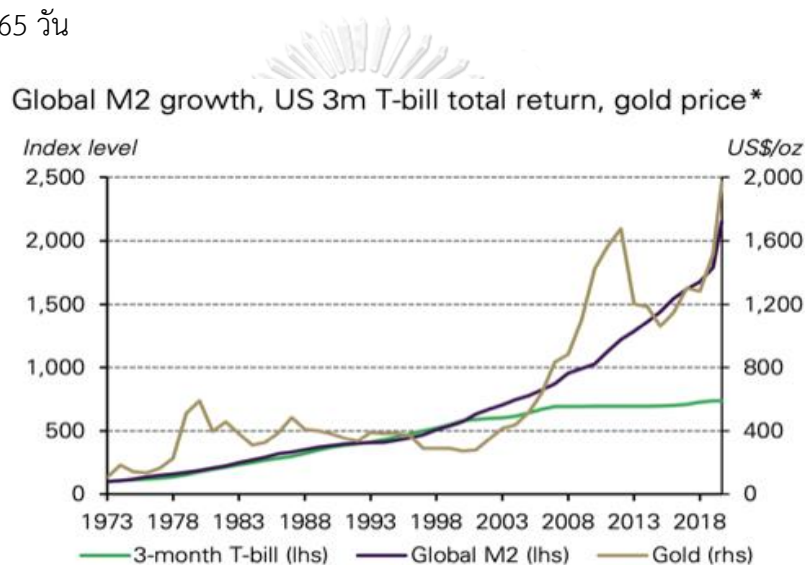
การปรับขึ้นหรือลดอัตราดอกเบี้ยของธนาคารกลางสหรัฐฯและนโยบายการเงินเป็นปัจจัยสำคัญที่ทำให้ดัชนีดอลลาร์มีแนวโน้มสูงขึ้นและลง หากธนาคารกลางเพิ่มความเข้มงวดต่อนโยบายการเงิน ประกาศปรับขึ้นอัตราดอกเบี้ย และหยุดซื้อพันธบัตร เป็นผลให้เงินดอลลาร์มีแนวโน้มแข็งค่า และราคาทองคำลดลง ในทางตรงกันข้ามหากธนาคารกลางประกาศลดอัตราดอกเบี้ยและซื้อพันธบัตรเพิ่ม เป็นผลให้แนวโน้มของค่าเงินดอลลาร์อ่อนค่าลงและราคาทองปรับสูงขึ้น



รูปที่ 7: ความสัมพันธ์ระหว่างอัตราดอกเบี้ยระหว่างธนาคารสหรัฐฯ และราคาทองคำตั้งแต่ปี 1971 ถึง 2021 (ที่มา: <https://www.nextmine.com/precious-metals/>)

พบว่ารูปแบบหลักของกราฟเป็นไปทิศทางตรงกันข้าม หมายความว่าหากราคาทองคำเคลื่อนไหวผกผันกับอัตราดอกเบี้ยในช่วงเวลาปกติ แต่สังเกตได้ว่าราคาทองคำจะขึ้นเมื่อเฟดปรับขึ้นอัตราดอกเบี้ยขึ้นอย่างรวดเร็ว โดยมีเหตุผลอยู่เบื้องหลัง

ความสัมพันธ์ระหว่างตัวเงินคลังและราคาทองคำสามารถหาคำตอบได้จากงานวิจัยของ (ทวิพงศ์ แซ่ลิ่ม และ ไกรชิต สุตะเมื่อง, 2556) สรุปไว้ว่า “อัตราผลตอบแทนของตัวเงินคลังสหรัฐฯ (T-Bill) อายุ 3 เดือน แปรผันในทิศทางตรงกันข้ามกับราคาทองคำ” ความหมายของตัวเงินคลัง (Treasury bill) คือตราสารหนี้ที่ออกโดยรัฐบาลและหน่วยงานภาครัฐ เป็นตราสารหนี้ระยะสั้น มีอายุไม่เกิน 365 วัน




รูปที่ 8: เปรียบเทียบราคาทองคำและอัตราผลตอบแทนจากตัวเงินคลังของสหรัฐฯประเภท 3 เดือน (ที่มา: <https://www.agabullion.com/BlogTR/Read?url=what-makes-gold-a-strategic-investment-tool>)

จากรูปที่ 8 เป็นกราฟข้อมูลตั้งแต่ปี 1973 ถึง 2018 รายงานชี้ให้เห็นว่า “ทองคำมีผลประกอบการที่ดีในอดีตท่ามกลางการร่วงลงของตลาดตราสารทุน (Equity market pullbacks) และอัตราเงินเฟ้อที่สูง ในปีที่อัตราเงินเฟ้อสูงกว่า 3% ราคาทองคำเพิ่มขึ้น 15% โดยเฉลี่ย นอกจากนี้ทองคำยังมีประสิทธิภาพมากขึ้นในการรองรับปริมาณเงินทั่วโลกในช่วงหลายปีที่ผ่านมามากกว่าตัวเงินคลังของสหรัฐฯ ซึ่งช่วยให้นักลงทุนรักษาเงินทุนได้ดีขึ้น” (Anna Golubova, 2021)


4) ดัชนีความผันผวนราคาทองคำ (Gold Volatility Index, GVZ)

ดัชนีความผันผวนราคาทองคำ คือ ตัวชี้วัดการเปลี่ยนแปลงของราคาทองคำโดยตลาดอนุพันธ์ The Chicago Board Options Exchange (CBOE) ดัชนีความผันผวน (GVZ) วัดจากการประเมินการคาดการณ์ความผันผวน 30 วันโดยสะท้อนจากราคาระยะสั้นของกองทุนทองคำ SPDR Gold ETF ที่เป็นกองทุน ETF ที่อ้างอิงกับราคาทองคำโลกที่ใหญ่ที่สุด ยิ่งนักลงทุนมีมุมมองว่าราคาทองผันผวนขึ้นดัชนี GVZ ก็จะปรับตัวขึ้น ในช่วงสถานการณ์ปกติราคาทองจะเปลี่ยนแปลงน้อยมาก ทำให้ค่าความผันผวนต่ำมาก ดัชนี GVZ ไม่ค่อยได้รับความสนใจในช่วงสถานการณ์ดังกล่าว หากเกิดสภาวะเศรษฐกิจถดถอย หรือมีความเสี่ยงจากค่าเงินสกุลหลักๆ ดัชนี GVZ จะถูกนำมาใช้เป็นเครื่องมือประเมินความกลัวได้ จึงสรุปได้ว่าราคาทองคำมีแนวโน้มและความสัมพันธ์ในเชิงบวกต่อความผันผวนของทองคำ



รูปที่ 9: ความสัมพันธ์ระหว่างราคาทองคำกับความผันผวนของทองคำรายวัน ตั้งแต่ กันยายน 2018 ถึง สิงหาคม 2019 (ที่มา https://www.dailyfx.com/forex/market_alert/2019/08/30/vix-volatility-hints-at-next-move-in-gold-us-dollar-stocks.html)

5) ปริมาณการถือครองเงินสำรองของธนาคารกลาง (Central Bank Reserves)




รูปที่ 10: Treemap แสดงการถือครองทองคำของธนาคารกลางของแต่ละประเทศ
 (ที่มา: <https://www.gold.org/goldhub/data/gold-reserves-by-country>)

พบว่าประเทศที่ถือครองทองคำสูงสุดโดยธนาคารกลางคือสหรัฐอเมริกาจำนวน 8,133 ตัน รองจากสหรัฐอเมริกาคือธนาคารกลางของเยอรมนีถือครองจำนวน 3,370 ตัน อันดับที่ 3 เป็นกองทุนการเงินระหว่างประเทศ (International monetary fund, IMF) ถือครองทองคำจำนวน 2,814 ตัน

ความสัมพันธ์ที่มีต่อราคาทองคำ คือ เมื่อธนาคารกลางกระจายทุนสำรองออกจากสกุลเงิน fiat ที่สะสมไว้และเปลี่ยนเป็นทองคำ ราคาทองคำจะมีแนวโน้มที่สูงขึ้น

6) ปริมาณอุปสงค์ทองคำสำหรับการผลิตอัญมณีและอุตสาหกรรมทั่วโลก

2022 gold demand almost matched the 2011 record



รูปที่ 11: ปริมาณอุปสงค์ของทองคำในแต่ละอุตสาหกรรมตั้งแต่ปี 2010 ถึง 2022

(ที่มา: <https://www.gold.org/goldhub/data/gold-demand-by-country>)

พบว่าสถิติอุปสงค์ของทองคำในช่วงครึ่งแรกของปี 2022 ใช้ในการผลิตเครื่องประดับคิดเป็นประมาณ 44% ของอุปสงค์ทองคำรวม อ้างอิงจาก World Gold Council ประเทศอินเดีย ประเทศจีน และสหรัฐอเมริกาเป็นผู้บริโภคทองคำสำหรับเครื่องประดับในปริมาณที่มากที่สุด 3 อันดับแรก ส่วนอุปสงค์ทองคำอีก 7.5% ถูกนำไปใช้ในวงการเทคโนโลยีและวงการเครื่องมือแพทย์ ราคาทองคำอาจได้รับผลกระทบจากทฤษฎีพื้นฐานของอุปสงค์และอุปทาน เมื่อความต้องการสินค้าอุปโภคบริโภค เช่น อัญมณีและอิเล็กทรอนิกส์เพิ่มขึ้น ราคาทองคำอาจมีแนวโน้มสูงขึ้น

7) ปริมาณการถือครองทองคำของกองทุนรวม Exchange-traded Funds (ETFs)

กองทุนรวมดัชนี หรือ ETFs เป็นหลักทรัพย์ (Security) ประเภทหนึ่งที่สามารถซื้อขายในตลาดหลักทรัพย์ได้เช่นเดียวกับหุ้นทั่วไป ETF ตัวแรกคือ Standard & Poor's Depository Receipts มีชื่อย่อว่า SPDR S&P500 ETF (SPY) ซึ่งติดตามดัชนี S&P500 และยังคงเป็น ETF ที่มีการซื้อขายอย่างคล่องตัวในปัจจุบัน การเคลื่อนไหวของกองทุนรวม ETFs ทองคำเป็นเครื่องมือที่นักลงทุนใช้เพื่อติดตามและสะท้อนราคาทองคำ



รูปที่ 12: ความสัมพันธ์ระหว่างราคาทองคำและจำนวนหุ้นที่กองทุน SPDR Gold Share ถือครอง
ช่วงเวลาตั้งแต่ ธันวาคม 2019 ถึง พฤศจิกายน 2020

(ที่มา: <https://seekingalpha.com/article/4395202-gld-why-2021-will-be-breakout-year-for-gold>)

ข้อมูลข่าวสารที่มีผลต่อราคาทองคำ ได้แก่ ข่าวเศรษฐกิจ ข่าวสงคราม ข่าวการเมือง ซึ่งข่าวเศรษฐกิจที่มีผลต่อราคาทองคำมากที่สุด ส่วนมากมาจากตัวเลขทางเศรษฐกิจของสหรัฐอเมริกา โดยสาเหตุเพราะว่าข่าวเศรษฐกิจสหรัฐฯ มีผลต่อราคาทองคำ เพราะว่าขนาดเศรษฐกิจของสหรัฐมีขนาดใหญ่เป็นอันดับ 1 ของโลก และหลายประเทศยังคงต้องพึ่งพิงเศรษฐกิจของสหรัฐฯเป็นหลัก เมื่อตัวเลขทางเศรษฐกิจของสหรัฐฯออกมาดี จะส่งผลให้เกิดความเชื่อมั่นที่ดีกับนักลงทุนโดยนักลงทุนจะให้ความสนใจเข้าซื้อหุ้นและนำเงินไปลงทุน ซึ่งส่งผลลบต่อราคาทองคำ เพราะเป็นช่วงเวลาที่นักลงทุนส่วนมากขายทองคำที่ถือครองอยู่ เพื่อนำเงินไปลงทุนในสินทรัพย์ที่ให้ผลตอบแทนสูงกว่า ในทางกลับกันเมื่อตัวเลขทางเศรษฐกิจของสหรัฐฯออกมาไม่ดี หรือมีเหตุการณ์ที่ส่งผลต่อเสถียรภาพเศรษฐกิจ หรือเกิดความไม่มั่นคงทางการเมือง จะส่งผลให้นักลงทุนขาดความเชื่อมั่น เกิดความกลัวที่จะถือสินทรัพย์ที่ไม่มั่นคง เช่น หุ้น สกุลเงินต่างชาติ นักลงทุนส่วนมากตัดสินใจขายหุ้น และหันความสนใจไปซื้อสินทรัพย์ปลอดภัยอย่างทองคำ ซึ่งส่งผลบวกต่อราคาทองคำ

ตารางที่ 3: เปรียบเทียบผลกระทบต่อทองคำด้านบวกและด้านลบ

| ข่าวที่ส่งผลบวกต่อราคาทอง | ข่าวที่ส่งผลลบต่อราคาทอง |
|---|--|
| ข่าวสงคราม ที่มีประเทศมหาอำนาจร่วมด้วย | ธนาคารกลางสหรัฐมีมติขึ้นอัตราดอกเบี้ย |
| จำนวนผู้ขอรับสวัสดิการการว่างงานเพิ่มขึ้น | จำนวนผู้ขอรับสวัสดิการการว่างงานลดลง |
| การจ้างงานนอกภาคการเกษตร (Non-farm payrolls) ลดลง | การจ้างงานนอกภาคการเกษตร (Non-farm payrolls) เพิ่มขึ้น |
| GDP หรือ ผลิตภัณฑ์มวลรวมในประเทศ ลดลง | GDP หรือ ผลิตภัณฑ์มวลรวมในประเทศเพิ่มขึ้น |
| ดัชนีตลาดหุ้นสหรัฐปิดในแดนลบ | ดัชนีตลาดหุ้นสหรัฐปิดในแดนบวก |

จะเห็นได้ว่าข่าวมีผลต่อราคาทองคำเสมอ เพราะการตอบสนองการรับรู้ข่าวสารของมนุษย์ ถูกถ่ายทอดออกมาเป็นความรู้สึก โดยมีความรู้สึกที่ดีต่อตัวเลขเศรษฐกิจที่ออกมาดี และมีความกลัวต่อข่าวที่ส่งผลกระทบต่อการลงทุน

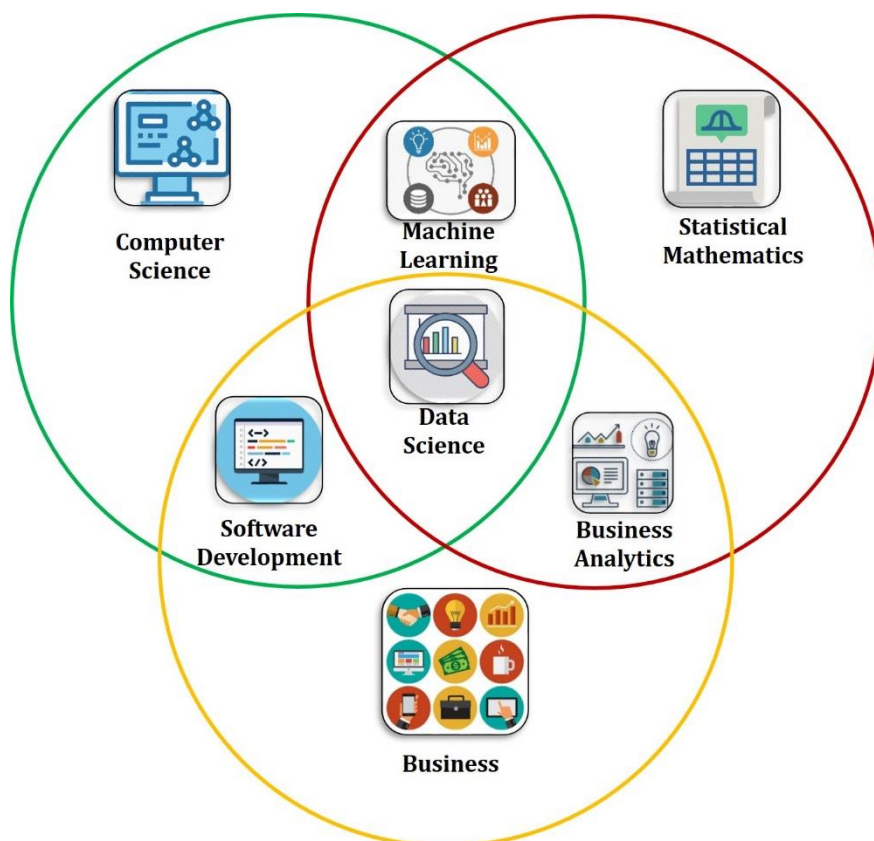
2.3 เทคนิคการวิเคราะห์ข้อมูล (Data Analysis Techniques)

Python คือเป็นภาษาที่เป็นที่นิยม และมีความสามารถรอบด้าน เป็นภาษาที่สามารถใช้พัฒนาเว็บด้านวิทยาศาสตร์ข้อมูล ด้านปัญญาประดิษฐ์ แอปพลิเคชันระดับองค์กร (Enterprise application) พัฒนาเกมส์ การสร้าง GUI (Graphical user interface) ระบบปฏิบัติการ (Operating system) มีนักเขียนโปรแกรม รวมถึงผู้พัฒนาหลาย ๆ ท่านนำคำสั่งต่าง ๆ ของ Python มาสร้างเป็นชุดคำสั่งหรือเป็น Package เพื่อให้สามารถทำงานตามวัตถุประสงค์แต่ละด้านได้อย่างมีประสิทธิภาพ โดยเรียกสิ่งนี้ว่า “Python Library”

การเรียนรู้ด้วยเครื่อง (Machine Learning)

การเรียนรู้ของเครื่องเป็นพื้นฐานเกี่ยวกับการสกัดค่าจากชุดข้อมูลขนาดใหญ่เพื่อนำมาวิเคราะห์ในสิ่งที่สนใจ นำมาใช้ในการวิจัยโดยวางอัลกอริทึมให้โมเดลหรือตัวแบบทำงานอัตโนมัติ ส่วนมากแรงจูงใจคือการสร้างอัลกอริทึมที่สามารถเลียนแบบหรือเพิ่มประสิทธิภาพการวิเคราะห์แทนมนุษย์หรือทางชีวภาพได้ ขอบเขตของการเรียนรู้ด้วยเครื่องรวบรวมศาสตร์ของสถิติและความรู้ด้านแบบจำลองทางคณิตศาสตร์ เพื่อเน้นการคาดการณ์หรือพยากรณ์ในสิ่งที่สนใจและนำไปใช้ประโยชน์

ปัจจุบันการเรียนรู้ของเครื่องยังเป็นส่วนหนึ่งของวิทยาการคอมพิวเตอร์ที่เกี่ยวข้องกับการประมวลผลข้อมูลขนาดใหญ่ (Large-scale information processing)



รูปที่ 13: ขอบเขตศาสตร์ความรู้ของ Machine Learning

([https://www.shiksha.com/it-software/articles/data-science-career-and-future-scope-](https://www.shiksha.com/it-software/articles/data-science-career-and-future-scope-blogId-26453)

[blogId-26453](https://www.shiksha.com/it-software/articles/data-science-career-and-future-scope-blogId-26453))

จากภาพรูปที่ 13 จะเห็นว่าการเรียนรู้ของเครื่องเป็นศาสตร์ร่วมของสถิติ คณิตศาสตร์ และ วิทยาการคอมพิวเตอร์ โดยมีเทคนิคการวิเคราะห์มากมาย เทคนิคส่วนมากมีอัลกอริทึมที่รับข้อมูลเข้ามาเรียนรู้

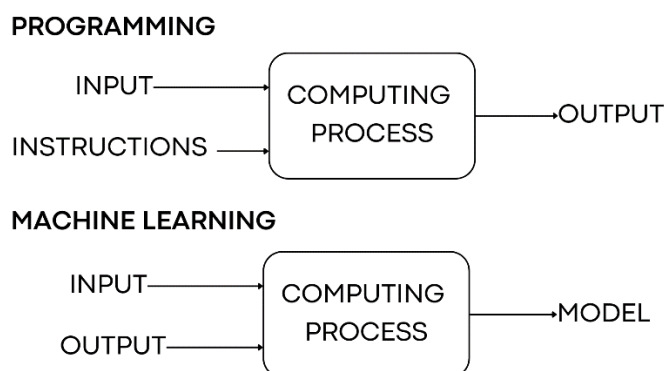
เทคนิคการเรียนรู้ของเครื่อง แบ่งออกเป็น 2 วิธี คือ

1) การเรียนรู้แบบมีผู้สอน (Supervised learning) เป็นเทคนิคที่เน้นเพื่อฝึกอัลกอริทึมให้ทำงานอย่างเฉพาะ โดยเรียนรู้จากชุดข้อมูลที่มีเป้าหมาย (Target) ที่แน่นอน

2) การเรียนรู้แบบไม่มีผู้สอน (Unsupervised learning) เป็นรูปแบบการเรียนรู้โดยที่ข้อมูลนำเข้า (Input) ทั้งหมดนั้นไม่มีการแบ่งประเภทและอัลกอริทึมต้องสร้างโครงสร้างจากข้อมูลนำเข้า

ด้วยตัวเอง เช่นการวิเคราะห์การจัดกลุ่ม (Cluster) เป็นการค้นหาการจัดกลุ่มภายในชุดข้อมูลนำเข้า หรือโครงข่ายประสาทเทียม (Neural networks) มีเป้าหมายเพื่อค้นหารูปแบบการอยู่ร่วมกันของข้อมูล

เทคนิคการเรียนรู้ของเครื่องแตกต่างจากการเขียนโปรแกรมทั่วไป การโปรแกรม (Programming) ปฏิบัติการโดยใส่ข้อมูล (Input data) และ ชุดคำสั่ง (Instruction set) ผ่านเข้ากระบวนการคำนวณ (Computing process) เพื่อให้ได้ผลลัพธ์ (Output) ในขณะที่การเรียนรู้ด้วยเครื่อง ปฏิบัติการโดยใส่ input และ output เข้ากระบวนการคำนวณ (Computing process) และเรียนรู้เพื่อหาฟังก์ชัน (Function) หรือตัวแบบ (Model) ที่เป็น Black-box หรือสมการ ที่จะนำไปใช้ตอบผลลัพธ์ในอนาคตได้ เมื่อผู้ใช้ใส่ข้อมูลนำเข้าใหม่เข้าตัวแบบ



รูปที่ 14: ข้อแตกต่างของแนวคิดและกระบวนการระหว่างการโปรแกรมกับการเรียนรู้ของเครื่อง

แนวคิดการเรียนรู้จากข้อมูล input และ output ที่ถูกป้อนเข้าป็นั้นพบว่าเป็นแนวคิดที่มีความแตกต่างระหว่างข้อมูลที่ใช้ในการฝึกหรือข้อมูลต้นแบบ (Train data) โมเดลและข้อมูลที่ใช้ในทดสอบประสิทธิภาพของโมเดลที่ผ่านการฝึก (Test data) เนื่องจากมีข้อมูล 2 ชุดจากที่กล่าวมา พารามิเตอร์ของโมเดลจะถูกตั้งค่าตามชุดข้อมูลที่ใช้ในการฝึกเท่านั้น ส่วนชุดข้อมูลที่ใช้ทดสอบถูกสร้างขึ้นจากกระบวนการที่มีรากฐานเดียวกันกับชุดข้อมูลที่ใช้ในการฝึก และค่าประมาณที่ไม่เอนเอียง (Unbiased estimate) ของประสิทธิภาพการทำงานสามารถรับได้โดยการวัดประสิทธิภาพข้อมูลที่ใช้ทดสอบของโมเดลที่ผ่านการฝึก ที่สำคัญประสิทธิภาพการทดสอบไม่ควรนำไปเพื่อปรับพารามิเตอร์ของโมเดล

โมเดลที่ใช้ในการศึกษางานวิจัยนี้

1) ต้นไม้ตัดสินใจ (Decision Trees, DTs)

ต้นไม้ตัดสินใจ เป็นวิธีการจัดการกระบวนการตัดสินใจตามลำดับในรูปแบบโครงสร้างผังงาน (Flowchart structure) ประกอบด้วย โหนดการตัดสินใจ (Decision nodes) แต่ละโหนดมีกิ่ง (Branches) ที่มีทางเลือก สอดคล้องกับการทดสอบตามโหนดคุณลักษณะ (Chance nodes) เปรียบได้กับตัวแปรสุ่ม (Random variables) ปรากฏตามลำต้นของต้นไม้ที่มีหน้าที่คำนวณค่ายูทิลิตี้ที่ใบ (Leaves) ของแต่ละกิ่ง ค่าคาดหวังยูทิลิตี้ของแต่ละการตัดสินใจจะถูกคำนวณโดยพื้นฐานของผลรวมถ่วงน้ำหนักกิ่งทั้งหมดจากการตัดสินใจไปยังใบทุกๆใบที่อยู่บนกิ่งนั้น

ส่วนประกอบต่างๆของต้นไม้ตัดสินใจ


1.1 Root node คือจุดเริ่มต้นของต้นไม้ตัดสินใจ แสดงถึงชุดข้อมูลที่แบ่งออกเป็นสองชุดหรือมากกว่าที่เปรียบเทียบกันได้

1.2 Leaf Node แสดงผลลัพธ์สุดท้าย อัลกอริทึมจะไม่สามารถแบ่งแยกกิ่งต้นไม้ต่อได้อีก

1.3 Parent and child node คือ Root node โหนดย่อยของ Parent node คือ Child node

1.4 Branch node หรือ Internal node คือโหนดที่แตกออกจากต้นไม้หลักทำให้เกิดกิ่งและ Child node โดยแตกกิ่งนั้นจะแตกเป็นจำนวนเท่ากับจำนวนค่าของคุณลักษณะในโหนดภายในนั้น


การใช้ต้นไม้ตัดสินใจสามารถใช้ได้ 2 ประเภทงานหลัก คือ งานการจำแนกประเภท (Classification) และงานการหาความสัมพันธ์เพื่อการพยากรณ์ (Regression) งานวิจัยนี้จะเน้นการจำแนกประเภท



รูปที่ 15: ตัวอย่างโครงสร้างต้นไม้ตัดสินใจ

(ที่มา <https://www.machinelearningnuggets.com/decision-trees-and-random-forests/>)

อัลกอริทึมที่ใช้ในการสร้าง Decision tree ดำเนินการจากบนลงล่างโดยการแบ่ง Root node (Decision node) ออกเป็นโหนดย่อยที่แตกต่างกันตามเงื่อนไขเพื่อค้นพบจุดที่ข้อมูลชุดนั้นถูกแบ่งประเภทออกอย่างบริสุทธิ์ที่สุด ขั้นตอนการแตกโหนด เรียกว่า Splitting อธิบายอย่างง่ายคือ อัลกอริทึมของ Decision trees จะสร้างเกณฑ์การแบ่งประเภทโหนดต่าง ๆ เพื่อได้โหนดผลลัพธ์ที่มีความกลมกลืนมากที่สุดเท่าที่จะเป็นไปได้



รูปที่ 16: ตัวอย่างอัลกอริทึม Decision Trees ทำการแบ่ง Internal Node เพื่อให้ได้ Leaf Node

จากรูปที่ 16 พบว่าโหนดที่ 1 เป็นจุดสีฟ้าและสีแดงผสมกันเท่าๆ กัน และเป็นโหนดที่ไม่บริสุทธิ์ที่สุด ส่วนโหนดที่ 3 เป็นสีฟ้าทั้งหมดและเป็นจุดข้อมูลที่บริสุทธิ์ที่สุด

แนวความคิดสร้างต้นไม้ตัดสินใจ มาจากการใช้อัลกอริทึมหลายแบบ ดังต่อไปนี้

1.1) แนวคิด Entropy

Entropy เป็นการวัดความไม่บริสุทธิ์ (Impurity) วัดความไม่แน่นอน หรือการสุ่ม (Randomness) ของชุดข้อมูล โดยทั่วไปจะใช้เพื่อประเมินคุณภาพของการแบ่งในต้นไม้ตัดสินใจ แนวคิดนี้มีจุดประสงค์เพื่อให้ได้ Leaf node ที่กลมกลืนกันหรือบริสุทธิ์ (Entropy ต่ำ) ซึ่งมีประโยชน์สำหรับการคาดการณ์ที่แม่นยำ ไม่เช่นนั้นจะเกิดชุด โหนดย่อยผสมหรือไม่กลมกลืนกัน (Entropy สูง) แต่หากพบว่า Entropy เท่ากับ 0 หมายถึงกรณีตัวอย่างการตัดสินใจนั้นมีเพียง 1 คลาส (1 ทางเลือก)

1.2) แนวคิดของ Information Gain

การสร้างโมเดลต้นไม้ตัดสินใจนั้นการเลือกฟีเจอร์หรือตัวแปรทำนาย (Predictor) ที่เหมาะสมมีความสำคัญมาก ในขณะที่อัลกอริทึมต้นไม้จำแนกตามค่า Information gain จากฟีเจอร์ที่สูงที่สุดไปจนถึง Child node ที่บริสุทธิ์ทั้งหมดหรือจนกว่า Information gain = 0 ซึ่งแนวคิดนี้พัฒนามาจากหลักการการลดค่า Entropy การคำนวณค่า Information gain มาจากส่วนต่างของ ค่า Entropy ก่อนแบ่งโหนด และ ค่า Entropy หลังแบ่งโหนด

หากบางกรณีการคำนวณค่อนข้างซับซ้อนทำให้อัลกอริทึมทำงานหนักหรืออาจเกิดปัญหา Overfitting (การปล่อยให้โมเดลเรียนรู้ชุดข้อมูลฝึกฝนมากเกินไป) จึงเป็นที่มาของแนวความคิดการตัดแต่งกิ่ง (Pruning) เป็นขั้นการตัดกิ่งต้นไม้ เพื่อช่วยในการประมวลผลเร็วขึ้นโดยไม่ต้องผ่านการคำนวณกิ่งที่ไม่เกี่ยวข้อง

1.3) แนวคิด Gini Index

ค่า Gini ในแต่ละโหนดเป็นตัวที่ใช้วัดความ Impurity ของคุณลักษณะ (Attribute / Feature) หากโหนดใดบริสุทธิ์ ค่า Gini เท่ากับ 0 พบได้ในกรณีที่ชุดข้อมูล Training set นั้นเป็นข้อมูลที่มี Class เหมือนกันทั้งหมด การคำนวณค่า Gini จะได้ผลลัพธ์เร็วกว่าและยังเป็นค่ามาตรฐานที่ถูกกำหนดไว้ (Default) ของ Library Scikit-learn นอกจากนี้ ค่า Gini ทำการแบ่ง Class ที่พบบ่อยในแต่ละกิ่ง แต่ Entropy จะพยายามสร้างความ balance ให้กับต้นไม้

1.4) การใช้ CHAID (Chi-square Automatic Interaction Detection)

อัลกอริทึม CHAID (Kass, 1980) ใช้สร้าง decision trees โดยพิจารณาจากค่า p-value จากการทดสอบความเป็นอิสระระหว่างตัวแปรของตัวสถิติ Chi-Square เป็นตัวคัดเลือกตัวแปรสำหรับการแยกโหนด เมื่อทำการแยกโหนด Attribute ที่สร้างค่า p-value ที่น้อยที่สุดจะถูกเลือก เพราะว่าค่า p-value ที่น้อยจะมีค่านัยสำคัญสูงขึ้น

2) นาอิว เบย์ (Naïve Bayes)

นาอิว เบย์ ใช้สำหรับโมเดลการจำแนกที่มีความคล้ายกับโมเดลเชิงเส้น (linear model) เป็นเทคนิคหนึ่งในการจำแนกประเภทข้อมูลด้วยความน่าจะเป็นอย่างตรงไปตรงมา และงานวิจัยส่วนใหญ่ใช้โมเดลนาอิว เบย์ เพราะเป็นเทคนิคที่เข้าใจง่าย และมีประสิทธิภาพเพราะมีการปรับค่าพารามิเตอร์ด้วยการสังเกตและรวบรวมจากค่าสถิติเบื้องต้นของแต่ละฟีเจอร์

เริ่มมีการศึกษาใช้นาอิว เบย์ กันอย่างแพร่หลายตั้งแต่ทศวรรษ 1960 ในกลุ่มงานวิจัยที่เกี่ยวข้องกับการสืบค้นข้อความในเอกสารต่าง ๆ นิยมสำหรับการจัดประเภทข้อความ การพิจารณาการจำแนกประเภทเอกสาร และยังมีนำไปประยุกต์ใช้กับงานด้านการจัดกลุ่มเอกสารตามจำนวนความถี่ของคำศัพท์สำคัญที่ต้องการค้นในเอกสารต่าง ๆ ซึ่งจำนวนความถี่ของคำศัพท์เป็นคุณลักษณะ (Attribute) ที่เหมาะสม สำหรับนำไปใช้ในการประมวลผลข้อมูลเอกสารเบื้องต้น ข้อดีของเทคนิคนาอิว เบย์ อีกประการหนึ่งคือต้องการข้อมูลที่ใช้ในการฝึกจำนวนไม่มากเพื่อการประมาณค่าพารามิเตอร์มาจำเป็นสำหรับการจำแนกประเภท (สุปัญญา อภิวงศ์โสภณ, 2561)

ที่มาของโมเดลมาจากกฎของเบย์ (Bayes) มีหลักการพื้นฐานจากการคำนวณความน่าจะเป็นแบบมีเงื่อนไข (Conditional probability) ภายใต้สมมติฐานว่าข้อมูลทุกคุณลักษณะต้องเป็นอิสระต่อกัน

$$P(X|Y) = \frac{P(X \cap Y)}{P(Y)} \quad (1)$$

โดย $P(X|Y)$ คือ ค่าความน่าจะเป็นที่เกิดเหตุการณ์ Y ขึ้นก่อนและมีเหตุการณ์ X เกิดตามมา

$P(X \cap Y)$ คือ ค่าความน่าจะเป็นร่วม (Joint probability) ของเหตุการณ์ X และเหตุการณ์ Y

$P(Y)$ คือ ค่าความน่าจะเป็นที่เหตุการณ์ Y เกิดขึ้น

ในลักษณะเดียวกันเราสามารถเขียนให้อยู่ในรูป $P(Y|X)$ หรือค่าความน่าจะเป็นที่เกิดเหตุการณ์ X ขึ้นก่อนและมีเหตุการณ์ Y เกิดตามมา จะได้สมการ $P(Y|X) = \frac{P(Y \cap X)}{P(X)}$ (2)

โดยที่ $P(X)$ คือ ค่าความน่าจะเป็นที่เหตุการณ์ X เกิดขึ้น

จากสมการ (1) และ (2) จะเห็นว่า $P(X \cap Y) = P(Y \cap X)$

โดยที่ $P(Y \cap X)$ หมายถึง ค่าความน่าจะเป็นร่วม (Joint probability) ของเหตุการณ์ X และเหตุการณ์ Y เช่นเดียวกัน ดังนั้นเราสามารถเขียนให้อยู่ในรูป


$$P(X \cap Y) = P(X|Y) \times P(Y) = P(Y|X) \times P(X)$$

$$P(Y|X) = \frac{P(X|Y) \times P(Y)}{P(X)}$$

นาอีฟ เบย์ มี 3 ประเภทคือ GaussianNB, BernoulliNB และ MultinomialNB การประยุกต์ใช้ GaussianNB เหมาะสำหรับข้อมูลเชิงปริมาณ BernoulliNB เหมาะสำหรับข้อมูลประเภท Binary ส่วน MultinomialNB เหมาะสำหรับข้อมูลที่ได้จากการนับ (Count data) ซึ่งทั้ง 3 ประเภทล้วนนำมาใช้กับการจำแนกข้อมูลประเภทข้อความได้

3) การถดถอยโลจิสติก (Logistic Regression)

การถดถอยโลจิสติกเป็นโมเดลที่กำเนิดมาเพื่อแก้ไขการถดถอยเชิงเส้น เป็นเทคนิคการจำแนกประเภทข้อมูลที่ binary นอกจากนี้ยังสามารถใช้กับข้อมูลประเภทต่างๆ และสามารถระบุตัวแปรที่มีประสิทธิภาพสูงสุดที่ใช้ในการจำแนกประเภทได้ ตัวโมเดลมีความเกี่ยวข้องกับตัวแปรอิสระกลุ่มหนึ่ง X_1, X_2, X_3, \dots การถดถอยโลจิสติกเป็นฟังก์ชันรูปตัว “S” ที่ให้ค่าทำนายอยู่ในช่วง 0 ถึง 1



รูปที่ 17: ตัวอย่าง Logistic Sigmoid Function

(ที่มา <https://www.javatpoint.com/logistic-regression-in-machine-learning>)

Sigmoid function เป็นฟังก์ชันที่ใช้ในการจับคู่ค่าที่ทำนายกับความน่าจะเป็น โดยจะมีค่าของฟังก์ชันอยู่ระหว่าง 0 ถึง 1 ซึ่งมาจากแนวคิดของค่าเกณฑ์ (Threshold value) ที่กำหนดความน่าจะเป็นเป็น 0 หรือ 1 เช่น ค่าที่สูงกว่าค่าเกณฑ์มีแนวโน้มเป็น 1 และค่าที่ต่ำกว่าค่าเกณฑ์มีแนวโน้มเป็น 0

Sigmoid function เขียนแทนด้วย $\sigma_{\beta}(x) = \frac{1}{(1 + e^{-\beta x})}$ โดยที่ค่า Parameter β หมายถึงความชัน (Steepness) ของ Sigmoid

สมมติสถานการณ์ข้อมูลชุดฝึกฝนใดๆ $D = \{(x^n, c^n), n = 1 \dots, N\}$ โดยที่ Target $c \in \{0,1\}$ จากชุดข้อมูลนี้หากต้องการกำหนดค่าความน่าจะเป็นที่ตัวแปร x จะถูกแบ่งอยู่ใน class 1 มีค่าเท่ากับ $p(c = 1|x) = f(x^T w)$ โดยที่ $0 \leq f(x) \leq 1$ ซึ่งในทางสถิติ $f(x)$ คือค่าของฟังก์ชัน (Mean function) และอินเวอร์สของฟังก์ชัน $f^{-1}(x)$ คือ ฟังก์ชันเชื่อมโยง (Link function)

ฟังก์ชัน $f(x)$ จัดให้อยู่ในรูปการหาค่าระหว่างช่วง 0 ถึง 1 จะถูกเรียกว่า Logistic Sigmoid หรือ


Logit เขียนแทนด้วย $f(x) = \frac{e^x}{1+e^x} = \frac{1}{1+e^{-x}}$ จากนั้นนำมาเขียนให้อยู่ในรูป scalar จะได้ $\sigma_{\beta}(x) = \sigma(\beta x)$

4) เครื่องเวกเตอร์ค้ำยัน (Support Vector Machines, SVM)

โมเดล SVM เป็นอัลกอริทึมเรียนรู้เพื่อหาค่าเหมาะสมที่สุด สามารถทำงานได้ดีกับข้อมูลที่ไม่รู้จัก การทำงานของอัลกอริทึมนี้คือ การหาเส้นระนาบที่เหมาะสมที่สุด เพื่อสร้างรูปแบบที่แบ่งแยกได้ในแนวเส้นตรง

การวิเคราะห์การจำแนกประเภทเชิงเส้น (Linear Discriminant) ในมิติหนึ่งถูกกำหนดด้วยระนาบเกิน (Hyperplanes, H) โดยพิจารณาจากรูปฟังก์ชัน

$$H(x_i) = (w \cdot x_i) + b$$



รูปที่ 18: SVM Classification ของข้อมูลใดๆ 2 Class (วงกลมสีฟ้า และวงกลมสีแดง)

โดยที่ w คือ ค่าเวกเตอร์น้ำหนัก (Weights vector);

x_i คือ ค่าเวกเตอร์ใดๆ;

b คือ ค่าไบแอส (Bias) หรือระยะเลื่อนขนานจากจุดกำเนิด (รัฐพล ชูพรหม, 2561)

จากรูปที่ 22 สามารถเขียนให้อยู่ในรูปสมการ ดังต่อไปนี้

$$H_0: w \cdot x_i + b = 0$$

$$H_1: w \cdot x_i + b = +1$$

$$H_2: w \cdot x_i + b = -1$$

d_+ คือ ระยะที่สั้นที่สุดที่ใกล้ขีดจุด positive;

d_- คือ ระยะที่สั้นที่สุดที่ใกล้ขีดจุด negative

มาร์จิ้น (Margin of Separation /Gutter) คือช่วงของ $(d_+) + (d_-) = d$ บนระนาบ H

อัลกอริทึมของการหาค่าเหมาะสมที่สุดคือการจัดการหาค่าเหมาะสมให้ hyperplane หรือขยายมาร์จิ้นให้กว้างพอที่จะแบ่งชุดข้อมูลได้ ทำได้โดยการลดค่า $\|w\|$ โดยมีเงื่อนไขว่า

$$w \cdot x_i + b > 0 \text{ เมื่อ } y_i = +1$$

$$w \cdot x_i + b < 0 \text{ เมื่อ } y_i = -1$$

เขียนเป็นเงื่อนไขรวมได้ว่า $y_i(w \cdot x_i) \geq 1$ เมื่อ y_i คือ ผลลัพธ์ หรือ Output ของฟังก์ชัน

2.4 การประมวลผลภาษาธรรมชาติ (Natural Language Processing, NLP)

การประมวลผลภาษาธรรมชาติ เป็นเทคนิคที่ใช้มาก ซึ่งมีวัตถุประสงค์ ทำให้เครื่อง (คอมพิวเตอร์) เข้าใจภาษาเขียนของมนุษย์ เช่น การจัดหมวดหมู่ข้อความ การวิเคราะห์ความรู้สึก การตรวจจับสแปม หรือการจัดหมวดหมู่หัวข้อ

1) กรอบความคิดพื้นฐานของการประมวลผลภาษาธรรมชาติ

1.1) การลบคำ Stop words หมายถึงการตัดคำสามัญที่ใช้กันโดยทั่วไป ไม่มีความเฉพาะทาง ในข้อความภาษาอังกฤษ การตัดคำเหล่านี้ออกก่อนที่จะฝึกโมเดลเพื่อลดเวลาการประมวลผลและ

พื้นที่ดิสก์ และเพิ่มความแม่นยำในการเรียนรู้ของเครื่อง ปัจจุบันมีเครื่องมือสำเร็จรูปมากมายสามารถช่วยตัดคำ Stop words ของจากกลุ่มข้อความที่เตรียมไว้โดยไม่ต้องสร้างชุดคำสั่งเอง ในกรณีที่ใช้ภาษา Python ซึ่งมี Library หลายตัวช่วยจัดการขั้นตอนนี้ เช่น NLTK, Gensim, Spacy ซึ่งแต่ละ Library มี List ของคำ Stop words ที่ทั้งคล้ายและแตกต่างกัน Library ที่มีมานานและนิยมใช้กันมากที่สุดคือ NLTK (Usman Malik, 2020) ยกตัวอย่างคำ Stop words ในภาษาอังกฤษทั่วไปที่ เช่น a, am, any, been, by, can, couldn't, did, further, have, if, just, might, need, on, other, should, that'll, they, were, when, you ฯลฯ

1.2) Tokenization หมายถึงกระบวนการแบ่งข้อความ (Textual data) ออกเป็นหน่วยย่อย (Element) เช่น คำ, วลี, ประโยค หรือ สัญลักษณ์ เรียกโดยรวมว่า Token มีวัตถุประสงค์เพื่อให้ข้อความจากเดิมเป็นรูปแบบไม่มีโครงสร้าง (Unstructured data) สู่รูปแบบที่ได้สัดส่วนที่ทำให้เป็นโครงสร้าง (Structured data) ได้ สำหรับการวิเคราะห์ข้อความให้สื่อความหมายได้อย่างดี การแบ่งกลุ่มเป็น Token มีประเด็นที่ต้องพิจารณา มีดังนี้

1.2.1 อักษรคั่น (Delimiter) ซึ่งส่วนใหญ่จะเป็นช่องว่าง จะทำให้การเขียนคำเกิดความผิดพลาดตัวอย่างประโยค

ตารางที่ 4: ตัวอย่างประโยคหลังทำ Tokenization

| | | |
|---|-----------------------------------|--|
| 1 | Sean is going to China. | ["Sean", "is", "going", "to", "China", "."] |
| 2 | Sean is going to the Philippines. | ["Sean", "is", "going", "to", "the", "Philippines", "."] |

พบว่าประโยคที่ 1 เมื่อแตกประโยคออกเป็นคำ (Tokenize) จะไม่พบปัญหา เนื่องจากแต่ละ Element นับเป็น 1 คำ ส่วนประโยคที่ 2 จะพบว่าชื่อประเทศ The Philippines ถูกนับเป็น 1 คำแต่ประกอบด้วย 2 Element

1.2.2 เครื่องหมายวรรคตอน (Punctuation) แม้ว่า Tokenizers จำนวนมากจะทำการปรับเพื่อตัดทิ้งเครื่องหมายวรรคตอนออกไป แต่สำหรับการวิเคราะห์ความรู้สึก ข้อมูลที่มีค่าจำนวนมากสามารถวัดได้จากเครื่องหมายเหล่านี้ เช่น ! ให้ความรู้สึกด้านลบ หรือด้านบวกของประโยค ในขณะที่ ? อาจหมายถึงความไม่แน่นอน (ไม่มีความรู้สึก) ส่วนเครื่องหมาย “ , ‘ , [], () อาจ

หมายความว่าคำเหล่านั้นควรอยู่ด้วยกัน เช่นเดียวกับคำที่เป็นตัวหนา ตัวเอียง ชีตเส้นใต้ หรือ Hyperlink ดังนั้นจะต้องพิจารณาเครื่องหมายเหล่านี้

1.3) Word Normalization หมายถึงการจัดการคำทั้งหมดให้เป็นมาตรฐาน เช่น Stemming คือการตัดส่วนต่อท้ายของคำ (Affix) หรือ Lemmatization คือการแปลงคำให้กลับไปสู่รากเดิม

ตารางที่ 5: ตัวอย่างคำเปรียบเทียบข้อแตกต่างระหว่าง Stemming และ Lemmatization

| คำที่มาจากข้อมูล | Stemming | Lemmatization |
|------------------|----------|---------------|
| feet | feet | foot |
| are | are | be |
| city | citi | city |
| finally | fina | final |
| historical | histori | history |

อย่างไรก็ดี มีประเด็นที่ควรพิจารณาพิจารณาดังนี้

1.3.1 ตัวพิมพ์ใหญ่ควรทำให้เป็นมาตรฐานเป็นตัวพิมพ์เล็ก อาจยกเว้นตัวพิมพ์ใหญ่กลางประโยคที่อาจเป็นชื่อเฉพาะ (Proper name) เช่น ชื่อคน ชื่อสถานที่ ชื่อแบรนด์ ฯลฯ

1.3.2 เครื่องหมาย Apostrophe (') ยกตัวอย่างเช่น พบว่า Sean's phone หลังถูก tokenize ยังคงได้ความหมายครบถ้วน ["Sean", "phone"] แต่บางกรณี เช่น I'm, We're, They'd, don't ทำให้ยากต่อการตัดเครื่องหมาย

1.3.3 คำกำกวม (Ambiguous) เช่น sanction, bimonthly, cleave, overlook, ravel ฯลฯ

2) Token Representation

ผลผลิตจากขั้นตอนการเตรียมข้อมูลที่อยู่ในรูปข้อความ (Text preprocessing) คือ Token อย่างไรก็ตาม ยังคงอยู่ในรูปข้อความ ซึ่งยังไม่สามารถนำป้อนเข้าโมเดลการเรียนรู้ของเครื่องได้ นอกจากข้อมูลเชิงตัวเลข (Numerical feature) เท่านั้น โดยขั้นตอนการแปลงนี้อาจเรียกว่า Text Encoding ซึ่งมีหลายวิธีการ เช่น Bag-Of-Words, Bigrams, Trigrams, Term-Frequency Inverse-Document-Frequency (TF-IDF) ฯลฯ

Term-Frequency Inverse-Document-Frequency (TFIDF)

เนื่องจากการนับคำศัพท์ (Term) ถ้าพบว่าคำศัพท์คำหนึ่งมีจำนวนมาก ปรากฏหลายครั้งในเอกสาร อาจเป็นเพราะคำศัพท์นี้เป็นเพียงคำศัพท์ที่ใช้บ่อย ไม่จำเป็นว่ามีความเกี่ยวข้องหรือมีความหมาย เทคนิค TF-IDF เป็นการสร้างการนับคำศัพท์ให้อยู่ในระดับมาตรฐาน มาจาก TF และ IDF

TF (The Term Frequency) หรือความถี่ของคำศัพท์ในเอกสาร วิธีการคำนวณที่ง่ายที่สุดคือการนับคำทุกคำที่ปรากฏในเอกสาร นอกจากนี้ยังมีวิธีการปรับความถี่ ตัวอย่างเช่น โดยการหารจำนวนคำศัพท์ด้วยความยาวข้อความในเอกสาร หรือตามความถี่ของคำที่ปรากฏบ่อยที่สุดในเอกสาร สูตรคำนวณระยะความถี่

$$TF(t, d) = \frac{f(t, d)}{\sum_{t \in d} f(t, d)} = \frac{\text{ความถี่ของคำศัพท์แต่ละคำที่ปรากฏในเอกสาร}}{\text{จำนวนคำศัพท์ทั้งหมดในเอกสาร}}$$

โดยที่ t แทน คำศัพท์ (Term) และ d แทน เอกสาร (Document)

IDF (The Inverse Document Frequency) หรือส่วนกลับความถี่เอกสารของคำในชุดเอกสารทั้งหมด (D) ค่า IDF นี้ชี้ให้เห็นว่าคำธรรมดาหรือคำที่หายากในชุดเอกสารทั้งหมดเป็นอย่างไร ยิ่งเข้าใกล้ 0 มากหมายถึงคำนั้นยิ่งพบบ่อยมากขึ้น IDF Matrix สามารถคำนวณได้จากสูตร

$$IDF(t, D) = \log\left(\frac{N_D}{df(t)}\right)$$

โดยที่ N_D คือจำนวนเอกสารทั้งหมด และ $df(t)$ คือจำนวนเอกสารที่มีคำศัพท์ (t)

การหาค่า TF-IDF หาได้จากสูตร

$$TF - IDF = TF \times IDF$$

ตัวอย่างเทคนิค TF-IDF

ตัวอย่างข้อความจากหนังสือ “Living Death” โดย Graham Masterton

“She tried to calm herself.”

“She couldn’t help herself from liking him.”

“She couldn’t take John, and equally she couldn’t leave him here.”

เมื่อผ่านขั้นตอนการแปลงทุกตัวอักษรให้เป็นตัวพิมพ์เล็ก และ text encoding โดยการแปลงคำศัพท์ตามลำดับ token จะได้

```
In [1]: from sklearn.feature_extraction.text import CountVectorizer
```

```
In [2]: corpus = [
    "She tried to calm herself.",
    "She couldn't help herself from liking him.",
    "She couldn't take John, and equally she couldn't leave him here."
]
```

```
In [3]: vectorizer = CountVectorizer()
X = vectorizer.fit_transform(corpus)
vectorizer.get_feature_names_out()
```

```
Out[3]: array(['and', 'calm', 'couldn', 'equally', 'from', 'help', 'here',
             'herself', 'him', 'john', 'leave', 'liking', 'she', 'take', 'to',
             'tried'], dtype=object)
```

```
In [4]: print(vectorizer.vocabulary_)
```

```
{'she': 12, 'tried': 15, 'to': 14, 'calm': 1, 'herself': 7, 'couldn': 2, 'help': 5,
 'from': 4, 'liking': 11, 'him': 8, 'take': 13, 'john': 9, 'and': 0, 'equally': 3,
 'leave': 10, 'here': 6}
```

รูปที่ 19: ตัวอย่างการทำ CountVectorizer และ Text encoding คำศัพท์ในเอกสารจากข้อความ

ตัวอย่าง

แปลงการแสดงผลจำนวนค่าตามแถว Array ที่ได้จากเทคนิคข้างต้น ด้วยคำสั่ง print(X.toarray())

```
[[0 1 0 0 0 0 1 0 0 0 0 1 0 1 1]
 [0 0 1 0 1 1 0 1 1 0 0 1 1 0 0]
 [1 0 2 1 0 0 1 0 1 1 1 0 2 1 0]]
```

จากผลลัพธ์ข้างต้น ความยาวในแต่ละ List เท่ากับจำนวนค่าที่ปรากฏในเอกสาร จากตัวอย่าง ความยาวเท่ากับ 16

เอกสารแถวที่ 1: 1 ที่เกิดขึ้นในคอลัมน์ที่ 1 เป็นจำนวนคำว่า “calm” จำนวน 1 คำ

เอกสารแถวที่ 2: 0 ที่เกิดขึ้นในคอลัมน์ที่ 3 เป็นจำนวนคำว่า “equally” จำนวน 0 คำ

เอกสารแถวที่ 3: 2 ที่เกิดขึ้นในคอลัมน์ที่ 2 เป็นจำนวนคำว่า “couldn’t” จำนวน 2 คำ

```
In [6]: from sklearn.feature_extraction.text import TfidfVectorizer
vec = TfidfVectorizer()
vec.fit(corpus)
print(vec.idf_)
```

```
[1.69314718 1.69314718 1.28768207 1.69314718 1.69314718 1.69314718
 1.69314718 1.28768207 1.28768207 1.69314718 1.69314718 1.69314718
 1.        1.69314718 1.69314718 1.69314718]
```

รูปที่ 20: ตัวอย่างการทำ TF-IDF คำศัพท์ในเอกสารจากข้อความตัวอย่าง

โดยที่สมาชิกใน List แสดงค่าตามลำดับอักขระภาษาอังกฤษและไม่ซ้ำกันในเอกสารหรือชุดข้อมูล ผลลัพธ์จากตัวอย่าง

- 1.69314718 คำนี้ที่อยู่ตำแหน่งที่ 0, 1, 3, 4, 5, 6, 9, 10, 11, 13, 14, 15 ตรงกับคำว่า “and”, “calm”, “equally”, “from”, “help”, “here”, “john”, “leave”, “liking”, “take”, “to”, “tried”
- 1.28768207 อยู่ตำแหน่งที่ 2, 7, 8 ตรงกับคำว่า “couldn’t”, “herself”, “him”
1. อยู่ตำแหน่งที่ 12 ตรงกับคำว่า “she”

2.5 การวัดประสิทธิภาพโมเดล (Model Evaluation)

การประเมินโมเดลการเรียนรู้ด้วยเครื่องเป็นสิ่งสำคัญ เพื่อใช้เป็นเครื่องยืนยันว่าโมเดลที่มีอยู่สามารถเรียนรู้ได้อย่างน่าเชื่อถือเพียงพอเพียงใด งานวิจัยของ (Al-Shabi, 2020) ใช้ค่า Accuracy, Precision, Recall และ F1-Score เพื่อวัดประสิทธิภาพของชุดข้อมูลและเครื่องมือที่ใช้ในการวิเคราะห์ความรู้สึก ซึ่งมีส่วนที่ใกล้เคียงกับงานวิจัยนี้ ผู้วิจัยจึงเลือกค่าวัดประสิทธิภาพ 4 ตัวดังกล่าวมาใช้เปรียบเทียบและประเมินประสิทธิภาพของโมเดลการจำแนกประเภทข้อความเพื่อคาดการณ์ทิศทางการเปลี่ยนแปลงราคาทองคำรายวัน และรายสัปดาห์ รวมถึงโมเดลวิเคราะห์การคาดการณ์ทิศทางการเปลี่ยนแปลงราคาทองคำรายวันนั้น

1) Confusion Matrix

สำหรับการประเมินโมเดลการจำแนก พิจารณาจากผลลัพธ์การคาดการณ์ (Predicted value) ที่ตรงและไม่ตรงกับค่าเป้าหมาย (Target value) จากนั้นแบ่งลงตาราง Confusion matrix

ตารางที่ 6: ตาราง Confusion Matrix

| | ACTUAL: NO | ACTUAL: YES |
|----------------|------------|-------------|
| PREDICTED: NO | TN | FN |
| PREDICTED: YES | FP | TP |

จากตารางที่กำหนดให้ผลลัพธ์ซึ่งกำลังสนใจอยู่คือ “YES” และผลลัพธ์ซึ่งไม่ได้สนใจอยู่คือ “NO” ค่าที่แสดงในตารางประกอบด้วย

TP (True Positive) บ่งบอกถึง จำนวนผลลัพธ์ที่คาดการณ์ถูกว่าเป็นผลลัพธ์ซึ่งกำลังสนใจอยู่

TN (True Negative) บ่งบอกถึง จำนวนผลลัพธ์ที่คาดการณ์ถูกว่าเป็นผลลัพธ์ซึ่งไม่ได้สนใจอยู่

FP (False Positive) บ่งบอกถึง จำนวนผลลัพธ์ที่คาดการณ์ผิดว่าเป็นผลลัพธ์ซึ่งกำลังสนใจอยู่

FN (False Negative) บ่งบอกถึง จำนวนผลลัพธ์ที่คาดการณ์ผิดว่าเป็นผลลัพธ์ซึ่งไม่ได้สนใจอยู่

2) ตัววัดประสิทธิภาพ

2.1) ค่าความถูกต้อง (Accuracy) สามารถบอกความถูกต้องของโมเดล โดยพิจารณาทุกค่าในตาราง Confusion matrix

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}$$

2.2) ค่าความแม่นยำ (Precision) บอกความแม่นยำของโมเดล โดยพิจารณาจากผลลัพธ์ที่คาดการณ์ว่าถูก (PREDICTED: YES)

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

2.3) ค่าระลึก (Recall หรือ Sensitivity) บอกความแม่นยำของโมเดล โดยพิจารณาจากผลลัพธ์ซึ่งกำลังสนใจ (ACTUAL: YES)

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

2.4) F-1 Score บอกความถูกต้องของโมเดล โดยพิจารณาจากผลลัพธ์ที่กำลังสนใจและไม่ได้สนใจ คำนวณจากค่าเฉลี่ยของค่า Precision และค่า Recall

$$F - 1 \text{ Score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

2.6 ความรู้สึกของการแพร่กระจายของข้อมูลในสื่อสังคมออนไลน์

ความรู้สึก (Sentiment) แพร่กระจายง่าย ซึ่งได้แนวคิดมาจาก การแพร่ติดต่อทางสังคม (Social contagious) หมายถึง แนวโน้มที่ทำให้เกิดการทำตามและทำในเวลาเดียวกัน ด้านการ แสดงออก การปลั่งเสียง ท่าทาง และการเคลื่อนไหวของบุคคลอื่นโดยอัตโนมัติ และครอบคลุมถึง เรื่องอารมณ์ (Sul, Dennis, & Yuan, 2017a) งานวิจัยยังเปิดเผยว่า โดยทั่วไปผู้สื่อข่าวที่อยู่ภาวะ Bullish บทวิเคราะห์นั้นจะมีผลกระทบต่อราคาในตลาดในเชิงบวก ในขณะที่บทวิเคราะห์ของผู้สื่อข่าวที่อยู่ภาวะ Bearish จะมีผลกระทบต่อราคาในตลาดในเชิงลบ (Peterson, 2016)

ดัชนีความเชื่อมั่นที่แม่นยำจากสื่อต่างๆ เช่น ข่าวและสื่อสังคมออนไลน์ จำเป็นต้องถูกสร้าง มาจากความเข้าใจอย่างถ่องแท้ถึงเป้าหมายและข้อจำกัดของการสื่อสารในแต่ละสื่อ โดยมี บรรณาธิการและผู้ตรวจสอบข้อเท็จจริงเนื้อหาบนสื่อต้องรับรองมาตรฐานของเนื้อหาข่าว ไม่หมิ่น ประมาทหรือเผยแพร่ข้อมูลที่ไม่ถูกต้อง ผลที่ตามมาคือ ผู้อ่านส่วนมากจะเชื่อเนื้อหาของบทความที่ เผยแพร่ โดยเฉพาะเนื้อหาที่ถูกเผยแพร่จากสำนักสื่อที่มีชื่อเสียง เช่น เนื้อหาสื่อด้านการลงทุนของ Reuters หรือ Bloomberg ภายใต้อิทธิพลที่เชื่อถือได้ แม้ว่าบทความเหล่านั้นจะมีเนื้อหาที่น่าสงสัย (Dubious content) ก็ตาม ผู้อ่านมักจะละเลยการคิดแบบมีวิจารณญาณเมื่อพวกเขาเชื่อถือ แหล่งข่าวจากสำนักสื่อที่มีชื่อเสียง (Peterson, 2016)

ปัจจุบันมีเทคโนโลยีที่พัฒนาอย่างต่อเนื่องและการเข้าถึงของอินเทอร์เน็ตเพิ่มขึ้นในวง กว้างขวางทำให้เกิด สังคมออนไลน์ (Social network) เป็นแหล่งที่ผู้คนทั่วไปสามารถทำความรู้จัก ร่วมแบ่งปันสิ่งที่มีความสนใจเหมือนกัน จนเกิดความเชื่อมโยงกันเป็นทิศทางบนโลกอินเทอร์เน็ต โดยมีรูปแบบการบริการแบบเครือข่ายที่เรียกว่า Social Networking Service (SNS) เช่น WeChat Line Tiktok Quora หรือ Twitter ศูนย์รวมเครือข่ายเหล่านี้ถูกเรียกว่า สื่อสังคมออนไลน์ (Social media) ประกอบด้วยเครื่องมือ เทคนิค และเทคโนโลยีที่ช่วยให้สามารถสื่อสารในรูปแบบ Digital platform (Sharma & Jain, 2020)

ไมโครบล็อกกิ้ง (Microblogging) เป็นแพลตฟอร์มสื่อออนไลน์ (Social media platform) ที่มีรูปแบบเฉพาะของบล็อก (Blog) ซึ่งไมโครบล็อกกิ้งยังเป็นเครื่องมือสื่อสารระหว่างผู้ใช้อินเทอร์เน็ต

ทั่วโลก โดยได้รับความสนใจในการใช้งานอย่างมากในปัจจุบัน มีมากกว่าล้านข้อความปรากฏในไมโครบล็อกของเว็บไซต์ที่นิยมในทุกวัน โดยผู้สร้างบล็อกจะเขียนเกี่ยวกับเรื่องราวชีวิต แบ่งปันความคิดหรือประสบการณ์ เล่าเรื่องหรือวิจารณ์ประเด็นในปัจจุบัน เนื่องจากมีผู้ใช้งานไมโคร บล็อกก็มากขึ้นไม่ว่าจะเป็นเรื่องผลิตภัณฑ์ การเมือง ศาสนา บ้านเหิง ฯลฯ ทำให้เวปเซอร์วิสที่ให้บริการไมโครบล็อกกลายเป็นแหล่งข้อมูลทางอารมณ์ของผู้คนที่สำคัญที่มีประโยชน์

ทวิตเตอร์ (Twitter) เป็นระบบไมโครบล็อกอันดับต้นๆของโลก เป็นสื่อสังคมออนไลน์ที่ใช้กันอย่างแพร่หลายในชีวิตประจำวัน “เครือข่ายสังคมออนไลน์ทวิตเตอร์ (Twitter) เป็นช่องทางการสื่อสารของข่าวทันเหตุการณ์ช่องทางหนึ่งที่ได้รับความนิยมในการกระจายข่าวสารต่างๆ อย่างรวดเร็ว ด้วยคุณลักษณะของทวิตเตอร์ที่สามารถส่งข้อความสั้นได้กระชับ ทำให้ผู้รับสามารถรับรู้ประเด็นสำคัญของข่าวได้โดยไม่เสียเวลามากนัก และสามารถส่งต่อให้ใครก็ได้อย่างรวดเร็ว” (สุปัญญา อภิวงค์โสภณ, 2561)

สำหรับงานวิจัยนี้แหล่งข้อมูลของสื่อสังคมออนไลน์มาจากทวิตเตอร์ โดย Liu, Kilman-Silver, & Mislove, 2014 อ้างถึง (Sul, Dennis, & Yuan, 2017b) อธิบายเกี่ยวกับทวิตเตอร์ว่า

ทวิตเตอร์ (Twitter) เป็นแพลตฟอร์มสื่อสังคมออนไลน์ (Social media) ที่ผู้ใช้โพสต์ข้อความสั้นไม่เกิน 140 ตัวอักษรเรียกว่า “ทวิต” (Tweets) ใครก็ตามสามารถเปิดบัญชีทวิตเตอร์ได้ และส่งทวิตได้ทันทีหลังเปิดบัญชี ผู้ใช้งานสามารถ “ซบสไครบ” (Subscribe) หรือ “ติดตาม” (Follow) ผู้ใช้รายอื่น และผู้ติดตาม (Followers) จะได้รับการแจ้งเตือนทันทีเมื่อผู้ใช้งานโพสต์ หรือทวิตข้อความ ผู้ใช้งานทวิตเตอร์จำนวนมากมีผู้ติดตามน้อย ขณะที่นักวิจารณ์ (Commentators) นักข่าว (Journalists) และคนดัง (Celebrities) มีผู้ติดตามหลายพันคนหรือมากกว่านั้น จำนวนผู้ติดตามโดยเฉลี่ยจะค่อยๆ เพิ่มขึ้นเมื่อเวลาผ่านไป ผู้ใช้งานทวิตเนอร์ส่วนใหญ่ติดตามผู้อื่นมากกว่าการมีผู้ติดตาม

2.7 บทบาทของสื่อสังคมออนไลน์ในตลาดการเงินและการลงทุน

เมื่อสองศตวรรษที่แล้วการรับรู้ข่าวสารเป็นข้อแตกต่างจากยุคปัจจุบัน จะเห็นว่าในยุคปัจจุบันการรับรู้ (Perceptions) เพิ่มโอกาสในการลงทุนซื้อขาย แสดงให้เห็นว่าการทำกำไรของนักลงทุนมี 2 วิธีการหลักคือ (1) รับข้อมูลที่สำคัญและรวดเร็วกว่าที่คนอื่น และ (2) รู้บริบทของข้อมูล (Context of information) หากเข้าใจถึงสิ่งที่กลุ่มนักลงทุนส่วนใหญ่เชื่อ ตกใจกลัว และคาดหวัง

อย่างไรอย่างหนึ่งจะทำให้คาดการณ์ได้ว่ากลุ่มนักลงทุนส่วนใหญ่มีแนวโน้มที่จะตอบสนองต่อข้อมูล และเหตุการณ์ใหม่อย่างไร ในอีกมุมมองหนึ่ง นักลงทุนใช้ข้อมูล (Information) เป็นพื้นฐานในการ ตัดสินใจการลงทุน

การตอบสนองต่อข้อมูลสามารถอธิบายได้ว่าความรู้สึกทางสังคม (Social sentiment) ที่ส่งผลกระทบต่อราคาสินทรัพย์ไม่ใช่เพียงสมมติฐานที่ถูกคาดการณ์โดยนักลงทุนที่มีความสามารถซึ่งตอนนี้มีหลักฐานที่ได้รับการพิสูจน์แล้วมาสนับสนุน การศึกษาจากชุดข้อมูลขนาดใหญ่และงานวิจัยเชิงวิชาการพบว่า การเปลี่ยนแปลงรูปแบบทางอารมณ์ระดับกลุ่มและรูปแบบความคิดส่งผลกระทบต่อราคาของหลักทรัพย์ใดๆ ในตลาดหลักทรัพย์ฯ เช่น เมื่อมีเหตุการณ์ประเทศหนึ่งพ่ายแพ้ในการแข่งขันรายการใหญ่ ราคาหุ้นในประเทศนั้นได้รับผลกระทบโดยตรง, เหตุการณ์ตกรอบในรอบตัดเชือกชิง World Cup Football นำไปสู่ราคาหุ้นในวันถัดไปร่วงลง 0.49 % ในประเทศต้นทางของทีมตกรอบ (Peterson, 2016)

มีงานวิจัยด้านจิตวิทยาสะท้อนอารมณ์และพฤติกรรมการลงทุน แสดงให้เห็นถึงความสัมพันธ์ระหว่างระยะเวลา 2 สัปดาห์หลังจากเกิดพายุแม่เหล็กโลก (Geomagnetic storms) และสัญญาณของภาวะซึมเศร้าในประชากรทั่วไป ภาวะซึมเศร้าเป็นความผิดปกติด้านอารมณ์ ที่มีส่วนจากความกลัวความเสี่ยง (Risk aversion) และนักวิจัยพบว่าพายุแม่เหล็กโลกรุนแรงทำให้ตลาดหุ้นทั่วโลกตกต่ำในช่วง 6 วันหลังจากเหตุการณ์ (Peterson, 2016)

นอกจากนี้นักวิจัย Kamstra, Kramer และ Levi (2003) พบว่า เวลาเปลี่ยนวันหยุดสุดสัปดาห์เป็นช่วงที่ตลาดปิดของวันศุกร์จนถึงเวลาตลาดเปิดวันจันทร์มักเกิดการได้รับผลตอบแทนจากหุ้นต่ำกว่าปกติ Peterson จึงตั้งสมมติฐานว่าประสิทธิภาพที่ลดลงนี้ อาจเกิดจากการตัดสินใจที่บกพร่องที่มาจาก การรบกวนการนอน สมมติฐานอาการที่เกิดจากการแปรปรวนต่อระบบนาฬิกาชีวภาพของร่างกาย หรือ Desynchronosis โดยเฉลี่ยในวันหยุดสุดสัปดาห์อาจอธิบาย "Monday Effect" โดยที่ราคาจะเพิ่มขึ้นโดยเฉลี่ยในวันจันทร์น้อยกว่าวันอื่นๆ ใน สัปดาห์ (Peterson, 2016)

จากหลากหลายตัวอย่างที่กล่าวข้างต้น ความแปลกของตลาดตามธรรมชาติเหล่านี้บอกล่าเรื่องราวที่น่าสนใจเกี่ยวกับผลกระทบของโลกธรรมชาติที่มีต่อพฤติกรรมของนักลงทุนโดยรวมและราคาตลาด

หากสถานะทางอารมณ์หรือความเชื่อมั่นของนักลงทุนสามารถคาดการณ์การเคลื่อนไหวของราคาตลาดได้ จึงมีคำถามว่าการวัดความเชื่อมั่นของนักลงทุนล่วงหน้าอย่างน่าเชื่อถือเพื่อทำนายราคา

ตลาดมีวิธีอย่างไร งานวิจัยทางวิชาการ ของ Baker–Wurgler กล่าวว่าดัชนีความเชื่อมั่น (Sentiment index) นับเป็นมาตรฐานอย่างดี เพราะ ดัชนีนี้ถูกวิเคราะห์มาจากข้อมูลในตลาดตราสารทุน ซึ่งตามปกติมีความผันแปร ดังนั้นดัชนีนี้ถูกจำกัดใช้เป็นมุมมองโดยรวมว่าเชิงบวกหรือเชิงลบในตลาดหลักทรัพย์ทั่วไป

การวิเคราะห์ความรู้สึก หรือดัชนีความเชื่อมั่น เป็นการมององค์ประกอบโดยรวม ณ ช่วงเวลาหนึ่ง ที่ควรจะต้องพิจารณาในการตัดสินใจลงทุน ว่ามีบรรยากาศเอื้ออำนวยหรือส่งผลกระทบต่อโอกาสในการลงทุนหรือไม่ ซึ่งอาจจะเป็นองค์ประกอบจากปัจจัยทางมหภาค เช่น ทิศทางของตลาดหลักทรัพย์ในต่างประเทศ กระแสเคลื่อนไหวของเงินทุนจากต่างชาติ (Fund flow) สภาพคล่องภายในประเทศ สภาวะเศรษฐกิจ ดัชนีความเชื่อมั่นในการลงทุน ดัชนีความเชื่อมั่นผู้บริโภค และองค์ประกอบทางด้านจิตวิทยาทางการลงทุนว่าช่วงเวลานั้นนักลงทุนมีความมั่นใจในการลงทุนมากน้อยแค่ไหน ซึ่งถ้า Sentiment ของการลงทุนดี นักลงทุนก็จะตัดสินใจลงทุนด้วยความสบายใจและมีโอกาสประสบความสำเร็จหรือได้รับผลตอบแทนเป็นที่น่าพอใจ (รัฐการ เปี่ยมพงศ์สานต์, 2559) สำหรับงานวิจัยนี้การวิเคราะห์ความรู้สึกจะถูกวัดออกมาในช่วง -1 ถึง 1 โดยที่ -1 หมายถึง ความรู้สึกในทิศทางที่ไม่ดี, 1 หมายถึง ความรู้สึกในทิศทางที่ดี และ 0 หมายถึง ความรู้สึกเป็นกลาง ข้อมูลการลงทุนส่วนมากที่ถูกแชร์ออกไปโดยใช้สื่อแบบดั้งเดิมและสื่อสังคมออนไลน์นั้นเป็นข้อเท็จจริงและเป็นความคิดเห็น แต่พฤติกรรมส่วนบุคคลไม่ได้เป็นเพียงผลลัพธ์ของการตัดสินใจอย่างมีเหตุผลเท่านั้น อารมณ์ถูกชักนำโดยข้อมูลและความคิดเห็นเหล่านั้นสามารถมีอิทธิพลต่อการตัดสินใจ (Sul et al., 2017b) ปัจจุบันมีงานวิจัยหลากหลายที่ได้ศึกษาความสัมพันธ์ระหว่างอารมณ์ของนักลงทุนกับพฤติกรรมการลงทุนในตลาดหลักทรัพย์ โดยงานวิจัยของ Nofsinger (2005) และ Gilbert et al. (2010) ศึกษาพบว่าอารมณ์มีอิทธิพลต่อการตัดสินใจของนักลงทุนในตลาดหลักทรัพย์

มีผลวิจัยชิ้นใหญ่ที่แสดงให้เห็นว่าสื่อสังคมออนไลน์ในภาพรวมนอกจากจะให้ข้อมูลแก่นักลงทุน ยังมีบทบาทสำคัญในความเชื่อมั่นของนักลงทุน ส่วนงานตีพิมพ์ที่เกี่ยวข้องกับ "ความรู้สึก" ให้เหตุผลว่าสื่อสังคมออนไลน์ส่งผลกระทบต่อผู้ใช้โดยตรงเนื่องจากผู้ใช้งานโซเชียลมีเดียอาจเป็นนักลงทุนรายย่อย เช่น งานวิจัยของ (Deng, Huang, Sinha, & Zhao, 2018) มีข้อคิดเห็นอย่างชัดเจนว่าสื่อสังคมออนไลน์จับความรู้สึกของผู้มีส่วนร่วมในตลาด (Market participants) ได้ ข้อมูลในสื่อออนไลน์ โดยเฉพาะในระดับรายชั่วโมง กระตุ้นให้ผู้ใช้งานสื่อออนไลน์มีการตอบสนองอย่างไม่ถูกต้องในตลาดหุ้น งานวิจัยของ (Renault, 2017) สรุปไว้ว่าความสัมพันธ์ระหว่างสื่อสังคมออนไลน์และผลตอบแทนจากหุ้น ส่วนใหญ่ได้รับกระแสมาจากความรู้สึกหรือทัศนคติของเทรดเดอร์มือใหม่

ตัวอย่างงานวิจัยของ (Mai, Shan, Bai, Wang, & Chiang, 2018) แสดงให้เห็นว่าความรู้สึกทางสื่อสังคมออนไลน์สามารถส่งผลกระทบต่อราคาบิตคอยน์ เนื่องจากผู้ใช้งานสื่อออนไลน์มีเดียอาจมีการซื้อขายบิตคอยน์ งานวิจัยของ (Ren, Dong, Padmanabhan, & Nickerson, 2021) จึงสรุปว่าไม่ใช่เรื่องน่าแปลกใจที่ความรู้สึกของสื่อสังคมออนไลน์จะส่งผลโดยตรงต่อผู้ใช้งานสื่อสังคมออนไลน์ และความเชื่อมั่นของสื่อสังคมออนไลน์เป็นตัวแทนของความรู้สึกของผู้มีส่วนร่วมในตลาด

วารสารของ Decision Sciences Institute ในปี 2016 เคยทำการวิจัยเกี่ยวกับการใช้ความรู้สึกบนสื่อสังคมออนไลน์คาดการณ์ผลตอบแทนจากหุ้น โดยได้ผลสรุปดังนี้

งานวิจัยพบว่าความรู้สึกของโพสต์บนสื่อสังคมออนไลน์สามารถคาดการณ์ผลตอบแทนของหุ้นในวันซื้อขายในอนาคตได้ โดยการทวิต (Tweet) หรือการโพสต์บน Twitter จากผู้ใช้ที่มีผู้ติดตามน้อยซึ่งไม่ได้ รีทวิต (Retweet) หรือ การตอบกลับบน Tweet จะส่งผลกระทบต่อผลตอบแทนในอนาคตในอีก 10 และ 20 วันต่อมา ในขณะที่การทวิตจากผู้ใช้ที่มีผู้ติดตามจำนวนมากและผู้ที่ถูกรีทวิตจะไม่ส่งผลกระทบต่อราคากลับมาในอนาคต

การค้นพบนี้สอดคล้องกับสมมติฐานของเราที่ว่าความรู้สึกบนสื่อสังคมออนไลน์ที่กระจายอย่างช้าๆ ใช้เวลานานกว่าในการหล่อหลอมรวมเข้าและส่งผลกระทบต่อราคาหุ้น ในขณะที่ความเชื่อมั่นที่กระจายเร็วกว่าจะถูกหล่อหลอมรวมเข้ากับราคาหุ้นอย่างรวดเร็ว จึงมีความเกี่ยวข้องเพียงเล็กน้อยกับผลตอบแทนในวันข้างหน้า (Sul, Dennis, & Yuan, 2017c)

(Peterson, 2016) แบ่งประเภทของแหล่งข้อมูลสำหรับการคาดการณ์ทางการเงินออกเป็น 3 ประเภท

ข่าวจากผู้เชี่ยวชาญ (Professional news) มีบรรณาธิการและผู้ตรวจสอบข้อเท็จจริงเนื้อหาบนสื่อต้องรับรองมาตรฐานของเนื้อหาข่าว

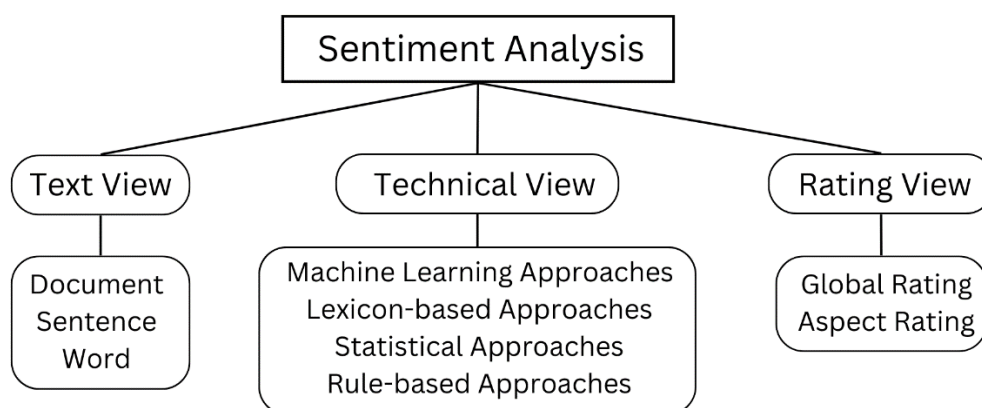
ข่าวจากสื่อสังคม (Social media) มีรูปแบบเนื้อหาไม่มีโครงสร้าง เป็นการแสดงความคิดเห็น และไม่มีการกลั่นกรอง บทความเชิงอภิปราย บทความทนาแลกเปลี่ยน

ข่าวจากการบันทึกการประชุมและบทสัมภาษณ์ผู้บริหาร (Earnings conference call transcripts and executive interviews) มีรูปแบบเนื้อหาที่มีโครงสร้าง มีส่วน Q&A ที่มีคำถามทำท่าย และคำตอบแบบต้นสด

2.8 เทคนิคการคำนวณค่าความรู้สึก (Sentiment Scoring Techniques)

การวิเคราะห์ความรู้สึก (Sentiment Analysis) เป็นหนึ่งในแนวคิดที่สำคัญที่สุดของการวิเคราะห์เนื้อหาที่ใช้ประโยชน์จากข้อมูลบนสื่อสังคมออนไลน์ที่เป็นรูปแบบข้อความจำนวนมาก การวิเคราะห์ความรู้สึกจะใช้การประมวลผลภาษาธรรมชาติ และเทคนิคการคำนวณ โดยสกัดออกมาเพื่อให้ทราบอารมณ์และความคิดเห็นจากข้อความได้โดยอัตโนมัติ จากงานวิจัยที่ผ่านมาการวิเคราะห์ความรู้สึกจำแนกตามมุมมองที่แตกต่างกัน

งานวิจัยของ (Calvo & Mac Kim, 2013) สรุปได้ว่า “นักวิจัยด้านการประมวลผลภาษาธรรมชาติมักจะใช้แบบจำลองสถานะทางอารมณ์ (Emotional states model) ขณะที่นักวิจัยด้านจิตวิทยามักจะใช้แบบจำลองเชิงมิติ (Dimensional model) เมื่อนักวิจัยด้านการประมวลผลภาษาธรรมชาติใช้แบบจำลองเชิงมิติ พวกเขามักจะเน้นเฉพาะมิติด้านความพึงพอใจ (Valence dimension) ซึ่งพวกเขาเรียกว่า "ความรู้สึก" (Sentiment)



รูปที่ 21: ภาพรวมเทคนิคการคำนวณค่าความรู้สึก

จากรูปที่ 21 การวิเคราะห์ความรู้สึกแบ่งออกเป็นหลายมุมมอง ได้แก่ มุมมองเทคนิคที่ใช้, มุมมองด้านข้อความ, ระดับคะแนน เป็นต้น

1) มุมมองทางเทคนิค สามารถจำแนกหลักการได้ดังนี้

1.1) หลักการการเรียนรู้ของเครื่อง จะใช้อัลกอริทึมการเรียนรู้หลายอย่างเพื่อกำหนดความรู้สึกโดยการฝึกฝนในชุดข้อมูลที่รู้จักในอดีต

1.2) หลักการอิงคลังคำศัพท์ เป็นการใช้การคำนวณข้อความรู้สำหรับการตรวจสอบ โดยใช้หลักแนวคิดด้านอรรถศาสตร์ (Semantic orientation) ของคำหรือประโยค ซึ่งเป็นการวัดอัตวิสัย (Subjectivity) และความคิดเห็นในข้อความ (Opinion)

1.3) หลักการตามกฎ เป็นจะค้นหาคำแสดงความคิดเห็นในข้อความแล้วจัดประเภทตามจำนวนคำที่เป็น Positive และ Negative โดยพิจารณาหลากหลายกฎเพื่อการจำแนกประเภท เช่น Dictionary polarity, คำปฏิเสธ (Negation words), คำจุดชนวน (Booster words), Emoticons, Mixed opinions ฯลฯ

1.4) หลักการทางสถิติ เป็นการใช้แบบจำลองทางสถิติ ตรวจสอบความสัมพันธ์ระหว่างลักษณะแฝง (Latent features) และการประเมินค่า (Rating) โดยตั้งสมมติฐานว่าลักษณะของข้อมูลที่เป็นรูปแบบข้อความและค่าคะแนนประเมินสามารถแสดงได้ด้วยการแจกแจงพหุนาม (Multinomial distributions) และพยายามจัดกลุ่มคำศัพท์หลักเป็นลักษณะและความรู้สึกเป็นค่าคะแนนประเมิน

2) มุมมองด้านข้อความ เหมาะสำหรับการจำแนกที่เน้นไปที่โครงสร้างของข้อความการจัดประเภทระดับเอกสาร (Document-level classification) มีเป้าหมายเพื่อค้นหาข้อความรู้ (Sentiment polarity) สำหรับการตรวจสอบทั้งหมด ในขณะที่การจัดประเภทระดับประโยค (Sentence-level) หรือระดับคำ (Word-level) สามารถแสดงข้อความรู้สำหรับการตรวจสอบแต่ละประโยคและคำ

บทสรุปของงานวิจัยของ (Collomb, Costea, Joyeux, Hasan, & Brunie, 2014) กล่าวว่า “หลักการการเรียนรู้ของเครื่องเป็นวิธีการที่พบมากที่สุดของการวิเคราะห์ความรู้สึก ซึ่งเป็นวิธีการที่ต้องการชุดข้อมูลที่สำคัญสำหรับการฝึกฝนและการเรียนรู้แนวคิดและความรู้สึกที่เกี่ยวข้อง นอกจากนี้ โมเดลมีแนวโน้มที่จะกำหนดเป้าหมายเพื่อการจัดประเภททวิภาคทั่วโลก” งานวิจัยนี้มุ่งเน้นไปที่หลักการการเรียนรู้ของเครื่องโดยมี Bidirectional Encoder Representation Transformers (BERT) model จาก Google ในปี 2018 ในเวลานั้นเทคนิคโครงข่ายประสาทเทียมแบบวนกลับ (Recurrent Neural Networks, RNN) ถูกนำมาใช้สำหรับการประมวลผลข้อความเป็นหลัก แนวคิดพื้นฐานของ BERT model นั้นมาจากการเรียนรู้การถ่ายโอน (Transfer learning) นอกจากนี้ BERT ได้รับการฝึกฝนล่วงหน้า (Pretraining) ในชุดข้อมูลทางภาษาขนาดใหญ่โดยมีเป้าหมายเพื่อทำนายคำที่หายไปข้อความให้ดีที่สุดเท่าที่จะเป็นไปได้ตามบริบท

งานวิจัยของ (Farimani, Jahan, Fard, & Tabbakh, 2022) กำหนดให้ใช้ FinBERT เป็นโมเดลการวิเคราะห์ความรู้สึก ที่รวมข้อมูลตลาดการลงทุน (Trade data, Market data) มีชื่อเรียกโมเดลว่า “FinBERT based Sentiment and Informative Market Feature (FinBERT-SIMF)” ซึ่งใช้ประโยชน์จากโมเดล pre-trained สำหรับการวิเคราะห์ความรู้สึก ความเชื่อมั่นทางการเงินที่มาจากถูกสร้างขึ้นจากรวบรวมข้อมูลเชิงลึกเกี่ยวกับความหมายและโครงสร้างของคำในหัวข้อข่าวและข้อมูลตลาดการลงทุนในอดีต ผลการวิจัยโดยการเปรียบเทียบค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ (Mean Absolute Percentage Error, MAPE) พบความผิดพลาดของการคาดการณ์อัตราแลกเปลี่ยนแปลงของเงินดอลลาร์สหรัฐกับเงินสกุลอื่นน้อยกว่าโมเดลที่ใช้ข้อมูลการเทรดในตลาดหุ้นหรือข้อมูลด้านอารมณ์อย่างใดอย่างหนึ่งเพียงอย่างเดียวเป็นข้อมูลสำหรับฝึกฝน หมายความว่าโมเดล FinBERT-SIMF ลดค่า MAPE ในชุดข้อมูล Validation และ ชุดข้อมูลทดสอบได้ โมเดลจึงมีประสิทธิภาพของการวิเคราะห์ความรู้สึกข่าวสารร่วมกับข้อมูลตลาดการลงทุนที่มีทิศทางในแนวเดียวกัน

2.9 สรุปบททวนวรรณกรรม

จากการศึกษา แนวคิด ทฤษฎี และบททวนวรรณกรรม สรุปได้ว่า การใช้ข้อมูลรูปแบบข้อความบนสื่อสังคมออนไลน์เช่น ทวิตเตอร์เป็นเครื่องมือที่สามารถที่จะใช้เป็นตัวแทน (Proxy) ในการวัดความเชื่อมั่นในการลงทุนของนักลงทุนซึ่งความเชื่อมั่นของนักลงทุนนี้เป็นตัวแปรหนึ่งที่ทำให้เกิดความไม่ปกติ (Shock) มีผลกระทบต่อตลาดหลักทรัพย์ได้ ซึ่งตลาดทองคำเป็นตลาดสินค้าโภคภัณฑ์ที่สำคัญที่นักลงทุนให้ความสนใจมาตลอด

งานวิจัยของ (Ranco, Aleksovski, Caldarelli, Grčar, & Mozetič, 2015) กล่าวว่า “ในอดีตเราไม่สามารถที่จะทำการวัดได้ เนื่องจากปัจจุบันได้เกิดสื่อสังคมออนไลน์มากมาย เราสามารถที่จะตรวจจับอารมณ์ของผู้คนได้ เนื่องจากผู้คนมีการเปิดเผยตัวตนกันมากขึ้นในสื่อสังคมออนไลน์จากการแสดงทัศนคติ อารมณ์ของตนที่มีต่อเรื่องต่างๆ”

ปัจจุบันจึงมีเทคนิคมากมายเพื่อวิเคราะห์และคาดการณ์แนวโน้มราคาทองคำ โดยเทคนิคการเรียนรู้ด้วยเครื่องและการประมวลภาษาธรรมชาติเป็นเครื่องมือที่นิยมในการวิเคราะห์จากตัวแปรที่หลากหลาย หนึ่งในตัวแปรที่ผู้วิจัยสนใจนำมาวิเคราะห์ร่วมกับตัวแปรสำคัญอื่นๆคือความรู้สึกที่มาจากข้อมูลรูปแบบข้อความบนสื่อสังคมออนไลน์ ซึ่งชุดข้อมูลดังกล่าวถูกดึงมาจากทวิตเตอร์ ซึ่งเป็นแพลตฟอร์มที่มีผู้ใช้จำนวนมากตั้งแต่ปี 2006 ถึงปัจจุบัน

บทที่ 3 ระเบียบการวิจัย

ในบทนี้กล่าวถึง การเก็บข้อมูลการทวีตจากสื่อสังคมออนไลน์ทวีตเตอร์ของผู้เชี่ยวชาญด้านการลงทุนทองคำ ขั้นตอนกระบวนการดำเนินงานในงานวิจัย เครื่องมือและเทคนิคที่ใช้วิเคราะห์ข้อมูล

3.1 การเก็บข้อมูล

สำหรับข้อมูลที่เป็นรูปแบบข้อความ (Textual Data) จาก Twitter ผู้วิจัยรวบรวมข้อมูล ตั้งแต่ มกราคม ปี 2017 ถึง ธันวาคม ปี 2022 ที่มาจากข้อความทวีตของผู้เชี่ยวชาญด้านการลงทุนทองคำจากทวีตเตอร์ จำนวน 10 ท่าน โดยคัดเลือกจากการสังเกตจำนวนผู้ติดตามที่มากกว่า 20,000 ผู้ติดตามขึ้นไป และเป็นผู้เชี่ยวชาญที่ใช้งานทวีตเตอร์ 6 ปีขึ้นไป

สำหรับข้อมูลเชิงปริมาณ ผู้วิจัยรวบรวม ราคาทองคำ (Gold spot) ดัชนีเงินดอลลาร์สหรัฐ (US Dollar Index, DXY) ดัชนีความผันผวนทองคำ (Gold Volatility Index, GVZ) อัตราดอกเบี้ยระหว่างธนาคารของสหรัฐฯ (Effective Federal Funds Rate, EFFR) SPDR® Gold Shares (GLD) SPDR S&P 500 ETF Trust (SPY) และอัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐอเมริกา 10 ปี (United States 10-Year Bond Yield, TNX) ตั้งแต่ มกราคม ปี 2017 ถึง ธันวาคม ปี 2022

ตารางที่ 7: รายชื่อผู้เชี่ยวชาญด้านการลงทุนทองคำในทวีตเตอร์ 10 ท่าน

| ชื่อทวีตเตอร์ | ชื่อผู้ใช้ | จำนวนผู้ติดตาม | เดือน ปี ค.ศ. ที่เริ่ม |
|--------------------|------------------|----------------|------------------------|
| World Gold Council | @GOLDCOUNCIL | 182.3 K | พฤษภาคม 2009 |
| Michael Maloney | @mike_maloney | 127.4 K | พฤษภาคม 2009 |
| Kitco NEWS | @KitcoNewsNow | 113 K | เมษายน 2010 |
| Patrick Karim | @badcharts1 | 65.1 K | กุมภาพันธ์ 2011 |
| The Gold Report | @SWGGoldReport | 46.2 K | มิถุนายน 2009 |
| ET Gold News | @ETGoldNews | 45.7 K | ตุลาคม 2009 |
| Peter Spina | @goldseek | 44.5 K | ตุลาคม 2010 |
| Jan Nieuwenhuis | @JanGold_ | 43.5 K | กุมภาพันธ์ 2011 |
| Egon von Greverz | @GoldSwitzerland | 38.9 K | พฤศจิกายน 2011 |
| James Turk | @FGRM | 34.8 K | มิถุนายน 2009 |

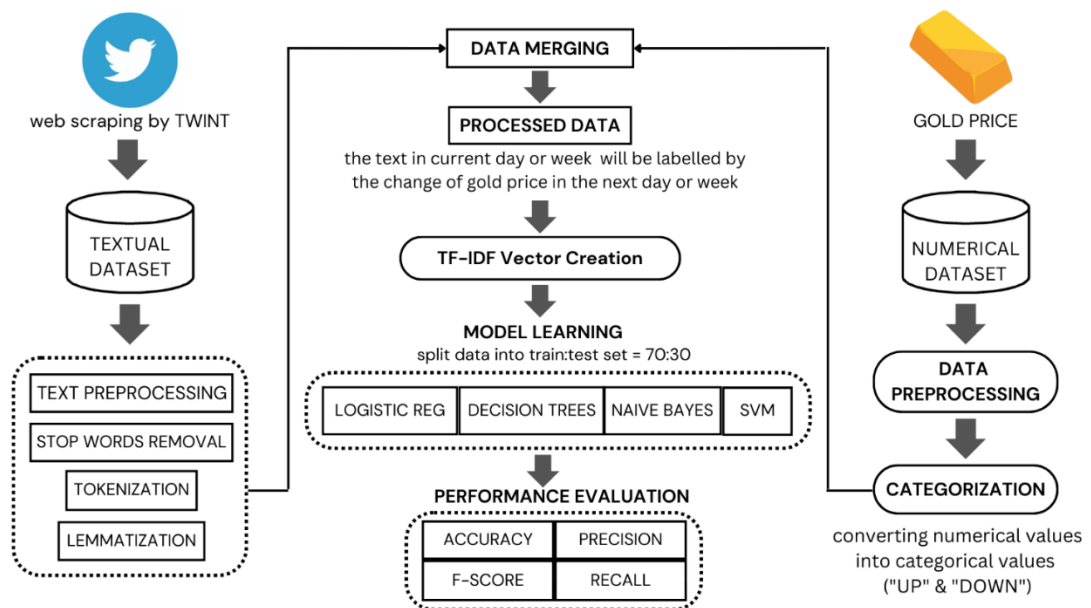
3.2 ขั้นตอนกระบวนการดำเนินงานในงานวิจัย

งานวิจัยนี้ประกอบด้วยกระบวนการวิเคราะห์ 2 ส่วน ได้แก่

ส่วนที่ 1 การใช้เทคนิคการเรียนรู้ของเครื่องเพื่อคาดการณ์ทิศทางราคาทองคำโดยมีข้อมูลนำเข้า (Input) เป็นข้อความทวีตของผู้เชี่ยวชาญด้านการลงทุนทองคำ และมี Output เป็นทิศทางราคาทองคำซึ่งถูก Label ว่า “UP”(ขึ้น) และ “DOWN”(ลง) ของวันต่อไป และสัปดาห์ต่อไป

ส่วนที่ 2 การใช้การวิเคราะห์ความรู้สึกเข้าร่วมเป็นตัวแปรคาดการณ์เพื่อคาดการณ์ทิศทางราคาทองคำร่วมกับตัวแปรคาดการณ์อื่นด้วยเทคนิคการเรียนรู้ของเครื่อง

1) ส่วนที่ 1



รูปที่ 22: ขั้นตอนกระบวนการดำเนินงานในการวิจัยส่วนที่ 1

(ที่มา: <https://www.vecteezy.com/free-vector/twitter-logo>,

https://www.kindpng.com/imgv/iixobwh_gold-bar-golden-investment-payment-metal-cartoon-gold/)

ขั้นตอนการดำเนินการวิจัย และ การออกแบบการทดลอง (Experimental design) แต่ละขั้นตอนใช้เครื่องมือการพัฒนาโปรแกรมภาษาไพทอน (Python) ร่วมกับโมดูล (Module) ต่าง ๆ แสดงดังรูปที่ 22

1.1) ดึงข้อมูลที่เป็นรูปแบบข้อความ (Textual Dataset) จากทวีตเตอร์ของผู้เชี่ยวชาญด้านการลงทุนทองคำ 10 ท่าน ด้วยอัลกอริทึมสำเร็จรูป TWINT มาเก็บเป็นไฟล์ JSON

```
import twint

c = twint.Config()
c.Username = "GoldTelegraph_"
c.Output = "tweet_data.json"
c.Lang = "en"
twint.run.Search(c)
```

รูปที่ 23: ตัวอย่างขั้นตอนการดึงข้อมูลจากทวีตเตอร์

1.2) การเตรียมข้อมูลที่เป็นรูปแบบข้อความ (Textual Preprocessing) ด้วยเทคนิคการประมวลผลภาษาธรรมชาติ (Natural Language Processing, NLP) แบ่งขั้นตอนย่อยออกเป็นดังนี้

1.2.1) การลบเครื่องหมาย ตัวเลข และลิงค์เว็บไซต์ต่างในข้อความทวีตทั้งหมดที่โปรแกรมไม่สามารถอ่านได้ รวมถึงแปลงตัวอักษรทุกตัวให้เป็นอักขระตัวพิมพ์เล็ก (lower case)

```
In [3]: 1 def remove(txt, pattern):
2         r = re.findall(pattern, txt)
3         for i in r:
4             txt = txt.lower()
5             txt = re.sub(r'http\S+', '', txt)
6             txt = re.sub(r'(@.*?)[\s]', ' ', txt)
7             txt = re.sub(r'\n\t', " not", txt)
8             txt = re.sub(r'([\;\:\;\|*\<\n])', " ", txt)
9             txt = re.sub(r'\s+', ' ', txt).strip()
10        return txt
```

รูปที่ 24: ตัวอย่างขั้นตอนการเตรียมข้อมูลรูปแบบข้อความ (Text preprocessing)

1.2.2) การลบคำ Stop words เพื่อลดภาระการประมวลผลข้อความขนาดใหญ่ และเพิ่มความแม่นยำของโมเดล ซึ่ง Stop words ที่มาจาก Library Scikit-learn เป็นอักขระตัวพิมพ์เล็กทั้งหมด ดังนั้นตัวอักษรข้อความทุกตัวต้องถูกแปลงให้เป็นอักขระตัวพิมพ์เล็กก่อน

สำหรับงานวิจัยนี้ใช้ Library ของ Scikit-learn ที่ชื่อว่า “ENGLISH_STOP_WORDS” ซึ่งมีคำ Stop word (รวมทั้งหมด 318) คำดังต่อไปนี้

```
In [8]: from sklearn.feature_extraction.text import ENGLISH_STOP_WORDS

In [9]: print(ENGLISH_STOP_WORDS)
print(len(ENGLISH_STOP_WORDS))

frozenset({'are', 'do', 'had', 'seems', 'into', 'since', 'was', 'put', 'cannot', 'found', 'now', 'our', 'under', 'am', 'because', 'ourselves', 'whereupon', 'afterwards', 'can', 'it', 'enough', 'who', 'un', 'thereafter', 'above', 'few', 'whereafter', 'such', 'elsewhere', 'four', 'which', 'from', 'fifteen', 'bottom', 'inc', 'almost', 'show', 'namely', 'latterly', 'mine', 'thereupon', 'when', 'after', 'give', 'keep', 'seeming', 'name', 'still', 'upon', 'another', 'would', 'whole', 'somewhere', 'once', 'seemed', 'being', 'a', 'something', 'except', 'eleven', 'ever', 'done', 'bill', 'while', 'of', 'everything', 'rather', 'whom', 'forty', 'sincere', 'ten', 'least', 'everywhere', 'out', 'should', 'thereby', 'only', 'alone', 'to', 'whoever', 'them', 'my', 'become', 'onto', 'throughout', 'empty', 'move', 'other', 'wherein', 'therein', 'else', 'more', 'you', 'nor', 'someone', 'then', 'nowhere', 'sixty', 'whatever', 'please', 'further', 'through', 'anyhow', 'what', 'each', 'side', 'i', 'cant', 'eight', 'will', 'former', 'before', 'also', 'where', 'so', 'on', 'how', 'no', 'eg', 'over', 'may', 'part', 'any', 'describe', 'hers', 'amongst', 'why', 'anything', 'hence', 'whither', 'beyond', 'serious', 'about', 'take', 'thru', 'first', 'nothing', 'we', 'could', 'most', 'her', 'perhaps', 'here', 'whereby', 'is', 'less', 'everyone', 'well', 'always', 'has', 'nine', 'either', 'themselves', 'whether', 'beforehand', 'yet', 'go', 'however', 'too', 'etc', 'down', 'as', 'ours', 'otherwise', 'herself', 'front', 'whereas', 'than', 'yourself', 'de', 'were', 'interest', 'must', 'nobody', 'though', 'mill', 'hereafter', 'in', 'within', 'thus', 'and', 'with', 'yourselves', 'an', 'twenty', 'although', 'its', 'thin', 'for', 'anywhere', 'formerly', 'ie', 'sometime', 'herein', 'that', 'across', 'back', 'she', 'meanwhile', 'the', 'already', 'fill', 'those', 'many', 'con', 'made', 'without', 'or', 'hasnt', 'thence', 'thick', 'might', 'never', 'couldnt', 'his', 'together', 'during', 'very', 'this', 'your', 'be', 'by', 'moreover', 'system', 'get', 'until', 'even', 'every', 'whence', 'six', 'becomes', 'have', 'next', 'third', 'often', 'itself', 'find', 'around', 'two', 'between', 'along', 'been', 'sometimes', 'hereupon', 'me', 'cry', 'indeed', 'myself', 'becoming', 'anyone', 'five', 'noone', 'their', 'towards', 'detail', 'anyway', 'himself', 'three', 'fifty', 'some', 'one', 'at', 'somehow', 'they', 'became', 'not', 'twelve', 'wherever', 'beside', 'against', 'toward', 'see', 'none', 'all', 'co', 'latter', 'neither', 'he', 'below', 'fire', 'hereby', 're', 'therefore', 'last', 'if', 'hundred', 'these', 'due', 'much', 'whose', 'ltd', 'amongst', 'nevertheless', 'there', 'whenever', 'among', 'per', 'up', 'mostly', 'but', 'us', 'both', 'seem', 'behind', 'via', 'him', 'others', 'amount', 'own', 'several', 'same', 'call', 'yours', 'top', 'full', 'off', 'again', 'besides'})
318
```

รูปที่ 25: คำ Stop word ทั้งหมดที่มาจาก ENGLISH_STOP_WORDS ของ Scikit learn

ข้อควรระวังการลบคำ Stop word ในบางกรณีเช่น ประโยค “I am sure the pricing wouldn't keep increasing for a few more days.” สังเกตได้ว่า “wouldn't” เป็นหนึ่งในกลุ่ม stop word หากตัดกลุ่มคำปฏิเสธเหล่านี้นี้ออกอาจทำให้ค่า Sentiment score เปลี่ยน เพื่อป้องกันการคำนวณ sentiment คลาดเคลื่อน ผู้วิจัยใช้วิธี replace() “n't” ที่ปรากฏใน Dataframe ทุกๆ ให้เป็น “not” ในขั้นตอนการเตรียมข้อมูล (Text preprocessing) ส่วนคำว่า “up” และ “down” ผู้วิจัยมีความเห็นว่าเป็นคำที่สามารถบอกทิศทางด้านการเงินและการลงทุน ควรถูกส่งผ่านเข้าโมเดล เพื่อฝึกฝน ดังนั้นการตัดคำ Stop word สำหรับงานวิจัยนี้คำว่า “not”, “no”, “up” และ “down” ถูกยกเว้น

1.2.3) การทำ Tokenization สำหรับงานวิจัยนี้ ใช้ข้อความนั้นถูกแบ่งออกด้วยช่องว่าง (Blank space)

```
In [1]: import nltk

In [2]: text = """The chart for gold looks strong enough to propel it to new highs.
PHYSICAL GOLD TIGHT: LBMA May Pressure GLD GOLD ETF To Make Physical Available.
Look at This Shocking Inflation. Plus Gold Price Surges To $1,950.
Tomorrow, my article for Goldmoney will explain why gold is rising to news levels,
it will be the new trade settlement medium for Russia, China, and the Shanghai Cooperation
This is what the Central Banks are up to as gold continues to crush fiat currencies.
It means kiss goodbye to all fiat hopium. Protect yourself with real money, platinum.
That's what central banks are doing because they know that will be the new Asian.
The bullish case, that Putin will be rapidly routed is unrealistic. If Russia collapses,
It still has the capacity to destabilise western fiat currencies. That is dangerous.
No one is thinking through the effect on markets of the resumption of the Ukraine.
Tanks are being shipped from NATO for big showdown. Energy prices sure to spike.
Bond yields will rise, equities fall."""

In [4]: # Tokenize into sentence lists
list = nltk.sent_tokenize(text)
# Starting 5 Sentence Lists in text
list[:5]

Out[4]: ['The chart for gold looks strong enough to propel it to new highs.',
'PHYSICAL GOLD TIGHT: LBMA May Pressure GLD GOLD ETF To Make Physical Available.',
'Look at This Shocking Inflation.',
'Plus Gold Price Surges To $1,950.',
'Tomorrow, my article for Goldmoney will explain why gold is rising to news levels,
it will be the new trade settlement medium for Russia, China, and the Shanghai Cooperation Organisation family of nations.']
```

รูปที่ 26: ตัวอย่างการทำ Tokenize ข้อความ (1)

```
In [5]: # Tokenize into words
words = nltk.word_tokenize(text)
# Starting 10 words in text
words[:10]
```

```
Out[5]: ['The',
'chart',
'for',
'gold',
'looks',
'strong',
'enough',
'to',
'propel',
'it']
```

รูปที่ 27: ตัวอย่างการทำ Tokenize ข้อความ (2)

1.2.4) ทำการลดความซับซ้อนของคำด้วยวิธี Stemming และ Lemmatization

```
In [14]: from nltk.stem import PorterStemmer

In [15]: stemm = PorterStemmer()

In [43]: for i in range(len(list)):
words=nltk.word_tokenize(txt)
words=[stemm.stem(word) for word in words if word not in ENGLISH_STOP_WORDS]
wrdr[i] = ' '.join(words)

In [44]: wrdr[:5]

Out[44]: ["'the', 'chart', 'gold', 'look', 'strong', 'propel', 'new', 'high.', 'physic', 'gold', 'tight :
', 'lbma', 'may', 'pressur', 'gld', 'gold', 'etf', 'to', 'make', 'physic', 'avail.', 'look', 'th
i', 'shock', 'inflat.', 'plu', 'gold', 'price', 'surg', 'to', '$ 1,950.', 'tomorrow', 'articl'
', 'goldmoney', 'explain', 'wji', 'gold', 'rise', 'new', 'level', 'new', 'trade', 'settlement', 'me
dium', 'russia', 'china', 'shanghai', 'cooper', 'organis', 'famili', 'nation', 'thi', 'central'
', 'bank', 'gold', 'continu', 'crush', 'fiat', 'currenc.', 'it', 'mean', 'kiss', 'goodby', 'fiat',
', 'hopium', 'protect', 'real', 'money', 'physic', 'gold', 'that', 's', 'central', 'bank', 'do'
', 'know', 'new', 'asian', 'trade', 'settlement', 'medium.', 'the', 'bullish', 'case', 'putin', 'rap
idli', 'rout', 'unrealist.', 'if', 'russia', 'doe', 'come', 'militari', 'pressur', 'it', 'capac'
', 'destabilis', 'wastern', 'fiat', 'currenc.', 'that', 'definit', 'russia', 's', 'strategi', 'no'
', 'think', 'effect', 'market', 'resumpt', 'ukrain', 'conflict.', 'tank', 'ship', 'nato', 'big', 'sh
owdown.', 'energi', 'price', 'sure', 'spike', 'higher.', 'futur', 'cpi', 'estim', 'well.', 'bond'
', 'yield', 'rise', 'equiti', 'fall.', ''],
[''the', 'chart', 'gold', 'look', 'strong', 'propel', 'new', 'high.', 'physic', 'gold', 'tight :
', 'lbma', 'may', 'pressur', 'gld', 'gold', 'etf', 'to', 'make', 'physic', 'avail.', 'look', 'th
i', 'shock', 'inflat.', 'plu', 'gold', 'price', 'surg', 'to', '$ 1,950.', 'tomorrow', 'articl'
', 'goldmoney', 'explain', 'wji', 'gold', 'rise', 'new', 'level', 'new', 'trade', 'settlement', 'me
dium', 'russia', 'china', 'shanghai', 'cooper', 'organis', 'famili', 'nation', 'thi', 'central'
', 'bank', 'gold', 'continu', 'crush', 'fiat', 'currenc.', 'it', 'mean', 'kiss', 'goodby', 'fiat',
```

รูปที่ 28: ตัวอย่างการทำ Stemming ชุดข้อความตัวอย่าง

```
In [31]: from nltk.stem import WordNetLemmatizer

In [32]: list = nltk.sent_tokenize(txt)
lemmatizer = WordNetLemmatizer()

In [34]: for i in range(len(list)):
wrdr = nltk.word_tokenize(text)
wrdr = [lemmatizer.lemmatize(word) for word in words if word not in ENGLISH_STOP_WORDS]
wrdr[i] = ' '.join(words)

In [36]: wrdr[:10]

Out[36]: ['chart',
'gold',
'look',
'strong',
'propel',
'new',
'high',
',',
'physic',
'gold']
```

รูปที่ 29: ตัวอย่างการทำ Lemmatization ชุดข้อความตัวอย่าง

1.3) เตรียมข้อมูลราคาทองคำรายวัน (มีหน่วยเป็น US\$/Troy Ounce) หากตรวจพบว่ามีค่าข้อมูลไม่สมบูรณ์ (missing values) ในชุดข้อมูลราคาทองคำ ซึ่งสันนิษฐานว่าเป็นวันหยุดประจำชาติของสหรัฐอเมริกา เช่น วันจันทร์ที่ 20 มิถุนายน 2565 เนื่องในโอกาสหยุดชดเชยวันจูนทีนธ์ (Juneteenth) ในวันนั้นตลาดหลักทรัพย์, ตลาดปริวรรตเงินตรา และตลาดสินค้าโภคภัณฑ์รวม

ทองคำจะปิดทำการ แต่เนื่องจากการ Label ทิศทางราคาทองคำขึ้นหรือลง จำเป็นต้องเปรียบเทียบจากราคาจริง ณ วันที่ตลาดเปิดซื้อขาย ดังนั้นข้อมูลแถวที่ถูกลบจากราคาทองคำขาดหายจึงถูกลบออก

1.5) แปลงทิศทางราคาทองคำที่เป็นไปทิศทางบวกหรือลบ ให้อยู่ในรูปแบบ Categorical data คือ “UP” และ “DOWN”

1.6) สร้างคอลัมน์ใหม่เพื่อเป็นค่าผลการคาดการณ์ทิศทางราคาทองคำ (Target value) โดยเลื่อนค่าทุกๆแถวขึ้น 1 แถว

```
[46]: clean_df_g = df3.reset_index(drop=True)
      print(clean_df_g.shape)
      clean_df_g.head()

(2284, 2)

[46]:   date  gold_market
0  2013-12-31      down
1  2014-01-01      down
2  2014-01-02       up
3  2014-01-03       up
4  2014-01-06       up

[151]: clean_df_gg = clean_df_g.copy()
       gold_ans_df = clean_df_gg.loc[1:2284,:].reset_index(drop=True)
       print(gold_ans_df.shape)
       gold_ans_df.head()

(2283, 2)

[151]:   date  gold_market
0  2014-01-01      down
1  2014-01-02       up
2  2014-01-03       up
3  2014-01-06       up
4  2014-01-07      down
```

รูปที่ 30: ตัวอย่างการเลื่อน Target value ขึ้น 1 แถว

1.7) ผสานข้อมูลทั้ง 2 เข้าอยู่ใน Dataframe เดียวกันมีฟีเจอร์ดังนี้

ตารางที่ 8: ฟีเจอร์ของข้อมูลนำเข้าที่พร้อมนำไปใช้ (ส่วนที่ 1)

| Features | Dtype | คำอธิบาย |
|----------|----------|--------------|
| Date | Datetime | วัน-เดือน-ปี |
| Tweet | String | ข้อความทวีต |

| | | |
|--------------------|--------|--|
| Changes_Gold_Price | String | การเปลี่ยนแปลงของราคาทองคำ “UP” และ “DOWN” |
| Prediction | String | ผลคาดการณ์ทิศทางราคาทองคำ “UP” และ “DOWN” |

| prediction | tidy_tweet |
|------------|---|
| UP | trend delicate gold heart necklace |
| UP | trend forecasting wearing apron shirt gold chain la gerardo home economics scene cannot buy love |
| UP | look key trend gold |
| UP | tuesday chart jan kitco news |
| UP | brace new world rising treasury yield kitco news |
| ... | ... |
| UP | youre ready brand new week technical trade time check pepsi pep gold's trend pullback 's possible double breakout |
| UP | ticket witness global expert discuss share insight trade current landscape key trend shaping future industry |
| UP | oil not spot bull wanted wti fail trend resistance wti down energy stock gold trend review macro |
| UP | latest trend gold price amp trading strategy check gold silver cost today price |
| UP | kate's chosen accessory visit bbc radio prince wale line longstanding trend piling chunky gold chain |

รูปที่ 31: ตัวอย่างชุดข้อมูลที่พร้อมนำไปใช้

| prediction | tidy_tweet |
|------------|--|
| UP | [trend, delicate, gold, heart, necklace] |
| UP | [trend, forecasting, wearing, apron, shirt, gold, chain, la, gerardo, home, economics, scene, cannot, buy, love] |
| UP | [look, key, trend, gold] |
| UP | [tuesday, chart, jan, kitco, news] |
| UP | [brace, new, world, rising, treasury, yield, kitco, news] |
| ... | ... |
| UP | [youre, ready, brand, new, week, technical, trade, time, check, pepsi, pep, gold's, trend, pullback, 's, possible, double, breakout] |
| UP | [ticket, witness, global, expert, discuss, share, insight, trade, current, landscape, key, trend, shaping, future, industry] |
| UP | [oil, not, spot, bull, wanted, wti, fail, trend, resistance, wti, down, energy, stock, gold, trend, review, macro] |
| UP | [latest, trend, gold, price, amp, trading, strategy, check, gold, silver, cost, today, price] |
| UP | [kate's, chosen, accessory, visit, bbc, radio, prince, wale, line, longstanding, trend, piling, chunky, gold, chain] |

รูปที่ 32: ตัวอย่างผลการทำงาน Tokenize ชุดข้อมูลที่พร้อมนำไปใช้

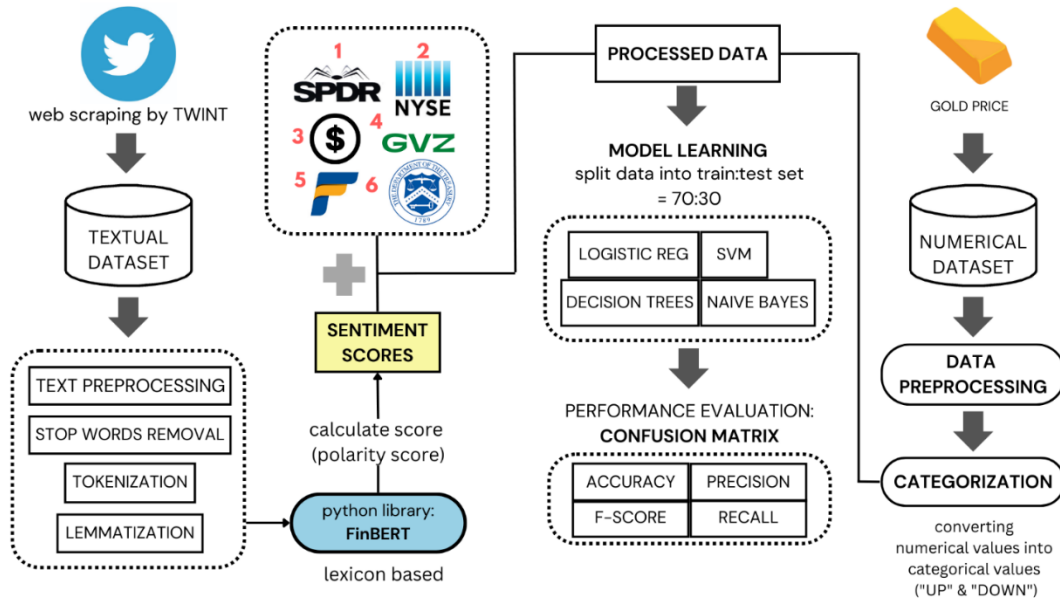
1.8) ใช้เทคนิค TF-IDF สร้างเมตริกซ์ของคำในเอกสาร

1.9) แบ่งชุดข้อมูลออกเป็นชุดเข้าฝึกฝนเรียนรู้และชุดทดสอบโดยใช้ Library ของ Scikit learn โดยมี Prediction เป็น Target value

1.10) นำข้อมูลติดตั้งเข้าโมเดลทั้ง 4 ตัว (Logistic Regression, Decision Trees, Naïve Bayes และ SVM)

1.11) ประเมินโมเดลทั้ง 4 ตัว ด้วยค่า Accuracy, Precision, F-1 Score และ Recall

2) ส่วนที่ 2



รูปที่ 33: ภาพรวมขั้นตอนกระบวนการดำเนินงานในงานวิจัยส่วนที่ 2

(ที่มา: https://etfinveste.pt/analise1_spy/, <https://www.vecteezy.com/free-vector/dollar-sign-icon>, <https://www.etfstream.com/companies/nyse/>, <https://gcaptain.com/treasury-blacklists-hong-kong/>)

2.1) ขั้นตอนการดึงจนถึงขั้นตอนการทำเตรียมข้อมูลในรูปแบบข้อความที่วิตจากวิตเตอร์ และการเตรียมข้อมูลทองคำรายวัน และรายสัปดาห์ ตั้งแต่ มกราคม 2017 ถึง ธันวาคม 2022 เหมือนในส่วนที่ 1 ทุกประการ

2.2) คำนวณค่า Sentiment ด้วย Library ชื่อ FinBERT

| | tweet | Positive | Negative | Neutral |
|-----|---|----------|----------|----------|
| 0 | look key trend gold | 0.059995 | 0.022486 | 0.917518 |
| 1 | tuesday chart jan kitco news | 0.021956 | 0.063266 | 0.914777 |
| 2 | stop wednesday january kitco news | 0.023449 | 0.033987 | 0.942565 |
| 3 | hit high renewed speculator buying kitco news | 0.493519 | 0.136537 | 0.369943 |
| 4 | gold remains bearish trend | 0.066086 | 0.398940 | 0.534974 |
| ... | ... | ... | ... | ... |
| 348 | gold price continued weak trend prior week closed negative territory loss writes | 0.021542 | 0.963823 | 0.014635 |
| 349 | kitcos gold survey result mixed sentiment show gold going week price hovers | 0.035790 | 0.898520 | 0.065690 |
| 350 | gold decline r amid weak global trend | 0.034704 | 0.943470 | 0.021826 |
| 351 | analyst verdict fouryearolds boast good record race recent year saratoga gold taken continue trend view card gt | 0.815522 | 0.011742 | 0.172736 |
| 352 | price bitcoin price hold support crypto market struggle gain momentum | 0.587824 | 0.093539 | 0.318637 |

รูปที่ 34: ตัวอย่างข้อความภาษาอังกฤษจากวิตเตอร์ที่นำมาทำ Sentiment

2.3) เตรียมข้อมูลนำเข้าที่เป็นตัวแปรสำหรับคาดการณ์ราคาทองคำ ตั้งแต่ มกราคม 2017 ถึง ธันวาคม 2022 ประกอบด้วย ดัชนีเงินดอลลาร์สหรัฐ (US Dollar Index, DXY) ดัชนีความผันผวนทองคำ (Gold Volatility Index, GVZ) อัตราดอกเบี้ยระหว่างธนาคารของสหรัฐฯ (Effective Federal Funds Rate, EFFR) SPDR® Gold Shares (GLD) SPDR S&P 500 ETF Trust (SPY) และ อัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐอเมริกา 10 ปี (United States 10-Year Bond Yield, TNX)

2.4) เนื่องจากพบว่ามีข้อมูลสูญหาย (Missing values) ในชุดข้อมูลปัจจัยทางเศรษฐกิจ ซึ่งแก้ไขโดยใช้วิธีการแทนค่าด้วย 0 เป็นวิธีเดียวกับ (Brownlee, 2017) ทดลองการทดแทนข้อมูลสูญหายของข้อมูลภาวะฉุกเฉินของม้า พบว่าการทดแทนด้วย 0 ทำให้ผลค่า Accuracy สูงที่สุด

2.5) ผสานข้อมูลทั้งหมดเข้าอยู่ใน Dataframe เดียวกัน มีฟีเจอร์ดังนี้

ตารางที่ 9: ฟีเจอร์ของข้อมูลนำเข้าที่พร้อมนำไปใช้ (ส่วนที่ 2)

| Features | Dtype | คำอธิบาย |
|--------------------|----------|---|
| Date | Datetime | วัน-เดือน-ปี |
| Tweet | String | ข้อความทวิต |
| Sentiment_Score | Int | ค่าความรู้สึกจากข้อความทวิต |
| Dollar_index | Int | ดัชนีเงินดอลลาร์สหรัฐ |
| EFFR | Int | อัตราดอกเบี้ยระหว่างธนาคารของสหรัฐอเมริกา |
| GVZ | Int | ดัชนีความผันผวนทองคำ |
| GLD | Int | ดัชนี SPDR® Gold Shares |
| SPY | Int | ดัชนี SPDR S&P 500 ETF Trust |
| TNX | Int | อัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐอเมริกา 10 ปี |
| Changes_Gold_Price | String | การเปลี่ยนแปลงของราคาทองคำ “UP” และ “DOWN” |
| Prediction | String | ผลคาดการณ์ทิศทางการราคาทองคำ “UP” และ “DOWN” |

2.6) แบ่งชุดข้อมูลออกเป็นชุดเข้าฝึกฝนเรียนรู้และชุดทดสอบโดยใช้ Library ของ Scikit learn โดยมี Prediction เป็นค่า Target value

2.7) นำข้อมูลติดตั้งเข้าโมเดลทั้ง 4 ตัว (Logistic Regression, Decision Trees, Naïve Bayes และ SVM)

2.8) ประเมินโมเดลทั้ง 4 ตัวด้วยค่า Accuracy, Precision, F-1 Score และ Recall

3.3 เครื่องมือและเทคนิคที่ใช้สร้างโมเดลและวิเคราะห์ข้อมูล

ผู้วิจัยเลือกใช้ภาษา Python version 3.9.5 โดยใช้ Environment ผ่าน Jupyter Notebook (Miniconda) ในการสร้างโมเดลและวิเคราะห์ข้อมูล ภายใต้ระบบปฏิบัติการ Ubuntu 22.04

1) เครื่องมือที่ใช้ในการดึงข้อมูลในรูปแบบข้อความจากทวิตเตอร์ ผู้วิจัยเลือกใช้ TWINT (Twitter Intelligence Tool) ที่สามารถดึงข้อความทวิตจากผู้ใช้รายบุคคล หัวข้อที่สนใจ Hashtag หรือเทรนด์จากทวิตเตอร์

2) เครื่องมือที่ใช้ในการคำนวณค่าความรู้สึก ผู้วิจัยเลือกใช้ FinBERT ซึ่งมีพื้นฐานมาจากโมเดล BERT (Bidirectional Encoder Representations from Transformers) ประกอบด้วย 2 ส่วน คือ Encoder และ Decoder

Encoder เป็นอัลกอริทึมสำหรับเรียนรู้ภาษา ไวยากรณ์ และบริบทของชุดข้อความ จากนั้นสร้างการแปลงคำให้เป็นรหัสหรือตัวเลข (Embedding) ส่วนตัว Decoder เป็นอัลกอริทึมสำหรับนำรหัสหรือตัวเลขนั้นสร้างคำถัดไปทีละคำ โมเดล BERT ได้รับการฝึกฝนแบบไม่มีผู้สอน (Unsupervised learning) โดยแบ่งออกเป็น 2 ภารกิจคือ เรียนรู้ภาษาและการปรับแต่งโมเดลอย่างละเอียดเพื่อเรียนรู้งานเฉพาะ

FinBERT เป็นแบบจำลองของ BERT ที่ได้รับการฝึกฝนล่วงหน้าเกี่ยวกับข้อมูลที่ถ่ายทอดเนื้อหาทางการเงิน มีวัตถุประสงค์เพื่อพัฒนา ปรับปรุงการวิจัยด้านการประมวลผลภาษาธรรมชาติในขอบเขตเนื้อหาทางการเงิน โมเดลนี้ได้รับการฝึกฝน เรียนรู้ภาษาในคลังคำศัพท์ (Corpus) เนื้อหาทางการเงิน 3 แหล่ง ขนาดของคลังคำศัพท์รวมทั้งหมดองค์กรทั้งหมดคือ 4.9 พันล้านโทเค็น แบ่งออกเป็น

รายงานการเงินธุรกิจ (Corporate reports) 10,000 ชุด 10 ไตรมาส มีขนาด 2.5 พันล้านโทเค็น

รายงานผลประกอบการ (Earnings call transcripts) ขนาด 1.3 พันล้านโทเคน

รายงานของนักวิเคราะห์ (Analyst reports): ขนาด 1.1 พันล้านโทเคน

เหตุผลหลักที่ผู้สร้างโมเดล FinBERT เลือกใช้แหล่งเนื้อหาหรือข้อมูลในรูปแบบข้อความด้านการเงิน คือ

- (1) เป็นชุดข้อมูลที่ถือเป็นแบบได้ดีที่สุดและถูกใช้ในรูปแบบของเนื้อหาการสื่อสารทางการเงินที่ใช้ในการวิจัยทางด้านเศรษฐกิจและการเงิน
- (2) เป็นชุดข้อมูลที่รวบรวมข้อคิดเห็นจากผู้วิเคราะห์ด้านการเงินที่มีตำแหน่งสำคัญ จากการศึกษาพบว่าข้อมูลที่ถูกถ่ายทอดจากมุมมองเหล่านี้เป็นสาระประโยชน์ต่อนักลงทุน (Huang, Wang, & Yang, 2022)
- (3) เป็นชุดข้อมูลที่มีลักษณะเนื้อหา การเปิดเผยต่อสื่อ ข้อกำหนด ผู้และรับสารที่แตกต่างกัน เป็นผลทำให้ pretrain โมเดล FinBERT ได้หลากหลายประเด็น

3.4 ตัววัดประสิทธิภาพของโมเดล

ตัววัดแต่ละค่านั้นถูกคำนวณมาจาก ข้อมูลจริงที่นำเข้าฝึกฝน (Actual data) อยู่ด้านคอลัมน์ และ ข้อมูลที่โมเดลให้ผลลัพธ์ที่คาดการณ์ได้ (Predicted data) อยู่ในแถว ทั้งหมดถูกจัดไว้ในตาราง Confusion matrix และคำนวณค่าความถูกต้อง (Accuracy) ค่าความแม่นยำ (Precision) ค่าระลึก (Recall) และ F1-Score ของแต่ละโมเดล โดยผลของการวัดสามารถอธิบายได้ดังต่อไปนี้

ค่าความถูกต้อง (Accuracy) สามารถบอกจำนวนผลลัพธ์ที่ทิศทางราคาของคำที่โมเดลคาดการณ์ตรงกับผลลัพธ์เป้าหมายจากจำนวนผลลัพธ์ทั้งหมด

ค่าความแม่นยำ (Precision) เป็นการวัดความแม่นยำของโมเดล โดยค่าที่ได้จะแสดงให้เห็นว่าโมเดลที่ใช้สามารถคาดการณ์ตรงกันเพียงใด

ค่าระลึก (Recall หรือ Sensitivity) เป็นการวัดความครอบคลุม โดยค่าที่ได้จะแสดงให้เห็นว่าโมเดลสามารถคาดการณ์ได้ว่าทิศทางราคาของตรงครอบคลุมกับผลลัพธ์เป้าหมายได้มากน้อยเพียงใด

ค่า F1-Score เป็นการคำนวณจากค่าเฉลี่ยของค่า Precision และค่า Recall

ภาษา Python มี Library ชื่อ Scikit-learn ถูกเรียกใช้ในการประเมินค่า Accuracy โดยใช้ฟังก์ชัน `accuracy_score` และการประเมินค่า Precision, Recall และ F1-Score ใช้ฟังก์ชัน `classification_report` ทั้ง 2 ฟังก์ชัน โดยใส่ค่าพารามิเตอร์ที่เหมือนกัน คือ ผลลัพธ์จริง (Actual result) และ ผลลัพธ์จากการคาดการณ์ของโมเดล (Predicted result)



บทที่ 4


ผลการวิเคราะห์

ในบทนี้จะกล่าวถึงผลการวิเคราะห์การคาดการณ์ทิศทางราคาทองคำจากความรู้สึกของข้อความบนทวิตเตอร์โดยใช้เทคนิคการเรียนรู้ด้วยเครื่อง ได้แก่ ต้นไม้ตัดสินใจ (Decision trees) นาอิว เบย์ (Naïve Bayes) การถดถอยโลจิสติก (Logistic regression) และเครื่องเวกเตอร์ค้ำยัน (Support vector machine) โดยพิจารณาจากค่าความถูกต้อง (Accuracy) ค่าความแม่นยำ (Precision) ค่าระลึก (Recall) และค่าวัดประสิทธิภาพโดยรวม (F1-score)

4.1 ผลการวิเคราะห์ภาพรวม


4.1.1 ภาพรวมข้อมูลที่เป็นรูปแบบข้อความ (Textual Dataset)

จากทวิตเตอร์ของผู้เชี่ยวชาญด้านการลงทุนทองคำ 10 ท่าน พบว่าผู้ใช้งาน Twitter ชื่อ Kitco NEWS โสข้อความที่เกี่ยวกับทองคำในสัดส่วนที่มากที่สุดเมื่อเทียบกับอีก 9 ผู้ใช้งาน



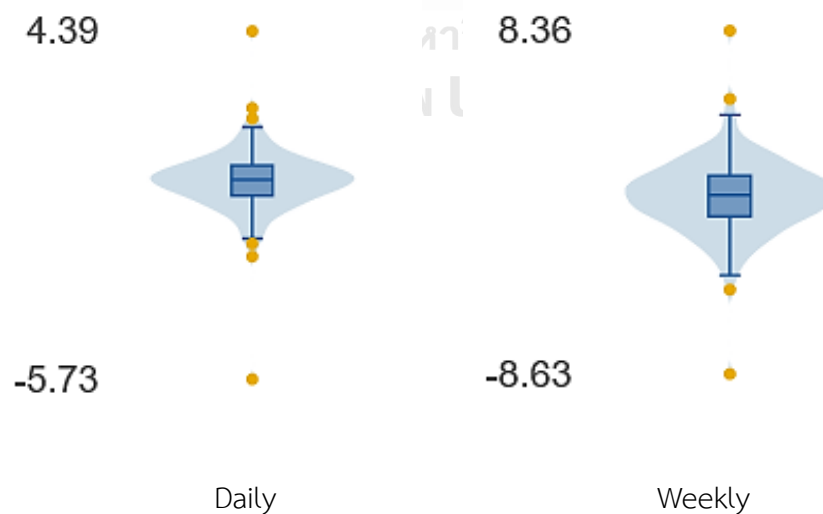
รูปที่ 35: จำนวนข้อความจากทวิตเตอร์ของผู้เชี่ยวชาญด้านการลงทุนทองคำ 10 ท่านระหว่าง มกราคม 2560 ถึง ธันวาคม 2565

4.1.2 ภาพรวมราคาทองคำที่นำมาวิเคราะห์



รูปที่ 36: การแจกแจงของเปอร์เซ็นต์การเปลี่ยนแปลงราคาทองคำรายวันระหว่าง มกราคม 2560 ถึง ธันวาคม 2565

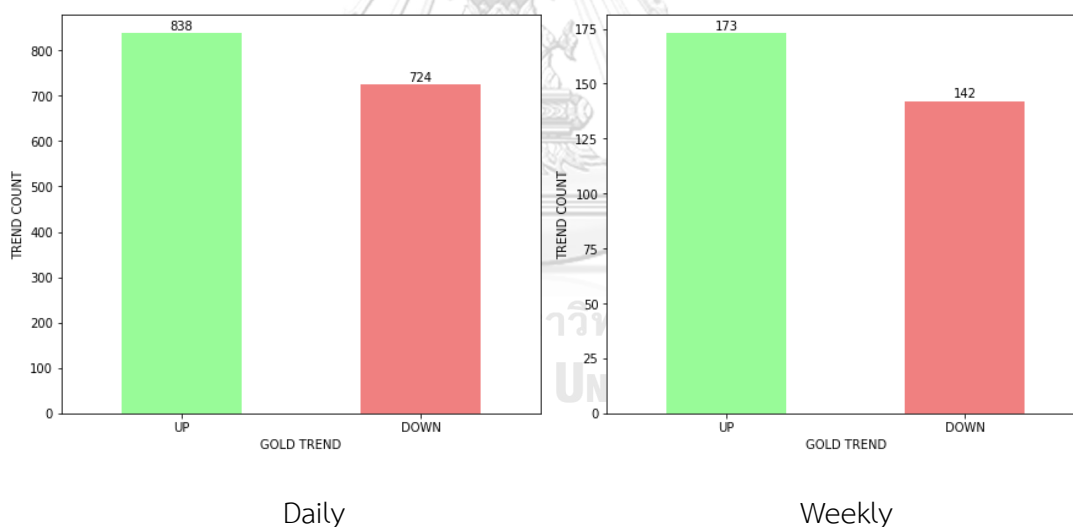
พบว่า การแจกแจงเปอร์เซ็นต์การเปลี่ยนแปลงราคาทองคำรายวันกับตัวแปรคาดการณ์ราคาทองคำ ตั้งแต่ มกราคม 2017 ถึง ธันวาคม 2022 พบสัดส่วนการเปลี่ยนแปลงราคาทองคำไปทิศทางบวก มีมากกว่าทิศทางลบ



รูปที่ 37: เปรียบเทียบการแจกแจงระหว่างเปอร์เซ็นต์การเปลี่ยนแปลงราคาทองคำรายวันและรายสัปดาห์

ตารางที่ 10: ค่าสถิติของเปอร์เซ็นต์การเปลี่ยนแปลงราคาทองคำรายวันและรายสัปดาห์

| ค่าสถิติ | เปอร์เซ็นต์การเปลี่ยนแปลง ราคาทองคำรายวัน | เปอร์เซ็นต์การเปลี่ยนแปลง ราคาทองคำรายสัปดาห์ |
|--------------------------------------|--|--|
| Minimum | -5.73 | -8.63 |
| Maximum | 4.39 | 8.36 |
| Mean | 0.033 | 0.164 |
| Standard deviation | 0.844 | 1.86 |
| 25 th Percentile (1. Q) | -0.39 | -0.83 |
| 50 th Percentile (Median) | 0.07 | 0.23 |
| 75 th Percentile (3. Q) | 0.488 | 1.19 |
| IQR | 0.878 | 2.020 |
| Outliers | 19 (1.1216%) | 3 (0.958%) |



รูปที่ 38: เปรียบเทียบจำนวน Target value ระหว่างการเปลี่ยนแปลงราคาทองคำรายวันและรายสัปดาห์


ตารางที่ 11: ค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างเปอร์เซ็นต์การเปลี่ยนแปลงราคาทองคำรายวันกับตัวแปรคาดการณ์ราคาทองคำ

| ตัวแปรคาดการณ์ | ค่าสัมประสิทธิ์สหสัมพันธ์ |
|-----------------------|---------------------------|
| ดัชนีเงินดอลลาร์สหรัฐ | -0.47 |
| ดัชนีความผันผวนทองคำ | 0.15 |

| ตัวแปรคาดการณ์ | ค่าสัมประสิทธิ์สหสัมพันธ์ |
|---|---------------------------|
| อัตราดอกเบี้ยระหว่างธนาคารของสหรัฐฯ | 0 |
| ดัชนี SPDR® Gold Shares (GLD) | 0.98 |
| ดัชนี SPDR S&P 500 ETF Trust (SPY) | 0.07 |
| อัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐอเมริกา 10 ปี | -0.29 |


พบว่าตัวแปรที่มีความสัมพันธ์กับการเปลี่ยนแปลงราคาทองในทิศทางเดียวกันมากที่สุดคือ ดัชนี SPDR® Gold Shares (GLD) ซึ่งเป็นหนึ่งในกองทุน Exchange traded fund (ETF) ปัจจุบัน SPDR® Gold Shares เป็นผู้ถือครองทองคำรายใหญ่ที่สุดของโลก และดัชนีตัวนี้ถูกอ้างอิงที่ราคาทองคำ ในขณะที่ดัชนี SPDR S&P 500 ETF Trust (SPY) ซึ่งเป็นกองทุน ETF ที่มีขนาด Asset under management (AUM) ใหญ่ที่สุดในโลกกลับมีความสัมพันธ์กับการเปลี่ยนแปลงราคาทอง น้อยมาก ใกล้เคียงกับอัตราดอกเบี้ยระหว่างธนาคารของสหรัฐฯ ที่ไม่พบความสัมพันธ์กับการเปลี่ยนแปลงราคาทองคำ ส่วนตัวแปรที่มีความสัมพันธ์กับการเปลี่ยนแปลงราคาทองในทิศทางตรงกันข้ามมากที่สุดคือ ดัชนีเงินดอลลาร์สหรัฐฯ

Correlation matrix



รูปที่ 39: เมทริกซ์สหสัมพันธ์ของเปอร์เซ็นต์การเปลี่ยนแปลงราคาทองคำรายวันกับตัวแปรคาดการณ์


Correlation between Change in Gold Price and Change in Dollar is: -0.47



รูปที่ 40: ความสัมพันธ์ระหว่างเปอร์เซ็นต์การเปลี่ยนแปลงราคาทองคำกับดัชนีเงินดอลลาร์สหรัฐฯ




Correlation between Change in Gold Price and Change in Gold Volatility is: 0.15



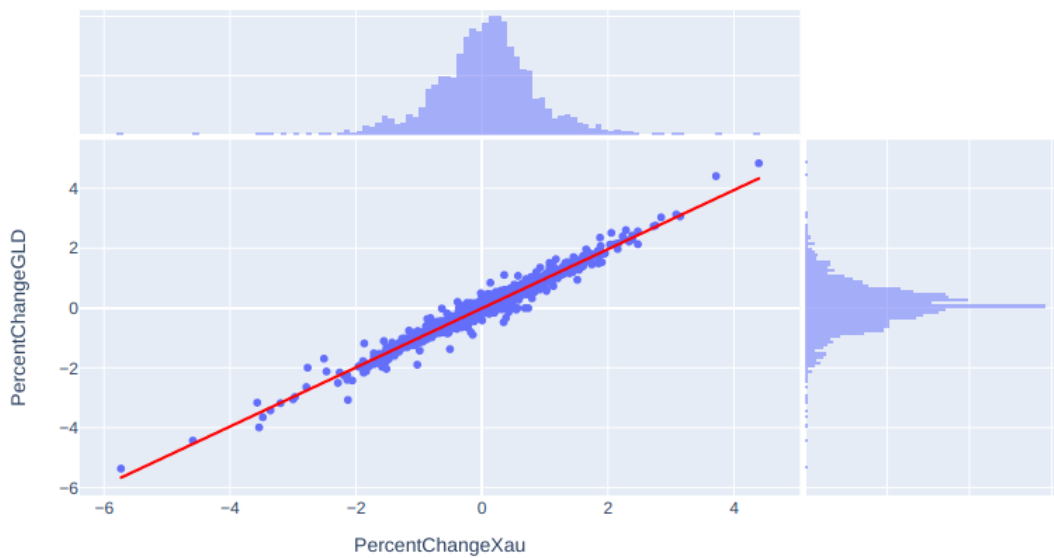
รูปที่ 41: ความสัมพันธ์ระหว่างเปอร์เซ็นต์การเปลี่ยนแปลงราคาทองคำกับดัชนีความผันผวนทองคำ

Correlation between Change in Gold Price and Change in Fed Interest Rate is: 0.00




รูปที่ 42: ความสัมพันธ์ระหว่างเปอร์เซ็นต์การเปลี่ยนแปลงราคาทองคำกับอัตราดอกเบี้ยระหว่างธนาคารของสหรัฐฯ

Correlation between Change in Gold Price and Change in GLD is: 0.98



รูปที่ 43: ความสัมพันธ์ระหว่างเปอร์เซ็นต์การเปลี่ยนแปลงราคาทองคำกับดัชนี SPDR® Gold Shares (GLD)

Correlation between Change in Gold Price and Change in SPY is: 0.07



รูปที่ 44: ความสัมพันธ์ระหว่างเปอร์เซ็นต์การเปลี่ยนแปลงราคาทองคำกับดัชนี SPDR S&P 500 ETF Trust (SPY)

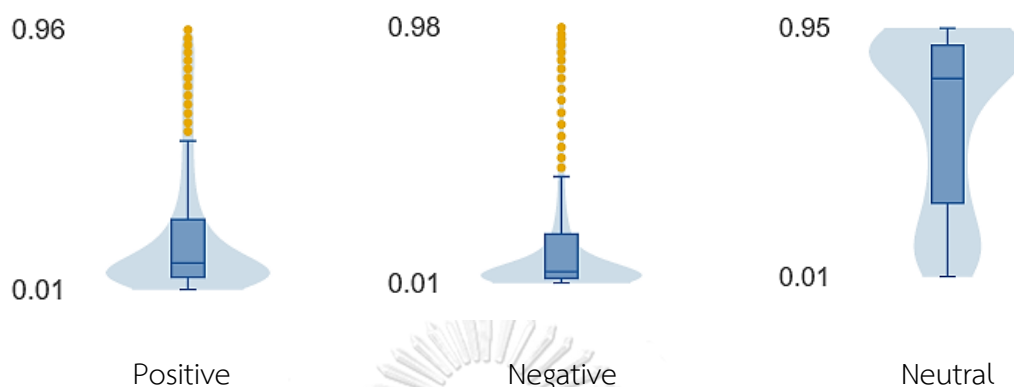
Correlation between Change in Gold Price and Change in Bond is: -0.29



รูปที่ 45: ความสัมพันธ์ระหว่างเปอร์เซ็นต์การเปลี่ยนแปลงราคาทองคำกับอัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐอเมริกา 10 ปี

4.1.3 ภาพรวมค่าความรู้สึก (Sentiment)

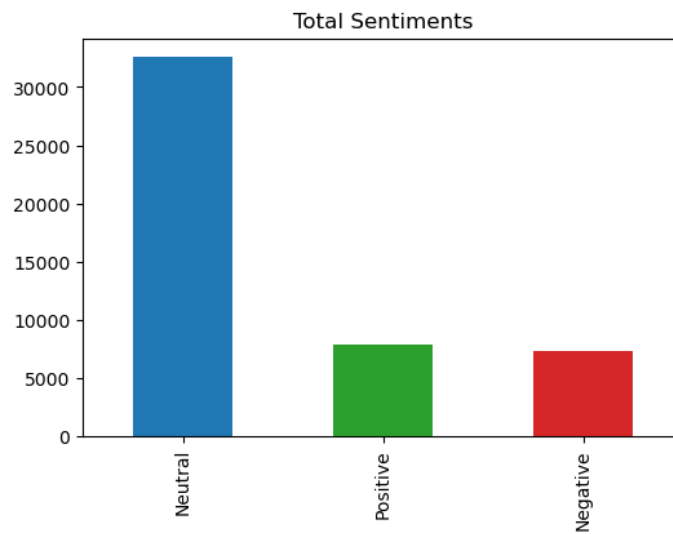
ค่าความรู้สึกจากข้อความทวิตของผู้เชี่ยวชาญด้านการลงทุนทองคำ 10 ท่านถูกวิเคราะห์ดังนี้



รูปที่ 46: เปรียบเทียบการแจกแจงของค่าความรู้สึกจากข้อความทวิตทั้งหมด 47,317 ข้อความ


ตารางที่ 12: อธิบายค่าความรู้สึกด้วยค่าสถิติ จากข้อความทวิตทั้งหมด 47,317 ข้อความ

| ค่าสถิติ | Positive | Negative | Neutral |
|--------------------------------------|--------------|--------------|---------|
| Minimum | 0.007 | 0.007 | 0.009 |
| Maximum | 0.958 | 0.957 | 0.952 |
| Mean | 0.214 | 0.178 | 0.608 |
| Standard deviation | 0.243 | 0.259 | 0.322 |
| 25 th Percentile (1. Q) | 0.026 | 0.025 | 0.288 |
| 50 th Percentile (Median) | 0.105 | 0.050 | 0.761 |
| 75 th Percentile (3. Q) | 0.263 | 0.192 | 0.887 |
| IQR | 0.211 | 0.168 | 0.599 |
| Outliers | 148 (0.310%) | 379 (0.793%) | 0 |

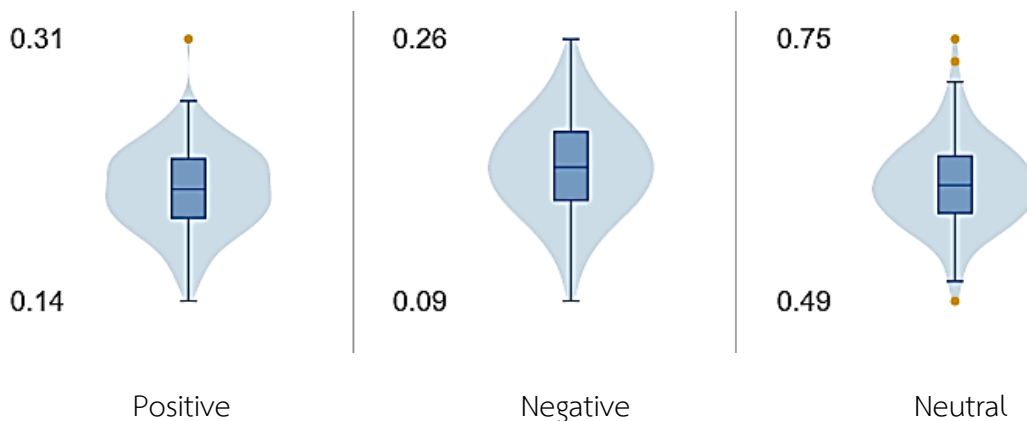


รูปที่ 47: แบ่งประเภทของค่าความรู้สึกจากข้อความทวิตทั้งหมด 47,317 ข้อความ

ผลวิเคราะห์จากข้อความทวิตทั้งหมด 47,317 ข้อความเบื้องต้นพบว่า ค่าต่ำสุด (Minimum) ค่าสูงสุด (Maximum) และค่าเบี่ยงเบนมาตรฐาน (Standard deviation) ของค่าความรู้สึก Positive และ Negative ใกล้เคียงกัน ส่วนค่าเฉลี่ยเลขคณิต (Mean) ของ Neutral มีค่ามากที่สุด นอกจากนี้ ผลค่าความรู้สึก Neutral มีจำนวนมากที่สุด



รูปที่ 48: เปรียบเทียบการแจกแจงของค่าความรู้สึกเฉลี่ยตามวันทั้งหมด 1,562 วัน



รูปที่ 49: เปรียบเทียบการแจกแจงของค่าความรู้สึกเฉลี่ยตามสัปดาห์ ทั้งหมด 313 สัปดาห์

ตารางที่ 13: อธิบายค่าความรู้สึกที่คำนวณเฉลี่ยตามรายวันและรายสัปดาห์

| | Positive | | Negative | | Neutral | |
|--------------------------------------|----------------|---------------|---------------|--------|---------------|---------------|
| | Daily | Weekly | Daily | Weekly | Daily | Weekly |
| Minimum | 0.054 | 0.139 | 0.019 | 0.093 | 0.238 | 0.493 |
| Maximum | 0.600 | 0.315 | 0.517 | 0.258 | 0.912 | 0.751 |
| Mean | 0.221 | 0.214 | 0.182 | 0.177 | 0.596 | 0.609 |
| Standard deviation | 0.063 | 0.029 | 0.067 | 0.032 | 0.087 | 0.044 |
| 25 th Percentile (1. Q) | 0.180 | 0.195 | 0.137 | 0.156 | 0.452 | 0.580 |
| 50 th Percentile (Median) | 0.218 | 0.214 | 0.178 | 0.177 | 0.597 | 0.607 |
| 75 th Percentile (3. Q) | 0.2556 | 0.234 | 0.224 | 0.199 | 0.650 | 0.636 |
| IQR | 0.076 | 0.040 | 0.088 | 0.043 | 0.107 | 0.056 |
| Outliers | 11 (0.704%) | 2 (0.635%) | 8 (0.512%) | 0 | 15 (0.96%) | 2 (0.635%) |

แนวคิดการวิเคราะห์

1. การวิเคราะห์ส่วนที่ 1

เป็นการวิเคราะห์เพื่อตรวจสอบราคา ประโยชน์ที่มาจากข้อความทวิตของผู้เชี่ยวชาญด้านการลงทุนทองคำ ว่ากำลังให้สัญญาณว่าราคาทองคำในวันถัดไปหรือสัปดาห์ถัดไปมีทิศทางอย่างไร แบ่งการทดสอบออกเป็นรายวันและรายสัปดาห์

2. การวิเคราะห์ส่วนที่ 2

เป็นการวิเคราะห์เพื่อทดสอบว่าค่าความรู้สึกร่วมกับตัวแปรคาดการณ์ที่สำคัญ ได้แก่ ดัชนีเงินดอลลาร์สหรัฐ ดัชนีความผันผวนทองคำ อัตราดอกเบี้ยระหว่างธนาคารของสหรัฐฯ ดัชนี SPDR® Gold Shares (GLD) ดัชนี SPDR S&P 500 ETF Trust (SPY) และอัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐอเมริกา 10 ปี เพื่อใช้ในการคาดการณ์ทิศทางราคาทองคำ แบ่งการทดสอบออกเป็น

กรณีที่ 1

1.1 ทดสอบโดยใช้เปอร์เซ็นต์การเปลี่ยนแปลงรายวันตัวแปรคาดการณ์ที่สำคัญ (6 ตัวแปร) ร่วมกับค่าความรู้สึก (Positive, Negative และ Neutral) ของแต่ละข้อความ Tweet หลังจากผสานข้อมูลทั้ง 9 ฟีเจอร์แล้วได้จำนวน เร็คคอร์ดทั้งหมด 47,317 เร็คคอร์ด

| date | Positive | Negative | Neutral | PercentChangeGVZ | PercentChangeDx | PercentChangeGLD | PercentChangeSPY | PercentChangeBond | PercentChangeDFF |
|------------|----------|----------|----------|------------------|-----------------|------------------|------------------|-------------------|------------------|
| 2022-04-30 | 0.098723 | 0.839269 | 0.062008 | 4.37 | -0.64 | -0.01 | -3.70 | 3.72 | 0.000000 |
| 2019-09-09 | 0.027325 | 0.056309 | 0.916366 | 0.07 | -0.11 | -0.37 | 0.05 | 5.58 | 0.004717 |
| 2020-03-26 | 0.045921 | 0.044239 | 0.909840 | -7.59 | -1.68 | 1.28 | 5.84 | -2.41 | 0.000000 |
| 2020-06-20 | 0.445265 | 0.031999 | 0.522736 | -0.22 | 0.21 | 1.10 | -1.01 | -1.85 | 0.000000 |
| 2019-03-09 | 0.604270 | 0.188477 | 0.207253 | 4.75 | -0.71 | 0.64 | 0.47 | -0.66 | 0.000000 |
| 2020-03-25 | 0.039320 | 0.030484 | 0.930195 | 0.37 | -0.97 | -1.37 | 1.50 | 1.28 | -0.166667 |
| 2022-02-28 | 0.401739 | 0.092931 | 0.505330 | 13.97 | 0.10 | 1.04 | -0.26 | -7.55 | 0.000000 |
| 2018-09-24 | 0.099138 | 0.020128 | 0.880735 | 1.95 | -0.03 | -0.02 | -0.33 | 0.73 | 0.005208 |
| 2021-10-16 | 0.955451 | 0.018247 | 0.026303 | -1.83 | -0.02 | -1.59 | 0.76 | 3.81 | 0.000000 |
| 2021-01-19 | 0.077392 | 0.010987 | 0.911621 | -0.89 | -0.29 | 0.85 | 0.79 | -0.77 | 0.000000 |

รูปที่ 50: ตัวอย่างข้อมูลนำเข้าของการวิเคราะห์ส่วนที่ 2 กรณีที่ 1 (1.1) (แสดงแบบสุ่ม)

1.2 ทดสอบโดยใช้เปอร์เซ็นต์การเปลี่ยนแปลงรายสัปดาห์ตัวแปรคาดการณ์ที่สำคัญ (6 ตัวแปร) ร่วมกับค่าความรู้สึก (Positive, Negative และ Neutral) ของแต่ละข้อความ Tweet หลังจากผสานข้อมูลทั้ง 9 ฟีเจอร์แล้วได้จำนวน เร็คคอร์ดทั้งหมด 47,317 เร็คคอร์ด

| WeekYear | Positive | Negative | Neutral | PercentChangeGVZ | PercentChangeDx | PercentChangeGLD | PercentChangeSPY | PercentChangeBond | PercentChangeDFF |
|----------|----------|----------|----------|------------------|-----------------|------------------|------------------|-------------------|------------------|
| 08/2020 | 0.465677 | 0.111807 | 0.422516 | 34.71 | -1.14 | -4.09 | -11.16 | -21.02 | 0.000006 |
| 52/2017 | 0.852819 | 0.046468 | 0.100713 | 2.74 | -0.19 | 1.36 | 2.46 | 2.95 | -0.009054 |
| 19/2020 | 0.517763 | 0.053296 | 0.428941 | -5.06 | 0.67 | 2.19 | -2.11 | -5.89 | 0.000000 |
| 18/2022 | 0.047790 | 0.049072 | 0.903138 | 13.31 | 0.87 | -3.78 | -2.34 | -6.84 | 0.216450 |
| 05/2021 | 0.080184 | 0.614343 | 0.305473 | -3.32 | -0.62 | 0.52 | 1.27 | 3.53 | 0.020408 |
| 40/2021 | 0.170193 | 0.032081 | 0.797726 | -3.89 | -0.14 | 0.67 | 1.83 | -2.36 | 0.000000 |
| 28/2021 | 0.102801 | 0.156187 | 0.741012 | -0.48 | 0.24 | -0.50 | 1.99 | -1.46 | 0.000000 |
| 15/2021 | 0.134809 | 0.069019 | 0.796172 | 2.74 | -0.76 | 0.03 | -0.12 | -1.94 | 0.000000 |
| 21/2018 | 0.028142 | 0.765923 | 0.205935 | 2.62 | 0.00 | -0.58 | 0.53 | -0.99 | 0.000000 |
| 39/2017 | 0.121621 | 0.017097 | 0.861282 | -2.04 | 0.78 | -0.40 | 1.25 | 0.93 | -0.012315 |

รูปที่ 51: ตัวอย่างข้อมูลนำเข้าของการวิเคราะห์ส่วนที่ 2 กรณีที่ 1 (1.2) (แสดงแบบสุ่ม)

กรณีที่ 2

2.1 ทดสอบโดยใช้เปอร์เซ็นต์การเปลี่ยนแปลงรายวันของตัวแปรคาดการณ์ที่สำคัญ (6 ตัวแปร) ร่วมกับค่าความรู้สึก (Positive, Negative และ Neutral) เฉลี่ยของแต่ละวัน มีจำนวนเร็คคอร์ดทั้งหมดหลังการเตรียม 1,562 เร็คคอร์ด

2.2 ทดสอบโดยใช้เปอร์เซ็นต์การเปลี่ยนแปลงรายสัปดาห์ของตัวแปรคาดการณ์ที่สำคัญ (6 ตัวแปร) ร่วมกับค่าความรู้สึก (Positive, Negative และ Neutral) เฉลี่ยของแต่ละสัปดาห์ มีจำนวนเร็คคอร์ดทั้งหมดหลังการเตรียม 313 เร็คคอร์ด

กรณีที่ 3

3.1 ทดสอบโดยพิจารณารายวัน โดยจำนวนวันที่ปรากฏราคาทองทั้งหมด 1,562 วัน โดยใช้ตัวแปรคาดการณ์ที่สำคัญ (6 ตัวแปร) โดยไม่มีค่าความรู้สึกเข้าร่วม ดังนั้นข้อมูลที่นำมาใช้ทั้งหมด 1,562 เร็คคอร์ด

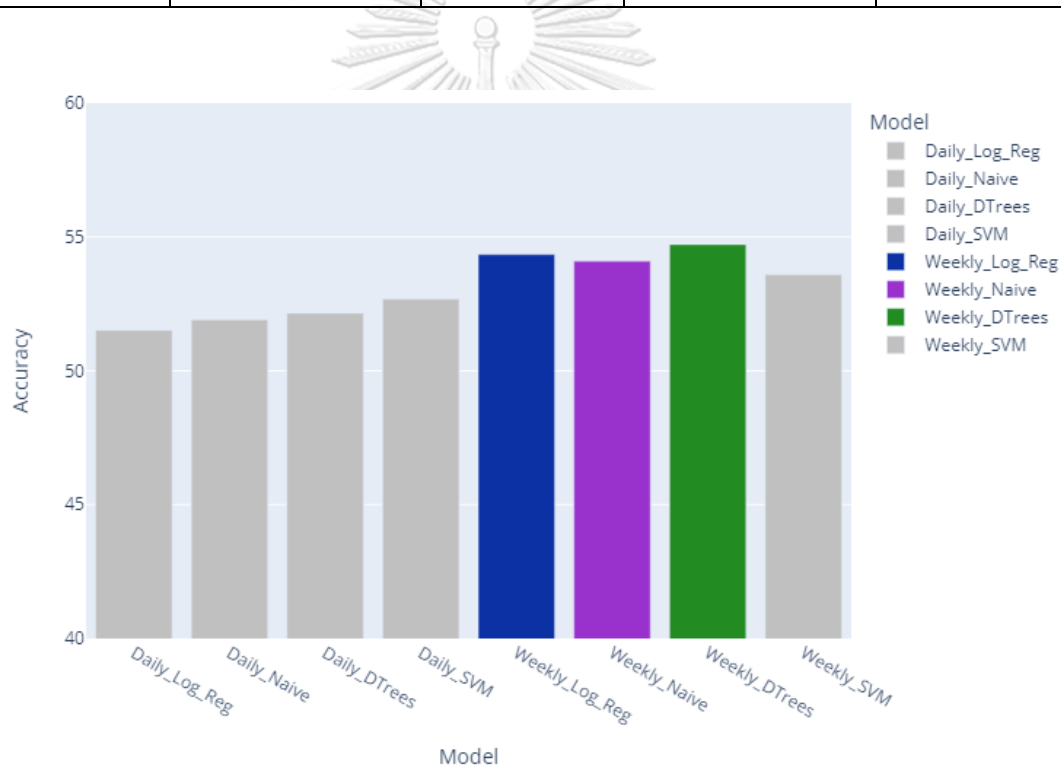
3.2 ทดสอบโดยพิจารณารายสัปดาห์ โดยจำนวนวันที่ปรากฏราคาทองทั้งหมด 313 สัปดาห์ โดยใช้ตัวแปรคาดการณ์ที่สำคัญ (6 ตัวแปร) โดยไม่มีค่าความรู้สึกเข้าร่วม ดังนั้นข้อมูลที่นำมาใช้ทั้งหมด 313 เร็คคอร์ด

4.2 ผลการวิเคราะห์ส่วนที่ 1

มีจำนวนเร็คคอร์ดทั้งหมดหลังการเตรียม 47,317 เร็คคอร์ด ได้ผลการวิเคราะห์ แต่ละเทคนิคดังต่อไปนี้

ตารางที่ 14: เปรียบเทียบค่าความถูกต้อง (Accuracy) ของแต่ละโมเดลของการวิเคราะห์ส่วนที่ 1

| รูปแบบการวิเคราะห์ | โมเดล | | | |
|--------------------|-----------------------------------|--------------------------|---------------------------------|-----------------------------|
| | การถดถอยโลจิสติก (Logistic Model) | นาอิว เบย์ (Naïve Bayes) | ต้นไม้ตัดสินใจ (Decision Trees) | เครื่องเวกเตอร์ค้ำยัน (SVM) |
| รายวัน | 0.515145 | 0.519089 | 0.531561 | 0.526838 |
| รายสัปดาห์ | 0.543453 | 0.540992 | 0.547196 | 0.5359280 |



รูปที่ 52: เปรียบเทียบค่าความถูกต้องของแต่ละโมเดลของการวิเคราะห์ส่วนที่ 1

พบว่าการวิเคราะห์รูปแบบรายสัปดาห์มีค่าความถูกต้องสูงที่สุดมีค่าเท่ากับ 54.7196% ด้วยโมเดลต้นไม้ตัดสินใจ รองลงมาคือค่าความถูกต้องเท่ากับ 54.3453% ด้วยโมเดลการถดถอยโลจิสติก ลำดับที่ 3 มีค่าความถูกต้องเท่ากับ 54.0992% ด้วยโมเดลนาอิว เบย์

ตารางที่ 15: Confusion matrix ของผลการวิเคราะห์ส่วนที่ 1 โดยพิจารณารายวันของแต่ละโมเดล

| Logistic Regression | | | | Decision Trees | | | |
|---------------------|------|-----------|------|----------------|------|-----------|------|
| Actual | | Predicted | | Actual | | Predicted | |
| | | DOWN | UP | | | DOWN | UP |
| | | DOWN | 2092 | | | 4411 | DOWN |
| UP | 2472 | 5221 | UP | 1995 | 5853 | | |

| Naïve Bayes | | | | Support Vector Machine | | | |
|-------------|------|-----------|------|------------------------|------|-----------|------|
| Actual | | Predicted | | Actual | | Predicted | |
| | | DOWN | UP | | | DOWN | UP |
| | | DOWN | 2086 | | | 4417 | DOWN |
| UP | 2410 | 5283 | UP | 2401 | 5447 | | |

ตารางที่ 16: Confusion matrix ของผลการวิเคราะห์ส่วนที่ 1 โดยพิจารณารายสัปดาห์ของแต่ละโมเดล

| Logistic Regression | | | | Decision Trees | | | |
|---------------------|------|-----------|------|----------------|------|-----------|------|
| Actual | | Predicted | | Actual | | Predicted | |
| | | DOWN | UP | | | DOWN | UP |
| | | DOWN | 1950 | | | 4377 | DOWN |
| UP | 2116 | 5779 | UP | 1977 | 5898 | | |


| Naïve Bayes | | | | Support Vector Machine | | | |
|-------------|------|-----------|------|------------------------|------|-----------|------|
| Actual | | Predicted | | Actual | | Predicted | |
| | | DOWN | UP | | | DOWN | UP |
| | | DOWN | 2102 | | | 4225 | DOWN |
| UP | 2303 | 5592 | UP | 2484 | 5391 | | |

4.3 ผลการวิเคราะห์ส่วนที่ 2 กรณีที่ 1

มีจำนวนเร็คคอร์ดทั้งหมดหลังการเตรียม 47,317 เร็คคอร์ด ได้ผลการวิเคราะห์ แต่ละเทคนิคดังต่อไปนี้

ตารางที่ 17: เปรียบเทียบค่าความถูกต้อง (Accuracy) ของแต่ละโมเดลของการวิเคราะห์ส่วนที่ 2 กรณีที่ 1

| รูปแบบการวิเคราะห์ | โมเดล | | | |
|--------------------|-----------------------------------|--------------------------|---------------------------------|-----------------------------|
| | การถดถอยโลจิสติก (Logistic Model) | นาอิว เบย์ (Naïve Bayes) | ต้นไม้ตัดสินใจ (Decision Trees) | เครื่องเวกเตอร์ค้ำยัน (SVM) |
| รายวัน | 0.92276 | 0.92164 | 0.96036 | 0.92206 |
| รายสัปดาห์ | 0.97736 | 0.97137 | 0.97646 | 0.97137 |



รูปที่ 53: เปรียบเทียบค่าความถูกต้องของแต่ละโมเดลของการวิเคราะห์ส่วนที่ 2 กรณีที่ 1

พบว่าผลการวิเคราะห์รูปแบบรายสัปดาห์มีค่าความถูกต้องสูงที่สุดมีค่าเท่ากับ 97.736% ด้วยโมเดลการถดถอยโลจิสติก รองลงมาคือค่าความถูกต้องเท่ากับ 97.646% ด้วยโมเดลต้นไม้ตัดสินใจ

ตารางที่ 18: Confusion matrix ของผลการวิเคราะห์ส่วนที่ 2 กรณีที่ 1 โดยพิจารณารายวันของแต่ละโมเดล

| Logistic Regression | | | | Decision Trees | | | |
|---------------------|-----------|------|------|------------------------|-----------|------|-----|
| Actual | Predicted | | | Actual | Predicted | | |
| | | DOWN | UP | | | DOWN | UP |
| | DOWN | 4946 | 598 | | DOWN | 6382 | 272 |
| | UP | 412 | 6084 | UP | 296 | 7382 | |
| Naïve Bayes | | | | Support Vector Machine | | | |
| Actual | Predicted | | | Actual | Predicted | | |
| | | DOWN | UP | | | DOWN | UP |
| | DOWN | 6205 | 449 | | DOWN | 6003 | 651 |
| | UP | 674 | 7004 | UP | 466 | 7212 | |

ตารางที่ 19: Confusion matrix ของผลการวิเคราะห์ส่วนที่ 2 กรณีที่ 1 โดยพิจารณารายสัปดาห์ของแต่ละโมเดล


| Logistic Regression | | | | Decision Trees | | | |
|---------------------|-----------|------|------|------------------------|-----------|------|-----|
| Actual | Predicted | | | Actual | Predicted | | |
| | | DOWN | UP | | | DOWN | UP |
| | DOWN | 6254 | 80 | | DOWN | 6185 | 149 |
| | UP | 245 | 7780 | UP | 189 | 7836 | |
| Naïve Bayes | | | | Support Vector Machine | | | |
| Actual | Predicted | | | Actual | Predicted | | |
| | | DOWN | UP | | | DOWN | UP |
| | DOWN | 6106 | 228 | | DOWN | 6257 | 77 |
| | UP | 183 | 7842 | UP | 334 | 7691 | |

4.4 ผลการวิเคราะห์ส่วนที่ 2 กรณีที่ 2

ทดสอบด้วยรูปแบบรายวันมีจำนวนเรีคคอร์ดทั้งหมด 1,562 เรีคคอร์ด และทดสอบด้วยรูปแบบรายสัปดาห์มีจำนวนเรีคคอร์ดทั้งหมด 313 เรีคคอร์ด ได้ผลการวิเคราะห์แต่ละเทคนิคดังต่อไปนี้

ตารางที่ 20: เปรียบเทียบค่าความถูกต้อง (Accuracy) ของแต่ละโมเดลของการวิเคราะห์ส่วนที่ 2 กรณีที่ 2

| รูปแบบการวิเคราะห์ | โมเดล | | | |
|--------------------|-----------------------------------|--------------------------|---------------------------------|-----------------------------|
| | การถดถอยโลจิสติก (Logistic Model) | นาอิว เบย์ (Naïve Bayes) | ต้นไม้ตัดสินใจ (Decision Trees) | เครื่องเวกเตอร์ค้ำยัน (SVM) |
| รายวัน | 0.54797 | 0.53091 | 0.50959 | 0.56484 |
| รายสัปดาห์ | 0.53684 | 0.60638 | 0.58510 | 0.53191 |



รูปที่ 54: เปรียบเทียบค่าความถูกต้องของแต่ละโมเดลของการวิเคราะห์ส่วนที่ 2 กรณีที่ 2

ตารางที่ 21: Confusion matrix ของผลการวิเคราะห์ส่วนที่ 2 กรณีที่ 2 โดยพิจารณารายวันของแต่ละโมเดล

| Logistic Regression | | | | Decision Trees | | | | | |
|---------------------|----|-----------|------|------------------------|-----|-----------|------|------|-----|
| Actual | | Predicted | | Actual | | Predicted | | | |
| | | | DOWN | | | UP | | DOWN | UP |
| | | DOWN | 28 | | | 193 | DOWN | 100 | 121 |
| | UP | 19 | 229 | UP | 109 | 139 | | | |
| Naïve Bayes | | | | Support Vector Machine | | | | | |
| Actual | | Predicted | | Actual | | Predicted | | | |
| | | | DOWN | | | UP | | DOWN | UP |
| | | DOWN | 35 | | | 186 | DOWN | 63 | 228 |
| | UP | 34 | 214 | UP | 40 | 320 | | | |

ตารางที่ 22: Confusion matrix ของผลการวิเคราะห์ส่วนที่ 2 กรณีที่ 2 โดยพิจารณารายสัปดาห์ของแต่ละโมเดล


| Logistic Regression | | | | Decision Trees | | | | | |
|---------------------|----|-----------|------|------------------------|----|-----------|------|------|----|
| Actual | | Predicted | | Actual | | Predicted | | | |
| | | | DOWN | | | UP | | DOWN | UP |
| | | DOWN | 11 | | | 31 | DOWN | 20 | 18 |
| | UP | 13 | 40 | UP | 21 | 35 | | | |
| Naïve Bayes | | | | Support Vector Machine | | | | | |
| Actual | | Predicted | | Actual | | Predicted | | | |
| | | | DOWN | | | UP | | DOWN | UP |
| | | DOWN | 11 | | | 27 | DOWN | 0 | 44 |
| | UP | 10 | 46 | UP | 0 | 50 | | | |

4.5 ผลการวิเคราะห์ส่วนที่ 2 กรณีที่ 3

ทดสอบด้วยรูปแบบรายวันมีจำนวนเรีคคอร์ดทั้งหมด 1,562 เรีคคอร์ด และทดสอบด้วยรูปแบบรายสัปดาห์มีจำนวนเรีคคอร์ดทั้งหมด 313 เรีคคอร์ด ได้ผลการวิเคราะห์แต่ละเทคนิคดังต่อไปนี้

ตารางที่ 23: เปรียบเทียบค่าความถูกต้อง (Accuracy) ของแต่ละโมเดลของการวิเคราะห์ส่วนที่ 2 กรณีที่ 3

| รูปแบบการวิเคราะห์ | โมเดล | | | |
|--------------------|-----------------------------------|--------------------------|---------------------------------|-----------------------------|
| | การถดถอยโลจิสติก (Logistic Model) | นาอิว เบย์ (Naïve Bayes) | ต้นไม้ตัดสินใจ (Decision Trees) | เครื่องเวกเตอร์ค้ำยัน (SVM) |
| รายวัน | 0.53944 | 0.53091 | 0.4840 | 0.52878 |
| รายสัปดาห์ | 0.52127 | 0.52127 | 0.60638 | 0.53191 |




รูปที่ 55: เปรียบเทียบค่าความถูกต้องของแต่ละโมเดลของการวิเคราะห์ส่วนที่ 2 กรณีที่ 3

ตารางที่ 24: Confusion matrix ของผลการวิเคราะห์ส่วนที่ 2 กรณีที่ 3 โดยพิจารณารายวันของแต่ละโมเดล

| Logistic Regression | | | | Decision Trees | | | |
|---------------------|----|-----------|----|------------------------|-----|-----------|------|
| Actual | | Predicted | | Actual | | Predicted | |
| | | DOWN | UP | | | DOWN | UP |
| | | DOWN | 25 | | | 196 | DOWN |
| UP | 20 | 228 | UP | 122 | 126 | | |
| Naïve Bayes | | | | Support Vector Machine | | | |
| Actual | | Predicted | | Actual | | Predicted | |
| | | DOWN | UP | | | DOWN | UP |
| | | DOWN | 35 | | | 186 | DOWN |
| UP | 34 | 214 | UP | 0 | 248 | | |

ตารางที่ 25: Confusion matrix ของผลการวิเคราะห์ส่วนที่ 2 กรณีที่ 3 โดยพิจารณารายสัปดาห์ของแต่ละโมเดล

| Logistic Regression | | | | Decision Trees | | | |
|---------------------|----|-----------|----|------------------------|----|-----------|------|
| Actual | | Predicted | | Actual | | Predicted | |
| | | DOWN | UP | | | DOWN | UP |
| | | DOWN | 7 | | | 37 | DOWN |
| UP | 8 | 42 | UP | 14 | 36 | | |
| Naïve Bayes | | | | Support Vector Machine | | | |
| Actual | | Predicted | | Actual | | Predicted | |
| | | DOWN | UP | | | DOWN | UP |
| | | DOWN | 15 | | | 29 | DOWN |
| UP | 16 | 34 | UP | 0 | 50 | | |



รูปที่ 56: เปรียบเทียบค่าความถูกต้องของแต่ละโมเดลของการวิเคราะห์ส่วนที่ 2 กรณีที่ 2 และ 3

จากรูปที่ 56 พบว่าค่าความถูกต้อง (Accuracy) ของแต่ละโมเดลทั้งรูปแบบการวิเคราะห์รายวันและรายสัปดาห์ของชุดข้อมูลที่มีฟีเจอร์ข้อมูลค่าความรู้สึก (Positive, Negative, Neutral) ร่วมกับตัวแปรคาดการณ์ราคาทองคำที่สำคัญ (6 ตัวแปร) มีประสิทธิภาพการวิเคราะห์ที่ดีกว่าชุดข้อมูลที่ไม่มีฟีเจอร์ค่าความรู้สึก ยกเว้นโมเดลต้นไม้ตัดสินใจที่ชุดข้อมูลที่ไม่มีฟีเจอร์ค่าความรู้สึกสามารถเรียนรู้และวิเคราะห์ได้ดีกว่าชุดข้อมูลที่มีฟีเจอร์ข้อมูลค่าความรู้สึก

ตารางที่ 26: เปรียบเทียบค่า Precision Recall และ F1-Score ของการวิเคราะห์ส่วนที่ 1

| เทคนิคการวิเคราะห์ | ตัววัดประสิทธิภาพ | ส่วนที่ 1 | | | |
|----------------------|-------------------|-----------|------|------------|------|
| | | รายวัน | | รายสัปดาห์ | |
| ต้นไม้ตัดสินใจ | Precision | DOWN | 0.48 | DOWN | 0.49 |
| | | UP | 0.56 | UP | 0.57 |
| | Recall | DOWN | 0.28 | DOWN | 0.30 |
| | | UP | 0.76 | UP | 0.75 |
| | F1-score | DOWN | 0.35 | DOWN | 0.37 |
| | | UP | 0.65 | UP | 0.65 |
| นาอึฟ เบย์ | Precision | DOWN | 0.46 | DOWN | 0.47 |
| | | UP | 0.56 | UP | 0.57 |
| | Recall | DOWN | 0.28 | DOWN | 0.32 |
| | | UP | 0.73 | UP | 0.70 |
| | F1-score | DOWN | 0.35 | DOWN | 0.38 |
| | | UP | 0.63 | UP | 0.63 |
| การถดถอยโลจิสติก | Precision | DOWN | 0.46 | DOWN | 0.47 |
| | | UP | 0.56 | UP | 0.56 |
| | Recall | DOWN | 0.30 | DOWN | 0.22 |
| | | UP | 0.72 | UP | 0.80 |
| | F1-score | DOWN | 0.36 | DOWN | 0.30 |
| | | UP | 0.63 | UP | 0.66 |
| เครื่องเวกเตอร์คำย่น | Precision | DOWN | 0.46 | DOWN | 0.47 |
| | | UP | 0.56 | UP | 0.57 |
| | Recall | DOWN | 0.32 | DOWN | 0.35 |
| | | UP | 0.69 | UP | 0.75 |
| | F1-score | DOWN | 0.38 | DOWN | 0.40 |
| | | UP | 0.62 | UP | 0.62 |

ตารางที่ 27: เปรียบเทียบค่า Precision Recall และ F1-Score ของการวิเคราะห์ส่วนที่ 2 กรณีที่ 1

| เทคนิคการวิเคราะห์ | ตัววัดประสิทธิภาพ | ส่วนที่ 2 กรณีที่ 1 | | | |
|----------------------|-------------------|---------------------|------|------------|------|
| | | รายวัน | | รายสัปดาห์ | |
| ต้นไม้ตัดสินใจ | Precision | DOWN | 0.96 | DOWN | 0.97 |
| | | UP | 0.97 | UP | 0.98 |
| | Recall | DOWN | 0.97 | DOWN | 0.98 |
| | | UP | 0.97 | UP | 0.98 |
| | F1-score | DOWN | 0.97 | DOWN | 0.97 |
| | | UP | 0.97 | UP | 0.98 |
| นาอึฟ เบย์ | Precision | DOWN | 0.90 | DOWN | 0.97 |
| | | UP | 0.94 | UP | 0.97 |
| | Recall | DOWN | 0.93 | DOWN | 0.96 |
| | | UP | 0.91 | UP | 0.98 |
| | F1-score | DOWN | 0.92 | DOWN | 0.97 |
| | | UP | 0.93 | UP | 0.97 |
| การถดถอยโลจิสติก | Precision | DOWN | 0.92 | DOWN | 0.96 |
| | | UP | 0.91 | UP | 0.99 |
| | Recall | DOWN | 0.89 | DOWN | 0.99 |
| | | UP | 0.94 | UP | 0.97 |
| | F1-score | DOWN | 0.91 | DOWN | 0.97 |
| | | UP | 0.92 | UP | 0.98 |
| เครื่องเวกเตอร์คำยัน | Precision | DOWN | 0.93 | DOWN | 0.95 |
| | | UP | 0.91 | UP | 0.99 |
| | Recall | DOWN | 0.90 | DOWN | 0.99 |
| | | UP | 0.94 | UP | 0.96 |
| | F1-score | DOWN | 0.91 | DOWN | 0.97 |
| | | UP | 0.93 | UP | 0.97 |

ตารางที่ 28: เปรียบเทียบค่า Precision Recall และ F1-Score ของการวิเคราะห์ส่วนที่ 2 กรณีที่ 2 และ กรณีที่ 3 (เปรียบเทียบระหว่างมีค่า Sentiment และ ไม่มีค่า Sentiment เป็นตัวแปร)

| เทคนิคการวิเคราะห์ | ตัววัดประสิทธิภาพ | | ส่วนที่ 2 กรณีที่ 2 | | ส่วนที่ 2 กรณีที่ 3 | |
|----------------------|-------------------|------|---------------------|------------|---------------------|------------|
| | | | รายวัน | รายสัปดาห์ | รายวัน | รายสัปดาห์ |
| ต้นไม้ตัดสินใจ | Precision | DOWN | 0.48 | 0.55 | 0.55 | 0.65 |
| | | UP | 0.53 | 0.59 | 0.57 | 0.62 |
| | Recall | DOWN | 0.45 | 0.53 | 0.43 | 0.45 |
| | | UP | 0.56 | 0.61 | 0.69 | 0.78 |
| | F1-score | DOWN | 0.47 | 0.54 | 0.48 | 0.53 |
| | | UP | 0.55 | 0.60 | 0.62 | 0.69 |
| นาอ็ฟ เบย์ | Precision | DOWN | 0.51 | 0.52 | 0.52 | 0.48 |
| | | UP | 0.54 | 0.63 | 0.56 | 0.54 |
| | Recall | DOWN | 0.16 | 0.29 | 0.38 | 0.34 |
| | | UP | 0.86 | 0.82 | 0.69 | 0.68 |
| | F1-score | DOWN | 0.24 | 0.37 | 0.44 | 0.40 |
| | | UP | 0.66 | 0.71 | 0.62 | 0.60 |
| การถดถอยโลจิสติก | Precision | DOWN | 0.60 | 0.46 | 0.57 | 0.47 |
| | | UP | 0.54 | 0.56 | 0.54 | 0.53 |
| | Recall | DOWN | 0.13 | 0.26 | 0.12 | 0.16 |
| | | UP | 0.92 | 0.75 | 0.92 | 0.84 |
| | F1-score | DOWN | 0.21 | 0.33 | 0.19 | 0.24 |
| | | UP | 0.68 | 0.65 | 0.68 | 0.65 |
| เครื่องเวกเตอร์คำย่น | Precision | DOWN | 0 | 0 | 0 | 0 |
| | | UP | 0.53 | 0.53 | 0.53 | 0.53 |
| | Recall | DOWN | 0 | 0 | 0 | 0 |
| | | UP | 1 | 1 | 1 | 1 |
| | F1-score | DOWN | 0 | 0 | 0 | 0 |
| | | UP | 0.69 | 0.69 | 0.69 | 0.69 |

4.6 วิจารณ์ผลการวิเคราะห์


ผลการวิเคราะห์ของแต่ละโมเดลการจำแนก (Classification models) หากใช้ค่าความถูกต้อง (Accuracy) เป็นเกณฑ์การเปรียบเทียบประสิทธิภาพของโมเดล พบว่า

ผลการวิเคราะห์ส่วนที่ 1 การวิเคราะห์ด้วยวิธีการประมวลภาษาธรรมชาติโดยพิจารณารายสัปดาห์ของทุกโมเดลมีประสิทธิภาพการเรียนรู้ที่ดีกว่ารายวัน

ผลการวิเคราะห์ส่วนที่ 2 กรณีที่ 1 ประสิทธิภาพของแต่ละโมเดล ทั้งรูปแบบการพิจารณา รายวันและรายสัปดาห์ล้วนมีค่าความถูกต้องมากกว่า 90% จึงตั้งข้อสังเกตค่าความถูกต้องเหล่านี้ด้วยวิธี Feature importance เพื่อวัดความสำคัญและความเหมาะสมของแต่ละฟีเจอร์ในชุดข้อมูล ผู้วิจัย นำโมเดลที่มีค่าความถูกต้องสูงที่สุด 2 อันดับแรกคือ โมเดลการถดถอยโลจิสติก และโมเดลต้นไม้ตัดสินใจ ที่เป็นรูปแบบการพิจารณารายสัปดาห์มาทำการวิเคราะห์

ตารางที่ 29: ค่าความสำคัญของฟีเจอร์ในข้อมูลการวิเคราะห์ส่วนที่ 2 กรณีที่ 1 ด้วยโมเดลการถดถอยโลจิสติก

| Feature index (ลำดับฟีเจอร์) | Feature name (ชื่อฟีเจอร์) | Importance score (ค่าความสำคัญ) |
|---------------------------------|--------------------------------|------------------------------------|
| Feature 0 | Positive Sentiment | 0.03632 |
| Feature 1 | Negative Sentiment | -0.10146 |
| Feature 2 | Neutral Sentiment | 0.08344 |
| Feature 3 | Percent Change in GVZ | 0.03082 |
| Feature 4 | Percent Change in Dollar Index | -0.45335 |
| Feature 5 | Percent Change in GLD | 4.31796 |
| Feature 6 | Percent Change in SPY | -0.00746 |
| Feature 7 | Percent Change in TNX | 0.03656 |
| Feature 8 | Percent Change in EFRF | 7.58345 |




รูปที่ 57: เปรียบเทียบค่าความสำคัญของพีเจอร์ในข้อมูลการวิเคราะห์ส่วนที่ 2 กรณีที่ 1 ด้วยโมเดลการถดถอยโลจิสติก

พบว่า มี 2 พีเจอร์ที่มีค่าโดดเด่นในชุดข้อมูลนี้คือ Percent Change in GLD (ดัชนี SPDR® Gold Shares) และ Percent Change in EFR (อัตราดอกเบี้ยระหว่างธนาคารของสหรัฐฯ) ค่าความสำคัญของพีเจอร์สำหรับโมเดลการถดถอยโลจิสติก ให้ค่าเดียวกับค่าสัมประสิทธิ์การถดถอย (Regression Coefficients) ซึ่งสะท้อนไปที่ค่า log odds สามารถบอกนัยของทิศทางอิทธิพลได้ ดังนั้น Percent Change in GLD และ Percent Change in EFR จึงเป็นตัวแปรสำคัญในการคาดการณ์ราคาทองคำมากกว่าตัวแปรตัวอื่น

ตารางที่ 30: ค่าความสำคัญของฟีเจอร์ในข้อมูลการวิเคราะห์ส่วนที่ 2 กรณีที่ 1 ด้วยโมเดลต้นไม้ตัดสินใจ

| Feature index (ลำดับฟีเจอร์) | Feature name (ชื่อฟีเจอร์) | Importance score (ค่าความสำคัญ) |
|---------------------------------|--------------------------------|------------------------------------|
| Feature 0 | Positive Sentiment | 0.01376 |
| Feature 1 | Negative Sentiment | 0.01439 |
| Feature 2 | Neutral Sentiment | 0.01322 |
| Feature 3 | Percent Change in GVZ | 0.00079 |
| Feature 4 | Percent Change in Dollar Index | 0.05589 |
| Feature 5 | Percent Change in GLD | 0.89418 |
| Feature 6 | Percent Change in SPY | 0.00637 |
| Feature 7 | Percent Change in TNX | 0.00080 |
| Feature 8 | Percent Change in EFFF | 0.00060 |



รูปที่ 58: เปรียบเทียบค่าความสำคัญของฟีเจอร์ในข้อมูลการวิเคราะห์ส่วนที่ 2 กรณีที่ 1 ด้วยโมเดลต้นไม้ตัดสินใจ

พบว่าพีเจอร์ที่มีค่าโดดเด่นในชุดข้อมูลนี้คือ Percent Change in GLD (ดัชนี SPDR® Gold Shares) ค่าความสำคัญของพีเจอร์ของโมเดลต้นไม้ตัดสินใจ สามารถค้นหาเกณฑ์การคัดกรองที่ดีที่สุดจากบนลงล่าง (เช่นเดียวกับค่า Entropy หรือ Gini) ดังนั้น Percent Change in GLD จึงเป็นตัวแปร (โหนดต้นไม้) ที่สามารถลดความไม่แน่นอนให้น้อยที่สุด และเป็นการพยายามแยกชั้นของทิศทางราคาทองคำให้ได้สัดส่วนมากกว่าตัวแปรตัวอื่น (เพิ่ม certainty ลด randomness) หากลองนำส่วนหนึ่งของต้นไม้มาสังเกตจะพบว่า Percent Change in GLD เป็นโหนดสำคัญ ดังรูป

```

|--- PercentChangeGLD <= 0.01
|   |--- PercentChangeGLD <= -0.11
|   |   |--- PercentChangeGLD <= -0.16
|   |   |   |--- PercentChangeGVZ <= -5.86
|   |   |   |   |--- PercentChangeGVZ <= -5.95
|   |   |   |   |   |--- Positive <= 0.01
|   |   |   |   |   |   |--- class: 1
|   |   |   |   |   |--- Positive > 0.01
|   |   |   |   |   |   |--- Negative <= 0.97
|   |   |   |   |   |   |   |--- Neutral <= 0.95
|   |   |   |   |   |   |   |   |--- Neutral <= 0.26
|   |   |   |   |   |   |   |   |   |--- Neutral <= 0.26
|   |   |   |   |   |   |   |   |   |   |--- PercentChangeGLD <= -0.69
|   |   |   |   |   |   |   |   |   |   |   |--- truncated branch of depth 8
|   |   |   |   |   |   |   |   |   |   |   |--- PercentChangeGLD > -0.69
|   |   |   |   |   |   |   |   |   |   |   |   |--- truncated branch of depth 5
|   |   |   |   |   |   |   |   |   |   |   |--- Neutral > 0.26
|   |   |   |   |   |   |   |   |   |   |   |   |--- class: 1
|   |   |   |   |   |   |   |   |   |   |--- Neutral > 0.26
|   |   |   |   |   |   |   |   |   |   |   |--- PercentChangeDx <= 1.16
|   |   |   |   |   |   |   |   |   |   |   |   |--- Negative <= 0.03
|   |   |   |   |   |   |   |   |   |   |   |   |   |--- truncated branch of depth 9
|   |   |   |   |   |   |   |   |   |   |   |   |   |--- Negative > 0.03
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- truncated branch of depth 6
|   |   |   |   |   |   |   |   |   |   |   |   |   |--- PercentChangeDx > 1.16
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- Neutral <= 0.83
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- class: 0
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- Neutral > 0.83
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- truncated branch of depth 4
|   |   |   |   |   |   |   |   |   |   |   |   |   |--- Neutral > 0.95
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- PercentChangeGLD <= -0.53
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- class: 0
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- PercentChangeGLD > -0.53
|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |--- class: 1

```


รูปที่ 59: ตัวอย่างบางส่วนของโมเดลต้นไม้ตัดสินใจสำหรับในข้อมูลการวิเคราะห์ส่วนที่ 2 กรณีที่ 1

ผลการวิเคราะห์ส่วนที่ 2 กรณีที่ 2 ประสิทธิภาพของโมเดลที่มีรูปแบบการพิจารณารายวัน พบว่า โมเดลเวคเตอร์ค้ำยันเป็นโมเดลที่มีค่าความถูกต้องมากที่สุด ส่วนรูปแบบการพิจารณาราย สัปดาห์ พบว่า โมเดลที่มีค่าความถูกต้องมากที่สุดคือโมเดลนาอ็พ เบย์

ผลการวิเคราะห์ส่วนที่ 2 กรณีที่ 3 ประสิทธิภาพของโมเดลที่มีรูปแบบการพิจารณารายวัน พบว่า โมเดลการถดถอยโลจิสติกเป็นโมเดลที่มีค่าความถูกต้องมากที่สุด ส่วนรูปแบบการพิจารณาราย สัปดาห์ พบว่า โมเดลที่มีค่าความถูกต้องมากที่สุดคือโมเดลต้นไม้ตัดสินใจ รองลงมาคือโมเดลเวคเตอร์ ค้ำยัน หากใช้วิธี Feature importance เช่นเดิมเพื่อวัดความสำคัญและความเหมาะสมของแต่ละ ฟีเจอร์ในชุดข้อมูล ผู้วิจัยนำโมเดลที่มีค่าความถูกต้องสูงที่สุดอันดับแรก (โมเดลต้นไม้ตัดสินใจ) มา ทดสอบ

ตารางที่ 31: ค่าความสำคัญของฟีเจอร์ในข้อมูลการวิเคราะห์ส่วนที่ 2 กรณีที่ 3 ด้วยโมเดลต้นไม้ ตัดสินใจ

| Feature index (ลำดับฟีเจอร์) | Feature name (ชื่อฟีเจอร์) | Importance score (ค่าความสำคัญ) |
|---------------------------------|--------------------------------|------------------------------------|
| Feature 0 | Percent Change in GVZ | 0.14184 |
| Feature 1 | Percent Change in Dollar Index | 0.23757 |
| Feature 2 | Percent Change in GLD | 0.19231 |
| Feature 3 | Percent Change in SPY | 0.21611 |
| Feature 4 | Percent Change in TNX | 0.13491 |
| Feature 5 | Percent Change in EFRF | 0.07725 |



รูปที่ 60: เปรียบเทียบค่าความสำคัญของพีเจอร์ในข้อมูลการวิเคราะห์ส่วนที่ 2 กรณีที่ 3 ด้วยโมเดล
ต้นไม้ตัดสินใจ

พบว่า มี 2 พีเจอร์ที่มีค่าโดดเด่นในชุดข้อมูลนี้คือ Percent Change in Dollar Index (ดัชนี ดอลลาร์สหรัฐฯ) และ Percent Change in SPY (ดัชนี SPDR S&P 500 ETF Trust) ค่าความสำคัญ ของพีเจอร์สำหรับโมเดลการถดถอยโลจิสติก ให้ค่าเดียวกับค่าสัมประสิทธิ์การถดถอย (Regression Coefficients) ซึ่งสะท้อนไปที่ค่า log odds สามารถบอกนัยของทิศทางอิทธิพลได้ ดังนั้น Percent Change in Dollar Index (ดัชนี ดอลลาร์สหรัฐฯ) และ Percent Change in SPY (ดัชนี SPDR S&P 500 ETF Trust) จึงเป็นตัวแปรสำคัญในการคาดการณ์ราคาทองคำมากกว่าตัวแปรตัวอื่นสำหรับการ วิเคราะห์ส่วนที่ 2 กรณีที่ 3 ด้วยโมเดลต้นไม้ตัดสินใจ

บทที่ 5

สรุป อภิปรายผล และข้อเสนอแนะ

5.1 ข้อสรุป

การวิเคราะห์การคาดการณ์ราคาทองคำจากความรู้สึกของข้อความบนทวิตเตอร์โดยใช้เทคนิคการเรียนรู้ด้วยเครื่องครั้งนี้ ผู้วิจัยได้นำข้อมูลจากข้อความทวิตของผู้เชี่ยวชาญด้านการลงทุนทองคำ เป็นข้อมูลรายวัน ตั้งแต่เดือนมกราคม 2017 ถึง เดือนธันวาคม 2022 โดยที่มาของข้อมูลมาจากข้อคิดเห็นของผู้เชี่ยวชาญด้านการลงทุนทองคำจาก Twitter จำนวน 10 ท่าน โดยคัดเลือกจากการสังเกตจำนวนผู้ติดตามที่มากกว่า 20,000 ผู้ติดตามขึ้นไป และเป็นผู้เชี่ยวชาญที่ใช้งานทวิตเตอร์ 6 ปีขึ้นไป สำหรับข้อมูลเชิงปริมาณ ผู้วิจัยรวบรวม ราคาทองคำ (Gold spot) ดัชนีเงินดอลลาร์สหรัฐ ดัชนีความผันผวนทองคำ อัตราดอกเบี้ยระหว่างธนาคารของสหรัฐฯ ดัชนี SPDR® Gold Shares ดัชนี SPDR S&P 500 ETF Trust (SPY) และอัตราผลตอบแทนพันธบัตรรัฐบาลสหรัฐอเมริกา 10 ปี ตั้งแต่ มกราคม ปี 2017 ถึง ธันวาคม ปี 2022 ได้จำนวนข้อความหลังการเตรียมทั้งสิ้น 47,317 ข้อความ (เร็คคอร์ด) นำมาแปลงเข้าสู่รูปของ Dataframe ได้ 1,562 เร็คคอร์ด สำหรับนำไปวิเคราะห์รายวัน และ 313 เร็คคอร์ด สำหรับนำไปวิเคราะห์รายสัปดาห์

การวิเคราะห์แบ่งออกเป็น 2 ส่วนคือ ส่วนที่ 1 มีวัตถุประสงค์เพื่อการตรวจจับคำ และประโยคที่มาจากข้อความทวิตของผู้เชี่ยวชาญด้านการลงทุนทองคำ ว่ากำลังให้สัญญาณทิศทางราคาทองคำในวันถัดไปหรือสัปดาห์ถัดไปมีทิศทางอย่างไร ส่วนที่ 2 มีวัตถุประสงค์เพื่อทดสอบค่าความรู้สึกร่วมกับตัวแปรคาดการณ์อื่น ๆ เพื่อใช้ในการคาดการณ์ทิศทางราคาทองคำเป็นตัวแปรตาม โดยการวิเคราะห์ทั้ง 2 ส่วนนี้มีค่า ผลลัพธ์เป้าหมาย (Target value) ชุดเดียวกัน คือ พีเจอร์ “Prediction” ซึ่งถูกสร้างมาจากการเปลี่ยนแปลงของทิศทางราคาทองคำรายวัน และรายสัปดาห์ ในช่วงเวลาถัดไป เช่น วันถัดไป หรือสัปดาห์ถัดไป

ผลการวิเคราะห์ พบว่าค่า Accuracy ของการวิเคราะห์ด้วยวิธีการประมวลภาษาธรรมชาติ โดยพิจารณารายสัปดาห์ของทุกโมเดลมีประสิทธิภาพการเรียนรู้ที่ดีกว่ารายวัน ส่วนค่า Accuracy ของการวิเคราะห์ด้วยชุดข้อมูลตัวแปรคาดการณ์ แต่ละโมเดลทั้งรูปแบบการวิเคราะห์รายวันและรายสัปดาห์ของชุดข้อมูลที่มีตัวแปรข้อมูลค่าความรู้สึก (Positive, Negative, Neutral) ร่วมกับตัวแปรคาดการณ์ราคาทองคำที่สำคัญ (6 ตัวแปร) มีประสิทธิภาพการวิเคราะห์ที่ดีกว่าชุดข้อมูลที่ไม่มีพีเจอร์ค่าความรู้สึก การวิเคราะห์ผลครั้งนี้ทำให้ทราบว่า ตัวแปรค่าความรู้สึก หรือ Sentiment เป็นตัวแปร

ที่สามารถเพิ่มประสิทธิภาพโมเดลการเรียนรู้ด้วยเครื่องประเภทการจำแนกได้ และหากใช้ข้อมูลรูปแบบรายสัปดาห์ รายเดือน รายไตรมาส หรือระยะยาวกว่านี้ จะทำให้การคาดการณ์แม่นยำมากขึ้น

ผู้วิจัยขอคำชี้แนะ และบทสัมภาษณ์จาก คุณธีรรัฐ จุฑาวรากุล ผู้บริหารบริษัท อินเทอร์เน็ตเวิลด์เทรด จำกัด ผู้เชี่ยวชาญด้านการลงทุนทองคำ โดยคุณธีรรัฐ ให้คำแนะนำว่า “การคาดการณ์ราคาทองคำ สิ่งที่สำคัญมากคือ กรอบเวลาที่แตกต่างกัน จะได้ผลการวิเคราะห์ต่างกัน ตัวแปรที่นำมาใช้ต้องมีความสัมพันธ์กัน แต่เรื่องของราคาทองคำนั้นตัวแปรเชิงปริมาณ ยังไม่ใช่ตัวแปรสำคัญที่มีความแน่นอนเสมอไป ไม่ควรให้น้ำหนักความเชื่อถือมากเกินไป หากใช้ตัวแปรเชิงคุณภาพ เช่นตัวแปรประเภทข้อความจะต้องถ่วงน้ำหนักความสำคัญของข้อความ ตามช่วงเวลาและสถานการณ์ที่เกิดขึ้น”

5.2 ปัญหา และอุปสรรค

ปัญหาที่พบจากการวิเคราะห์การคาดการณ์ราคาทองคำจากความรู้สึกของข้อความบนทวิตเตอร์โดยใช้เทคนิคการเรียนรู้ด้วยเครื่องครั้งนี้ มีดังนี้

1. กระบวนการคำนวณค่าความรู้สึกด้วยเครื่องมือชื่อ FinBERT บนข้อมูลขนาดใหญ่ใช้ทรัพยากรคอมพิวเตอร์สูง

ปัญหา: เนื่องจากข้อมูลถูกรวบรวมมาเป็นรูปแบบข้อความที่มีขนาดใหญ่ แต่เครื่องมือที่ใช้ในการวิเคราะห์ข้อมูล (Jupyter Notebook) มีทรัพยากร (หรือ Integrated Development Environment, IDE) ที่จำกัด จึงต้องใช้เวลานานในการคำนวณค่าความรู้สึกได้อย่างครบถ้วน

แนวทางแก้ไข: นอกจากการแบ่งข้อมูลออกเป็นข้อมูลย่อย การติดตั้ง Jupyter Notebook บน GPU server ด้วย Google Cloud Platform ก็เป็นทางเลือกให้การคำนวณค่าความรู้สึกได้อย่างครบถ้วนและรวดเร็ว

2. จำนวนตัวแปรคาดการณ์และการเลือกใช้ตัวแปรคาดการณ์ที่นำมาคาดการณ์ราคาทองคำควรเป็นตัวแปรที่มีระดับความสัมพันธ์กับราคาทองคำอย่างมีนัยสำคัญ

ปัญหา: ตัวแปรคาดการณ์ที่มาจากตัวเลขทางเศรษฐกิจและตัวเลขดัชนีในตลาดหลักทรัพย์นั้นมีมากมาย ที่สามารถนำมาใช้ร่วมการคาดการณ์ สำหรับตัวแปรที่ถูกสุ่มนำมาใช้ในการวิเคราะห์ครั้งนี้หลายตัวมีระดับความสัมพันธ์ (Correlation) ราคาทองคำค่อนข้างน้อย

แนวทางแก้ไข: การเลือกใช้ใช้นั้นควรตรวจสอบและศึกษาระดับความสัมพันธ์ของตัวแปรกับราคาทองคำให้เหมาะสม และอย่างมีนัยสำคัญ

5.3 ข้อเสนอแนะ

การศึกษา “การคาดการณ์ทิศทางราคาทองคำจากความรู้สึกของข้อความบนทวิตเตอร์โดยใช้วิธีการเรียนรู้ด้วยเครื่อง” ในครั้งนี้เก็บข้อมูลย้อนหลังเพียง 6 ปี ข้อความข้อคิดเห็นที่ถูกรวบรวมมาวิเคราะห์นั้นอาจไม่ครอบคลุมที่เครื่องมือการวิเคราะห์จะสามารถจับทิศทางราคาทองคำได้อย่างแม่นยำ นอกจากนี้ควรแบ่งหรือคัดเลือกความถูกต้องของข้อความทวิตของผู้เชี่ยวชาญด้านทองคำแต่ละท่าน อาจจะได้ผลการวิเคราะห์ที่แตกต่างจากการศึกษาครั้งนี้

การศึกษาในครั้งต่อไปควรรวบรวม และศึกษางานวิจัยที่เกี่ยวข้องเพิ่มเติมอาจจะมีเทคนิคการเรียนรู้ด้วยเครื่องอื่นๆที่สามารถวิเคราะห์ได้อย่างมีประสิทธิภาพกว่า เลือกตัวแปรที่มีระดับความสัมพันธ์กับราคาทองคำมากขึ้น หรือทำการพิจารณากรอบเวลาที่ยาวขึ้น อาจจะทำให้การคาดการณ์แม่นยำมากขึ้น ทั้งนี้ควรคำนึงถึงปัจจัยที่เกิดขึ้นอย่างกะทันหันและไม่สามารถควบคุมได้ เช่น สถานการณ์ความไม่สงบในรัสเซีย-ยูเครน เหตุการณ์การระบาดโรคติดเชื้อไวรัสโคโรนา 2019 ฯลฯ ซึ่งราคาทองคำมักอ่อนไหวต่อข่าวเหตุการณ์ดังกล่าว

บรรณานุกรม

- Al-Shabi, M. (2020). Evaluating the performance of the most important Lexicons used to Sentiment analysis and opinions Mining. *IJCSNS*, 20(1), 1.
- Bollen, M. (2011). Zeng, 2011 Bollen J., Mao H., Zeng X. *Twitter mood predicts the stock market*, *Journal of Computational Science*, 2(1), 1-8.
- Brownlee, J. (2017). A gentle introduction to the bag-of-words model. *Machine Learning Mastery*, 21.
- Calvo, R. A., & Mac Kim, S. (2013). Emotions in text: dimensional and categorical models. *Computational Intelligence*, 29(3), 527-543.
- Collomb, A., Costea, C., Joyeux, D., Hasan, O., & Brunie, L. (2014). A study and comparison of sentiment analysis methods for reputation evaluation. *Rapport de recherche RR-LIRIS-2014-002*.
- Coronado, S., & Rojas, O. (2016). A study of co-movements between oil price, stock index and exchange rate under a cross-bicorrelation perspective: the case of Mexico. *arXiv preprint arXiv:1602.03271*.
- Deng, S., Huang, Z. J., Sinha, A. P., & Zhao, H. (2018). The interaction between microblog sentiment and stock return: An empirical examination. *MIS quarterly*, 42(3), 895-918.
- Dickinson, B., & Hu, W. (2015). Sentiment analysis of investor opinions on twitter. *Social Networking*, 4(03), 62.
- Drozдовica, J. (2023). Is gold a good investment right now? <https://capital.com/is-gold-a-good-investment-now>
- Farimani, S. A., Jahan, M. V., Fard, A. M., & Tabbakh, S. R. K. (2022). Investigating the informativeness of technical indicators and news sentiment in financial market price prediction. *Knowledge-Based Systems*, 247, 108742.
- Géron, A. (2017). Hands-on machine learning with scikit-learn and tensorflow: Concepts. *Tools, and Techniques to build intelligent systems*.
- Ghatak, K. (2022). Decision Tree Algorithm for Classification. <https://www.shiksha.com/online-courses/articles/decision-tree-algorithm-for->

classification/

- Golubova, A. (2021). Gold's 2021 drivers: Ballooning deficits, inflation and overvalued equities - WGC. <https://www.kitco.com/news/2021-01-14/Gold-s-2021-drivers-Ballooning-deficits-inflation-and-overvalued-equities-WGC.html>
- Huang, A. H., Wang, H., & Yang, Y. (2022). FinBERT: A large language model for extracting information from financial text. *Contemporary Accounting Research*, 14-15.
- Huang, Y. Y. a. M. C. S. U. a. A. (2020). FinBERT: A Pretrained Language Model for Financial Communications. <https://github.com/yya518/FinBERT>
- Junjie, Z., & Mengoni, P. (2020). *Spot Gold Price Prediction Using Financial News Sentiment Analysis*. Paper presented at the 2020 IEEE/WIC/ACM International Joint Conference on Web Intelligence and Intelligent Agent Technology (WI-IAT).
- Kedia, P. (2021). Create simple Bag-of-Words models. <https://medium.com/mlearning-ai/create-simple-bag-of-words-models-78b19578246>
- Kumar, A., & Jaiswal, A. (2020). Systematic literature review of sentiment analysis on Twitter using soft computing techniques. *Concurrency and Computation: Practice and Experience*, 32(1), e5107.
- Mai, F., Shan, Z., Bai, Q., Wang, X., & Chiang, R. H. (2018). How does social media impact Bitcoin value? A test of the silent majority hypothesis. *Journal of management information systems*, 35(1), 19-52.
- Müller, A. C., & Guido, S. (2016). *Introduction to machine learning with Python: a guide for data scientists*. " O'Reilly Media, Inc."
- Naithani, K., & Raiwani, Y. P. (2022). Realization of natural language processing and machine learning approaches for text based sentiment analysis. *Expert Systems*, e13114.
- Nti, I. K., Adekoya, A. F., & Weyori, B. A. (2020). Predicting Stock Market Price Movement Using Sentiment Analysis: Evidence From Ghana. *Appl. Comput. Syst.*, 25(1), 33-42.
- Onsumran, C., Thammaboosadee, S., & Kiattisin, S. (2015). *Gold price volatility prediction by text mining in economic indicators news*. Mahidol University.
- Pagolu, V. S., Reddy, K. N., Panda, G., & Majhi, B. (2016). *Sentiment analysis of Twitter data for predicting stock market movements*. Paper presented at the 2016

international conference on signal processing, communication, power and embedded system (SCOPE5).

- Peterson, R. L. (2016). *Trading on sentiment: The power of minds over markets*: John Wiley & Sons.
- Ranco, G., Aleksovski, D., Caldarelli, G., Grčar, M., & Mozetič, I. (2015). The effects of Twitter sentiment on stock price returns. *PloS one*, *10*(9), e0138441.
- Ren, J., Dong, H., Padmanabhan, B., & Nickerson, J. V. (2021). How does social media sentiment impact mass media sentiment? A study of news in the financial markets. *Journal of the Association for Information Science and Technology*, *72*(9), 1183-1197.
- Renault, T. (2017). Intraday online investor sentiment and return patterns in the US stock market. *Journal of Banking & Finance*, *84*, 25-40.
- Sharma, S., & Jain, A. (2020). Role of sentiment analysis in social media security and analytics. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, *10*(5), e1366.
- So, S. M., & Lei, V. U. (2015). On the relationship between investor sentiment, VIX and trading volume. *RISK GOVERNANCE & CONTROL: Financial markets and institutions*, *114*.
- Sul, H. K., Dennis, A. R., & Yuan, L. (2017a). Trading on twitter: Using social media sentiment to predict stock returns. *Decision Sciences*, *48*(3), 460.
- Sul, H. K., Dennis, A. R., & Yuan, L. (2017b). Trading on twitter: Using social media sentiment to predict stock returns. *Decision Sciences*, *48*(3), 457.
- Sul, H. K., Dennis, A. R., & Yuan, L. (2017c). Trading on twitter: Using social media sentiment to predict stock returns. *Decision Sciences*, *48*(3), 479.
- Srivastava, R., Bharti, P., & Verma, P. (2022). Comparative Analysis of Lexicon and Machine Learning Approach for Sentiment Analysis. *International Journal of Advanced Computer Science and Applications*, *13*(3).
- Wilson, L. (2022). Coming Rate Hikes By Fed Will Be Rocket Fuel for Gold & Silver Prices https://munknee.com/coming-rate-hikes-by-fed-will-be-rocket-fuel-for-gold-silver-prices/?utm_source=rss&utm_medium=rss&utm_campaign=coming-

rate-hikes-by-fed-will-be-rocket-fuel-for-gold-silver-prices

กิตติศักดิ์ เพชรรุ่งนภา. (2561). การจำแนกประเภทบทวิจารณ์ของผู้ใช้โซเชียลแอปพลิเคชันเพื่อการสร้าง
 ทิศเกิดสำหรับระบบติดตามปัญหา.

ข่าวแบบไหนที่ส่งผลกับราคาทองคำ. (2560). https://www.intergold.co.th/investor_core/new-investor-update-1/

เจนวิทย์ ชินกุลกิจนิวัฒน์. (2563). ดัชนี GOLD VIX.

<https://www.bangkokbiznews.com/blogs/columnist/125804>

ณัฐวุฒิ อุณมาลย์, น. พ., อนุพงศ์ สุขประเสริฐ, อุทิศ พงศ์จิรวัฒนา. (2564). การวิเคราะห์ความสัมพันธ์
 ระหว่างความรู้สึกวิตเตอร์กับราคาน้ำมันดิบในตลาดเวสต์เท็กซัส (WTI). Paper presented
 at the การประชุมวิชาการระดับชาติ วิทยาศาสตร์ เทคโนโลยีและนวัตกรรม ครั้งที่ 2,
 มหาวิทยาลัยแม่โจ้.

ทวีพงศ์ แซ่ลิ้ม และ ไกรชิต สุตะเมื่อง. (2556). ปัจจัยที่มีผลกระทบต่อราคาทองคำในตลาดโลก. วารสาร
 การเงิน การลงทุน การตลาด และบริหารธุรกิจ ปีที่ 3 ฉบับที่ 2(เมษายน-มิถุนายน 2556), 2,
 19.

ทำไมต้องรู้จัก Dollar Index ส่งผลต่อพอร์ตลงทุนขนาดไหน. (2565).

<https://www.moneybuffalo.in.th/stock/what-is-dollar-index>

ธนาคารกรุงศรีอยุธยา. HUI Index.

https://www.gcap.co.th/gcapgold/knowledge_detail.php?gcapnews_id=604

ธาดา จันตะคุณ. (2559). การพยากรณ์ความเป็นไปได้ในการเลือกสมัครสาขาวิชาโดยใช้เทคนิคเหมือง
 ข้อมูล. มหาวิทยาลัยราชภัฏมหาสารคาม. (สาขาวิชาระบบสารสนเทศเพื่อการจัดการ คณะ
 วิทยาศาสตร์และเทคโนโลยี). (005.74 ธ242ก)

ภัทรา เรืองสวัสดิ์. (2010). รูปแบบการดำเนินชีวิตและพฤติกรรมการใช้เครือข่ายสังคมออนไลน์ของคน
 วัยทำงานในเขตกรุงเทพมหานคร. มหาวิทยาลัยธรรมศาสตร์.

มนัสวี เต็ดอนันต์กุล. (2565). ทองขึ้นเพราะอะไร แล้วนำลงทุนไหม?

<https://www.kasikornbank.com/th/kwealth/Pages/a084-invest-gold.aspx>

ศรินยา ตั้งเกื้อมิตร และ บัณฑิต ชัยวิษณุชาติ. (2555). การวิเคราะห์ความสัมพันธ์ระหว่างปริมาณการ
 ถือครองทองคำของกองทุนทองคำ (SPDR Gold Trust) และราคาทองคำแห่งในตลาดโลก.
 มหาวิทยาลัยเกษตรศาสตร์. (วิทยานิพนธ์).

สุปัญญา อภิวงศ์โสภณ. (2561). ตรวจสอบข่าวปลอมด้วยวิธีการเรียนรู้ด้วยเครื่อง. (ปริญญา

วิศวกรรมศาสตร์ดุสิตบัณฑิต). จุฬาลงกรณ์มหาวิทยาลัย. (วิทยานิพนธ์ดุสิตบัณฑิต).
(5771425821)



ประวัติผู้เขียน

ชื่อ-สกุล

สกันต์ ลิ้มศรีสกุลวงศ์

สถานที่เกิด

กรุงเทพฯ

วุฒิการศึกษา

M.B.B.S. Guangzhou University of Chinese Medicine

ที่อยู่ปัจจุบัน

156/47-48 ถนนอิสรภาพ แขวงบ้านช่างหล่อ เขตบางกอกน้อย

กรุงเทพมหานครฯ



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY